

单项模型可筛选的船舶横摇组合预测

李占英¹, 徐亮², 初红霞³, 梅彦平¹

(1. 大连理工大学城市学院 电子与自动化学院, 辽宁 大连 116600; 2. 大连中远船务工程有限公司, 辽宁 大连 116113; 3. 黑龙江工程学院 电气与信息工程学院, 哈尔滨 150001)

摘要: 提出了基于单项模型可筛选的船舶横摇运动组合预测方法. 运用协整理论方法和非负约束的冗余方法对模型进行筛选, 将筛选出的单项模型进行组合, 并将其用于对我国某型船舶横浪航行情况的预测. 预测结果表明, 在预测精度及预测时长方面均好于各单项模型和未经过单项模型筛选的组合预测模型, 从而验证了所提出方法的有效性和可行性.

关键词: 船舶横摇运动; 组合预测; 模型筛选; 时间序列预测; 神经网络

中图分类号: TP183

文献标志码: A

Ship roll combination prediction based on single model screening

LI Zhan-ying¹, XU Liang², CHU Hong-xia³, MEI Yan-ping¹

(1. School of Electronic Engineering and Automation, City Institute of Dalian University of Technology, Dalian 116600, China; 2. Cosco Dalian Shipyard Company Ltd, Dalian 116113, China; 3. College of Electrical and Information Engineering, Heilongjiang Institute of Technology, Harbin 150001, China. Correspondent: LI Zhan-ying, E-mail: l_zy1979@126.com)

Abstract: The combination prediction of ship rolling motion is proposed based on single model screening. Single model is selected by using co-integration theory and redundant method based on non-negative constraints, and the combination model is established by using the screened single models. The combination model is used to predict the situation of one certain type of ship sailing in the beam sea condition. Simulation results show that the model used in contrast to single model and combination model of single model non-screening can quickly and accurately predict the time series of ship rolling, and also show the feasibility and effectiveness of the proposed.

Key words: ship rolling motion; combination prediction; model screening; time series prediction; neural network

0 引言

舰船摇荡运动的极短期预测技术对于改进航态控制系统性能, 提高其武器装备系统的适应力和海上特殊作业等具有重大意义. 船舶运动预测是依据已有的运动信息预测未来的运动情况. 目前常用的预测方法有: 灰色系统预测、时间序列预测、神经网络预测^[1-3]等. 每种方法都有其独特的信息特征, 能从不同的角度反映未来的情况, 预测结果可能差别很大, 也可能互补. 为了最大限度地利用有用信息, Bates等^[4]在1969年提出了组合预测理论. 组合预测的目的是取长补短, 利用更多可靠的信息形成一个更加稳定的预测结果, 显著地改进了预测效果, 受到了国内外学者的关注并已应用于各行各业^[5-10]. 组合预测模型成

功的关键是如何选择单个模型进行组合预测及如何确定各个模型的加权系数. 然而在实际应用中, 通常只是人为主观地决定参与组合预测的单项预测模型, 而不经筛选直接进行组合, 因此, 研究如何从多种备选模型中选择最有效的几种模型进行预测是很必要的.

组合预测的实质是对单项预测模型的信息进行选择利用的一个过程. 在模型选择过程中, 若将预测误差较大的某些方法简单地舍掉, 则会失去一些有用的信息, 所以应对参加组合预测的单项模型进行模型筛选. 预测模型的筛选过程既不能仅根据已有的知识和经验来选择, 也不能仅依据其在某个特定预测对象上所呈现的明显特征来选择.

收稿日期: 2012-12-11; 修回日期: 2013-04-22.

基金项目: 国家高技术研究发展计划项目(2008AA01Z148); 黑龙江省教育厅科学技术研究项目(12531528).

作者简介: 李占英(1979—), 女, 副教授, 博士, 从事智能控制、时间序列预测的研究; 徐亮(1978—), 男, 工程师, 从事船体设计的研究.

本文在已有的船舶运动预测方法的研究基础上, 选择多个单项模型进行组合预测. 分析了如何判定和检验参与组合预测的单项预测需满足的条件, 并运用非负约束的冗余方法和协整理论方法对模型进行筛选. 将筛选出的单项模型进行组合, 并与一些已有的单项预测模型和组合模型进行对比. 实验结果表明, 经过筛选后所得的组合模型具有更好的预测效果.

1 组合预测模型中单项预测模型的筛选

1.1 协整性筛选

一个时间序列由于随机干扰等因素, 变量在短期内有可能偏离均值, 但从长期看却存在某种均衡关系. 协整可被看作这种均衡关系性质的统计表示. 在预测序列不稳定的条件下, 必须在组合单项预测方法之前考虑协整性要求, 进行单项预测方法的协整性筛选, 保证非平稳序列预测误差的稳定性, 这是组合预测的重要前提条件^[11]. 因此在建立组合预测模型前, 应剔除与被预测序列不具有协整关系的预测序列.

时间序列是协整的是指若实际序列和预测序列本身是非平稳的, 即为 $I(1)$ ($I(1)$ 表示一阶单整过程) 的, 而其一阶差分后的序列是平稳的, 即为 $I(0)$, 且具有零均值, 则称二者具有协整性^[12].

对某一时间序列进行协整筛选, 首先应进行时间序列平稳性检验, 然后进行时间序列协整性检验. 常用的平稳性检验方法有两种: 图示法和单位根检验法. 本文选用单位根检验方法进行序列平稳性判断. 协整检验法通常有 E-G 两步法和 Johansen 协积检验法^[12], 本文选用后者, 该方法通过特征值轨迹检验和最大特征值检验来判别变量之间的协整性.

1.2 非负约束的冗余方法筛选

在一些组合预测模型中, 若因为某个模型的存在而降低了组合预测的精度, 则此单项预测模型所包含的信息称为冗余信息, 利用含有冗余信息的单项模型进行预测的方法称为冗余方法. 若能将所有冗余方法剔除, 则组合预测的精度将会提高, 组合预测的复杂度也将得到简化.

设船舶横摇运动预测有 n 种方法, 第 i 种方法预测的误差向量为 E_i , 则各单项预测方法的预测平方和及协方差分别记为

$$E_i^T E_i = E_{ii}, E_{ij} = E_i^T E_j, \quad i, j = 1, 2, \dots, n, i \neq j. \quad (1)$$

n 种方法得到的预测误差协方差为

$$A_n = (E_{ij})_{n \times n} = \begin{bmatrix} E_{11} & E_{12} & \dots & E_{1n} \\ E_{21} & E_{22} & \dots & E_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ E_{n1} & E_{n2} & \dots & E_{nn} \end{bmatrix}. \quad (2)$$

文献 [11] 的研究表明: 若预测误差协方差阵 A_n 中第 r 列元素代数余子式之和非正, 则第 r 个预测模型为冗余方法, 即: 若 $\sum_{i=1}^n A_{ir} \leq 0$ (其中 A_{ir} 为 A_n 中元素 E_{ir} 的代数余子式), 则第 r 个预测模型应在组合之前去掉.

由此可知, 只需计算几个预测模型的预测协方差阵 A_n , 便可完成对组合预测模型的非负约束筛选.

1.3 单项预测模型的筛选流程

根据协整性和非负约束的冗余方法筛选, 可以得到组合预测建模中各单项预测模型的筛选流程如图 1 所示.

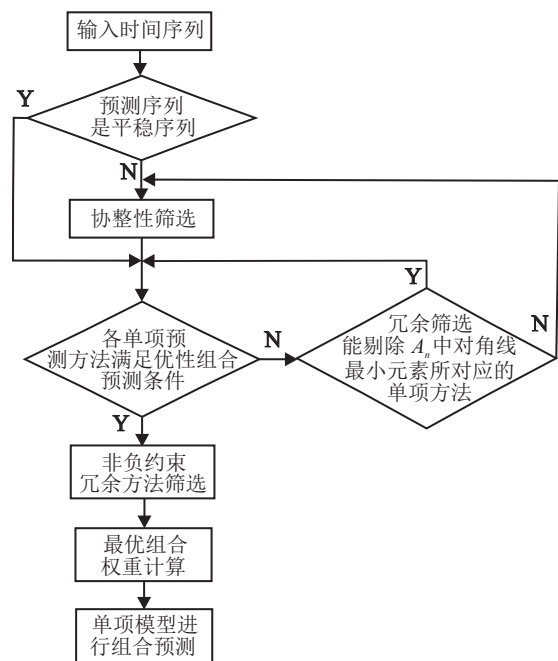


图 1 各单项预测模型的筛选流程

图 1 中, 最优组合预测条件是指组合预测的预测误差平方和小于参加组合的各种方法的预测误差平方和中的最小者^[13]. 最优组合并不一定总是存在, 若不存在, 则只能放弃组合, 选择预测精度最高的单项预测方法进行预测.

2 仿真实验

2.1 单项预测模型的选用

进行组合预测前需选取各单项模型. 由文献 [14] 可知, 船舶横摇运动时间序列具有混沌特性, 因此, 基于相空间重构的预测模型能较好地反映横摇运动本质且预测效果较好. 本节所选用的模型均基于相空间重构思想, 选择具有代表性的神经网络模型, 即 DRNN 网络预测模型、RBF 网络预测模型、BP 网络预测模型、回声状态网络预测模型等 4 种模型进行组合预测模型中各单项预测模型的冗余和协整筛选, 进而建立非线性最优组合预测模型.

2.2 预测模型的协整性筛选

为方便起见,将基于相空间重构的4种模型,即DRNN网络预测模型、RBF网络预测模型、BP网络预测模型和回声状态网络预测模型等单项预测序列分别编号为 Y_1 、 Y_2 、 Y_3 和 Y_4 ,一阶差分后的序列分别记为 dY_1 、 dY_2 、 dY_3 和 dY_4 ,实际值序列为 Y .在同一样本区间下预测,利用检验残差序列的单整阶数法进行原序列和预测序列之间的协整性筛选,利用Mackinnon提出的响应面方法(RSM)来建立临界值与样本容量之间的关系式.本节实验是在Eview6.0软件下完成的,利用软件进行单位根检验,分别对原始序列和一阶差分后的序列进行检验,检验结果如表1所示.

表1 原始序列单位根检验结果

| 单位根检验及临界值 | 原始序列 | 一阶差分后序列 |
|-----------|------------|------------|
| ADF 统计值 | 1.660 720 | -10.859 18 |
| 1% 临界值 | -2.567 295 | -2.567 249 |
| 5% 临界值 | -1.941 143 | -1.941 136 |
| 10% 临界值 | -1.616 485 | -1.616 489 |
| 结论 | 非平稳 | 平稳 |

由表1可知,原始序列经过单位根检验后的统计值大于临界值,表明含有单位根,序列是非平稳的.若经过一阶差分后,单位根的检验为负且绝对值较大,则拒绝单位根假设,表明序列为平稳的,说明原序列为 $I(1)$ 的.同理可以通过对其他预测序列的检验,得到各预测序列单位根的检验结果如表2所示.

表2 各预测序列单位根检验方法

| 预测方法 | ADF 统计量 | 1% 临界值 | 结论 |
|--------|------------|------------|-----|
| Y_1 | 4.508 492 | -2.627 238 | 非平稳 |
| dY_1 | -3.729 161 | -2.628 961 | 平稳 |
| Y_2 | 1.540 758 | -2.632 688 | 非平稳 |
| dY_2 | -5.320 203 | -2.632 688 | 平稳 |
| Y_3 | 3.049 417 | -2.627 238 | 非平稳 |
| dY_3 | -4.066 953 | -2.627 238 | 平稳 |
| Y_4 | -3.510 868 | -2.630 762 | 平稳 |
| dY_4 | -5.102 727 | -2.630 762 | 平稳 |

由协整的定义可知,要具有协整性必须满足一个必要条件:组合预测中的每个单项预测序列均为 $I(1)$ 序列且具有协整关系,此时预测误差是 $I(0)$,否则预测误差是 $I(1)$.由上述实验结果可知, Y_4 序列的ADF统计值小于临界值,为平稳序列,不是 $I(1)$ 序列,不满足与实际值序列协整的必要条件,预测误差是不稳定的,因此应在组合之前剔除 Y_4 这种方法,即剔除回声状态网络方法.而其余的几个序列均是 $I(1)$ 序列,可以再利用Johansen协整检验的协整筛选方法继续检验它们与实际序列 Y 的协整关系.直接利用Eviews下的Cointegration test下的Johansen cointegration test进行检验即可.

表3和表4用于检验是否存在协积关系,即原假设是3个变量之间不存在长期均衡关系.这个假设在

5%显著性水平下已被拒绝,表明它们具有协积关系.而且通过迹统计量检验有 $52.61 > 29.80$, $28.45 > 15.50$, $13.19 > 3.84$,最大特征值统计量检验有 $24.16 > 21.13$, $25.16 > 14.26$, $13.19 > 3.84$,所以上述 Y_1 、 Y_2 、 Y_3 三个序列存在协整关系.

表3 Johansen 协积检验-迹统计量

| Hypothesized No. of CE (s) | 特征值 | 迹统计量 检验 | 5% 检验 |
|----------------------------|----------|----------|----------|
| RBF 模型* | 0.488 85 | 52.607 0 | 29.797 1 |
| DRNN 模型* | 0.345 42 | 28.447 4 | 15.494 7 |
| BP 模型* | 0.306 80 | 13.191 9 | 3.841 47 |

表4 Johansen 协积检验-最大特征值统计量

| Hypothesized No. of CE (s) | 特征值 | 最大特征值 统计量检验 | 5% 显著水平 |
|----------------------------|-----------|-------------|-----------|
| RBF 模型* | 0.488 854 | 24.159 60 | 21.131 62 |
| DRNN 模型* | 0.345 423 | 15.255 56 | 14.264 60 |
| BP 模型* | 0.306 803 | 13.191 88 | 3.841 466 |

注:*表示在0.05的显著水平内拒绝原假设.

2.3 冗余方法筛选

根据各单项模型的预测,可以计算出它们的误差序列 E_1 、 E_2 、 E_3 ,计算预测误差信息矩阵,得到结果如下:

$$A_n = \begin{bmatrix} 0.0199 & 0.0176 & 0.0150 \\ 0.0176 & 0.0296 & 0.0276 \\ 0.0150 & 0.0276 & 0.0391 \end{bmatrix}.$$

由误差信息矩阵可知,误差矩阵的对角线元素中的最小者不是其所在行的最小者,即 $\min\{E_{11}, E_{22}, E_{33}\} = E_{11} = 0.0199$,而 $E_{11} > E_{12}$,满足优性组合预测存在的充要条件^[13],所以,这3种模型的恰当组合可以降低预测误差,提高预测精度,满足需要.计算预测误差信息矩阵 A_n 的行列式 $|A_n|$ 与伴随矩阵 A_n^* ,可得

$$|A_n| = 3.6738 \times 10^{-6},$$

$$A_n^* = 10^{-3} \times \begin{bmatrix} 0.3956 & -0.2742 & 0.0418 \\ -0.2742 & 0.5531 & -0.2852 \\ 0.0418 & -0.2852 & 0.2793 \end{bmatrix}.$$

计算3列元素的代数余子式之和分别为0.1632、-0.0063、0.0359.其中只有第2列元素的代数余子式之和小于零,因此第2种方法(RBF网络预测方法)即为冗余方法,应在组合之前剔除.可见即使单项预测效果较好的模型也不一定在组合预测中发挥优势.

将DRNN与BP模型进行组合,重新计算组合预测模型的预测误差信息矩阵为

$$A_n = \begin{bmatrix} 0.0199 & 0.0150 \\ 0.0150 & 0.0391 \end{bmatrix}, |A_n| = 5.5309 \times 10^{-4},$$

$$A_n^* = \begin{bmatrix} 0.0391 & -0.0150 \\ -0.0150 & 0.0199 \end{bmatrix}.$$

这2列元素的代数余子式之和分别为0.0241和0.0049,均大于零.若这2个单项预测模型的组合权重满足非负性约束,即没有冗余方法,则可以最小方差为准则建立基于这2种模型的加权组合预测模型.

令 \hat{y}_z 为组合预测模型的预测值, w 为权系数, e_z 为预测误差; x_{1t} 为DRNN模型预测值, w_1 为其权系数, e_1 为预测误差; x_{2t} 为BP模型预测值, w_2 为权系数, e_2 为预测误差,则有

$$\begin{cases} \hat{y}_z = w_1 x_{1t} + w_2 x_{2t}, \\ w_1 + w_2 = 1. \end{cases} \quad (3)$$

误差为

$$e_z = w_1 e_1 + w_2 e_2, \quad (4)$$

协方差为

$$\text{Var}(e_z) = \text{Var}(w_1 e_1 + w_2 e_2), \quad (5)$$

从而有

$$w_1 = \frac{\text{Var}(e_2) - \text{Cov}(e_1, e_2)}{\text{Var}(e_1) + \text{Var}(e_2) - 2\text{Cov}(e_1, e_2)}. \quad (6)$$

又因为 $w_2 = 1 - w_1$,所以 $\text{Cov}(e_1, e_2) = 0$,且

$$w_1 = \frac{\text{Var}(e_2)}{\text{Var}(e_1) + \text{Var}(e_2)}, \quad (7)$$

$$w_2 = \frac{\text{Var}(e_1)}{\text{Var}(e_1) + \text{Var}(e_2)}. \quad (8)$$

2.4 仿真结果对比

各预测模型均以船舶90°横浪时的横摇角前800个样本即400s为训练数据,为与已有方法预测20s进行对比及清晰显示预测结果,依然选取后40个样本(801~840个样本)即20s为预测数据.将组合预测模型与各单项预测模型的预测效果进行对比,如图2和图3所示.其中DRNN模型预测权系数为 $w_1 = 0.7235$,BP模型预测权系数为 $w_2 = 0.2765$.




图2 模型预测对比




图3 模型预测误差对比

由图2及图3的预测情况可知,组合预测模型的预测逐点相对误差明显好于各单项预测模型的预测逐点误差,且预测时长和精度也有所增加,在误差0.05度量级内可预测时长达到20s.为了充分说明本文所提出的模型筛选方法的有效性,可将组合模型中再加入冗余模型进行预测,以对比本文获得的最优组合预测模型的预测效果.

将之前检验的冗余模型(RBF)加到组合模型中,再次进行预测,预测的结果与DRNN网络和BP网络进行对比,得到预测误差如图4所示.




图4 含RBF冗余模型的预测误差对比

由图3和图4可以看出,加入单项模型预测效果较好的RBF网络之后,组合预测模型在15s后预测误差增大,预测效果不如单项的DRNN模型.可见加入冗余模型后不但不能使组合模型达到较好的预测效果,反而使得组合模型的预测效果下降,因此剔除冗余后的组合预测模型会使模型预测精度更高,预测时长更长.

实验结果表明,单项预测效果较好的预测模型不一定能在组合预测模型中发挥作用,反而可能会起到降低预测效果的作用,因此如果仅根据经验选择预测效果较好的单项模型进行组合,并不一定能得到最优的模型.综上所述,经过单项模型筛选的组合预测模型在预测逐点相对误差及预测时长上均具有最好的效果.其效果不仅优于各个单项预测模型,也优于含有冗余单项模型的组合模型的预测,从而证实了本文中模型筛选工作的重要性.

3 结论

在以往的组合预测研究中,通常不经过单项模型的筛选,而是根据个人的主观臆断,将误差较大的模型舍弃,挑选认为预测精度好的模型进行组合.然而,那些误差较大的模型恰恰可能包含着很多有用的信息,致使预报模型的预报脱离实际.本文在对以往的船舶摇荡运动极短期预测研究成果进行总结和分析的基础上,针对上述问题,在提高组合预测准确度和精度的前提下,对组合预测的单项预测模型筛选问题进行了深入研究,并给出了相应的筛选步骤和方法.经过实验仿真,验证了该方法能有效地提高组合预测

的精度,简化计算,为船舶横摇运动预测提供了一条新的思路.本文的方法也适用于船舶的其他摇荡运动预测.本文所做的工作仅限于极短期的预测,若能突破极短期进行中长期预测将会有更大的意义.如何突破极短期预测增加预测时间尚需进一步探索.

参考文献(References)

- [1] Viorel Nicolau, Dorel Aiordachioaie, Rustem Popa Wiener. Neural network prediction of the wave on the yaw motion of a ship influenc[C]. IEEE Int Joint Conf on Neural Networks Budapest. Hungary: IEEE, 2004: 2081-2086.
- [2] Pena Fernando Lopez, Gonzalez Marcos Miguez, Casas Vicente Diaz, et al. Ship roll motion time series forecasting using neural networks[C]. IEEE Int Conf on Computational Intelligence for Measurement Systems and Applications(CIMSA). Ottawa: IEEE, 2011: 1-6.
- [3] De Masi G, Gaggiotti F, Bruschi R, et al. Ship motion prediction by radial basis neural networks[C]. 2011 IEEE Workshop on Hybrid Intelligent Models and Applications(HIMA). Paris: IEEE, 2011: 28-32.
- [4] Bates J M, Granger C W J. Combination of forecasts[J]. Operations Research Quarterly, 1969, 20(4): 319-325.
- [5] Widodo A, Budi I. Combination of time series forecasts using neural network[C]. 2011 Int Conf on Electrical Engineering and Informatics(ICEEI). Bandung: IEEE, 2011: 1-6.
- [6] Hong Kook Kim, Rose R C. Cepstrum-domain model combination based on decomposition of speech and noise using MMSE-LSA for ASR in noisy environments[J]. IEEE Trans on Audio, Speech, and Language Processing, 2009, 17(4): 704-713.
- [7] Jin Lei, Chen Huayou, Li Xiang, et al. The optimal combination forecasting model based on closeness degree and IOWHA operator under the uncertain environment[C]. 2011 IEEE Int Conf on Grey Systems and Intelligent Services(GSIS). Nanjing: IEEE, 2011: 223-227.
- [8] Zhang Yang. Hourly traffic forecasts using interacting multiple model(IMM) predictor[J]. IEEE Signal Proc Letters, 2011, 18(10): 607-610.
- [9] Granger C W J. Combining forecasts-twenty years later[J]. J of Forecasting, 1989, 8(3): 167-173.
- [10] 曾勇,李玉东,唐小我.简单平均组合预测有效性的应用分析[J].电子科技大学学报,1999,28(1): 84-88.
(Zeng Y, Li Y D, Tang X W. An empirical study of efficiency of averages of forecasting[J]. J of University of Electronic Science and Technology of China, 1999, 2(28): 84-88.)
- [11] 韩冬梅,牛文清,于长锐.组合预测建模中单项预测模型筛选研究[J].系统工程与电子技术,2009,6(31): 1381-1385.
(Han D M, Niu W Q, Yu C R. Research on single forecast model screening for combination forecast modeling[J]. Systems Engineering and Electronic, 2009, 6(31): 1381-1385.)
- [12] 张世英,许启发,周红.金融时间序列分析[M].北京:清华大学出版社,2008: 86-90.
(Zhang S Y, Xu Q F, Zhou H. Analysis of financial time series[M]. Beijing: Tsinghua University Press, 2008: 86-90.)
- [13] 陈华友,侯定丕.基于预测有效度的优越性组合预测模型研究[J].中国科学技术大学学报,2002,32(2): 172-180.
(Chen H Y, Hou D P. Research on superior combination forecasting model based on forecasting effective measure[J]. J of University of Science and Technology of China, 2002, 32(2): 172-180.)
- [14] 李占英,王科俊,徐亮,等.混沌对角递归神经网络的船舶横摇预报方法[J].控制与决策,2012,27(11): 1681-1684.
(Li Z Y, Wang K J, Xu L, et al. Approach of prediction of ship rolling based on chaotic diagonal recurrent neural networks[J]. Control and Decision, 2012, 27(11): 1681-1684.)

(责任编辑: 闫 妍)