

基于神经核网络高斯过程回归的甲板运动预测

秦朋, 罗建军, 马卫华, 武黎明

(西北工业大学 航天学院, 陕西 西安 710072)

摘要:甲板运动预测与补偿是舰载机自动着舰的关键技术之一。传统甲板运动预测方法依赖于运动建模的准确性和参数调整,面临复杂海况、不同舰型、航态变化时具有适应性差、预测时长短、结果可靠性低等问题。提出一种基于神经核网络高斯过程回归(NKN-GPR)的甲板运动预测模型,使用神经核网络(NKN)实现高斯过程回归(GPR)模型自动复合核构造,有效改善基于规则库自动核搜索(ACKS)算法依赖人工先验知识的不足。以正弦波组合模型和功率谱模型构造仿真数据,对NKN-GPR模型和基于最小二乘法的自回归(AR)模型进行对比仿真验证,仿真结果表明,NKN-GPR模型在运动预测精度、平滑性、预测时长等方面具有显著优势,证明了所提算法的有效性,可为舰载机自动安全着舰提供理论支撑。

关键词:自动着舰;甲板运动预测;高斯过程回归;神经核网络;自动复合核构造

中图分类号:V249.12

文献标志码:A

文章编号:1000-2758(2024)03-0377-09

舰船海上航行会因海浪、海涌和风力的影响产生纵向运动(纵荡、沉浮、俯仰)和横侧向运动(横荡、横滚、偏航),导致甲板上的着舰点做三自由度漂移。舰载机着舰接近舰尾时,要求飞机和甲板的运动保持高度同步,将纵向偏差限制在小范围阈值内,以避免着舰挂索过程中飞机意外逃逸、撞击甲板等事故发生。但由于机、舰之间指令解算和信号传输存在时延,舰载机对引导控制指令的响应存在滞后性,致使同步运动十分困难^[1]。因此,使用甲板运动预测补偿引导控制指令,是实现舰载机自动着舰的重要手段,也是当前研究的热点问题。

甲板运动预测方法采用的模型一般可分为舰船流体动力学模型、经典时间序列模型、机器学习模型和混合模型^[2]。早期甲板运动预测基于舰船流体动力学模型,将艏前波高测量值应用于卷积方程,进而获取舰船甲板运动的预测,其性能取决于舰船响应核函数^[3]。但实际应用时难以获得高精度物理模型,导致适应性较差、预测精度较低。为克服需要精确估计响应核函数、噪声和状态空间的缺陷,基于

经典时间序列模型的运动预测方法得到广泛研究。根据输入的波浪传感器时间序列和舰船响应数据,使用时间序列模型预测舰船实时运动,如基于统计学的自回归(AR)模型、自回归移动平均模型等^[4-5]。经典时间序列模型采用的统计学方法具有计算量小、实时性好的优点,但是难以处理噪声数据,缺乏对环境的适应性。

机器学习为甲板运动预测问题提供了新的解决思路。基于奇异值分解和遗传算法的神经网络、支持向量机、径向基函数神经网络、长短期记忆神经网络等机器学习方法在海试中被证明能够准确预测波浪序列引起的舰船运动响应^[6-9]。但以上方法通常只针对特定工况有较好的预测性能,当面对新的工况或随机性过强时,训练模型的适应性差。为解决这一问题,基于机器学习方法的混合模型预测成为近年研究的热点。结合预测模型与预处理技术,能克服单一机器学习模型预测的缺点。Xu等^[10]将移动网格搜索-最小平方支持向量机的混合模型用于在线预测波浪中的舰船滚动运动。Skulstad等^[11]建立动态模型和神经网络组成的合作性混合模型,其中神经网络用于预测动态模型的加速度误差,以实现预测精度提升。此外,相关研究还提出了自适应动态粒子群优化算法、双向长短时记忆神经网络、长

收稿日期:2023-06-10

基金项目:国家自然科学基金(12072269)资助

作者简介:秦朋(1990—),硕士研究生

通信作者:罗建军(1965—),教授 e-mail:jljluo@nwpu.edu.cn

短时记忆网络-高斯过程回归、EMD-SVR 等各类混合模型^[12-14]。与传统单一机器学习预测方法相比,混合模型具有更好的预测精度,但很少考虑预测结果的不确定性,且存在模型复杂、参数难以调整、泛化性差、不易在线应用的缺点。

另一方面,虽然预测精度是甲板运动预测研究中的重要指标,但获取强随机性下舰船运动的趋势和可靠地预测不确定性信息更有利于提高舰载机自动着舰的安全性和效率。高斯过程回归(GPR)是近年发展起来的一种概率机器学习方法,有严格的统计学习理论支撑,对高维、小样本、非线性等复杂问题具有高适应性、强泛化能力、易于计算模型预测的置信区间^[15],如余敏等^[16]采用稀疏伪输入高斯过程回归方法进行空间自由翻滚目标的运动预测,为机器人抓捕提供了前提条件。但传统高斯过程回归通常需要给定核函数的参数化形式,选择合适的核函数是 GPR 建模的关键挑战。Duvenaud 等^[17]在传统 GPR 模型框架下嵌入一种自动复合核搜索(ACKS)算法,能够自动捕获数据内在结构特性,充分挖掘数据中隐含的模式信息,从而建立更精准的回归模型,实现了观测数据到预测数据端到端自动模型构造及预测。基于 ACKS 的高斯过程在锂电池剩余寿命估计、导弹气动性能评价等复杂问题中展现出显著优势,明显提升了 GPR 模型的性能^[18-19]。但 ACKS 的主要缺点是基于规则库的离散搜索内核语法非常昂贵,即使对于短时间序列也常需要数小时的学习计算。Sun 等^[20]在上述 ACKS 基础上提出了神经核网络(NKN)方法,用神经网络形式代替基于规则库的离散内核搜索语法,实现了复合核函数快速构造。本文将神经核网络高斯过程回归(NKN-GPR)方法应用于甲板运动预测,能根据采集的甲板运动数据自动地快速构建模型,预测结果平滑性高、泛化性强,避免其他机器学习模型或混合模型参数难调、易过拟合等缺点。面对强随机性下的甲板运动数据,仍能够获得精确的预测结果,计算可靠的预测置信区间及甲板运动趋势,有利于提高舰载机自动着舰的安全性和效率。

1 问题描述

舰船纵向(纵荡、沉浮、俯仰)和横侧向运动(横荡、横滚、偏航)间耦合作用很小,可视为彼此独立

的过程^[21]。舰船甲板运动预测是根据历史观测数据 $\mathbf{y} = [y_t, y_{t-1}, \dots, y_{t-T+1}]$ 实现未来时刻运动状态估计的过程。其中, $(t - T + 1) \sim t$ 表示观测数据的时间窗口, T 表示窗口内采集的数据点数目, y_t 为 t 时刻描述甲板单自由度运动状态的标量值,整合时间和状态序列可得如下历史观测数据集

$$\mathbf{D} = \{(t, y_t), \dots, (t - T + 1, y_{(t-T+1)})\} = (\mathbf{t}, \mathbf{y}) \quad (1)$$

甲板运动预测的目标是根据数据集 \mathbf{D} 估计未来时刻 $t_* \in (t \sim t + M)$ 的运动状态 $f(t_*)$ 。其中, M 为前向预测时间窗口的大小,是衡量预测能力的重要指标; $f(\cdot)$ 表示运动预测器,使用 GPR 实现,并基于 NKN 实现 GPR 复合核函数的自动构造。

2 高斯过程回归

GPR 是使用高斯过程先验对数据进行回归分析的非参数概率模型^[22],能够拟合非线性数据,给出预测样本的完整后验分布,提供模型关于预测的置信区间,具有良好的模型可解释性。本节简要阐述 GPR 模型框架及训练过程。

2.1 模型框架

高斯过程(GP)是任意有限个随机变量具有联合高斯分布的集合,其性质完全由均值函数 $m(\mathbf{x})$ 和协方差函数 $k(\mathbf{x}, \mathbf{x}')$ 确定,其中 $\mathbf{x}, \mathbf{x}' \in \mathbf{R}^d$ 为任意随机变量。GP 可定义为

$$f(\mathbf{x}) \sim \text{GP}(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}')) \quad (2)$$

通常可对数据进行预处理使均值函数为 0。

给定训练集样本 $\mathbf{D} = (\mathbf{X}, \mathbf{y}) = (\{\mathbf{x}_i\}, \{y_i\})_{i=1}^n$, 其中 \mathbf{X} 表示 n 个输入向量 \mathbf{x}_i 组成的特征矩阵, \mathbf{y} 表示 n 个标量观测值 y_i 组成的观测向量,考虑以下一般的线性回归模型

$$y_i = f(\mathbf{x}_i) + \varepsilon_i \quad (3)$$

式中: y_i 为在 \mathbf{x}_i 处的观测值; $f(\cdot)$ 为函数值; \mathbf{x}_i 为输入向量; $\varepsilon_i \sim N(0, \sigma_n^2)$ 为独立同分布的高斯噪声,可得观测值 \mathbf{y} 的先验分布为

$$\mathbf{y} \sim N(0, \mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}_n) \quad (4)$$

观测值 \mathbf{y} 和预测值 f_* 的联合先验分布为

$$\begin{bmatrix} \mathbf{y} \\ f_* \end{bmatrix} \sim N\left(0, \begin{bmatrix} \mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}_n & \mathbf{K}(\mathbf{X}, \mathbf{x}_*) \\ \mathbf{K}(\mathbf{x}_*, \mathbf{X}) & k(\mathbf{x}_*, \mathbf{x}_*) \end{bmatrix}\right) \quad (5)$$

式中: $\mathbf{K}(\mathbf{X}, \mathbf{X}) = (k_{ij})$ 为 $n \times n$ 对称正定协方差矩阵,矩阵元素 $k_{ij} = k(\mathbf{x}_i, \mathbf{x}_j)$ 用来度量 \mathbf{x}_i 和 \mathbf{x}_j 之间的

相关性; $\mathbf{K}(\mathbf{X}, \mathbf{x}_*) = \mathbf{K}(\mathbf{x}_*, \mathbf{X})^\top$ 用来度量训练样本输入 \mathbf{X} 和测试点 \mathbf{x}_* 之间的协方差; $k(\mathbf{x}_*, \mathbf{x}_*)$ 表示测试点 \mathbf{x}_* 自身的方差。计算预测值 f_* 的后验分布为

$$f_* | \mathbf{X}, \mathbf{y}, \mathbf{x}_* \sim N(\bar{f}_*, \text{cov}(f_*)) \quad (6)$$

式中

$$\bar{f}_* = \mathbf{K}(\mathbf{x}_*, \mathbf{X}) [\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}_n]^{-1} \mathbf{y} \quad (7)$$

$$\text{cov}(f_*) = k(\mathbf{x}_*, \mathbf{x}_*) - \mathbf{K}(\mathbf{x}_*, \mathbf{X}) \times [\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}_n]^{-1} \mathbf{K}(\mathbf{X}, \mathbf{x}_*) \quad (8)$$

则 $\mu_* = \bar{f}_*$, $\sigma_{f_*}^2 = \text{cov}(f_*)$ 即为测试点 \mathbf{x}_* 对应预测值 f_* 的均值和方差。

2.2 模型训练

GPR的协方差函数 $k(\mathbf{x}, \mathbf{x}')$ 称作核函数,本质上决定了样本点相似性的度量方法。作为一种非参数模型,当核函数、训练数据给定,GPR模型唯一确定。但核函数自身是有参数的,通常作为GPR模型的超参数,一般通过极大似然估计获得,即通过最大化边际对数似然函数 $L(\boldsymbol{\phi}) = \lg p(\mathbf{y} | \mathbf{X}, \boldsymbol{\phi})$ 来确定核函数参数 $\boldsymbol{\phi}$ 。如对于平方指数核函数

$$k_{\text{SE}}(\mathbf{x}, \mathbf{x}') = \sigma^2 \exp\left(-\frac{(\mathbf{x} - \mathbf{x}')^2}{2l^2}\right) \quad (9)$$

式中: l 为方差尺度; σ^2 为信号方差,可记核函数参数 $\boldsymbol{\phi} = \{l, \sigma^2\}$ 。最大化 $L(\boldsymbol{\phi})$ 等价于最小化如(10)式所示的负对数似然函数

$$\begin{aligned} \lg p(\mathbf{y} | \sigma, l) &= \lg N(\mathbf{0}, \mathbf{K}_{\text{yy}}(\sigma, l)) = \\ &= -\frac{1}{2} \mathbf{y}^\top \mathbf{K}_{\text{yy}}^{-1} \mathbf{y} - \frac{1}{2} \lg |\mathbf{K}_{\text{yy}}| - \frac{N}{2} \lg(2\pi) \end{aligned} \quad (10)$$

获得最优超参数 $\boldsymbol{\phi}$ 后,GPR模型完全确定,利用(7)~(8)式即可计算测试点 \mathbf{x}_* 对应的预测值 f_* 及其方差 $\sigma_{f_*}^2$ 。

3 NKN自动复合核构造

GPR需要提前给定核函数 $k(\mathbf{x}, \mathbf{x}')$ 的参数化形式,其泛化能力严重依赖于核函数的选择。由于舰船运动规律与舰船型号、航行状态等因素相关,难以获得历史运动数据的结构特性,基于单一核函数的GPR模型无法实现对未来运动状态的准确预测,构造合理的复合核函数至关重要。本节首先介绍复合核函数常用的ACKS算法,进一步给出基于神经核网络的改进形式和训练方法。

3.1 ACKS算法

ACKS算法的核心是定义基础核函数库和复合

核函数构造规则,即使用“加”、“乘”等基本运算操作基础SE核、Per核、Lin核、RQ核,从而得到新的复杂核函数^[23]。各基础核函数定义为

$$\begin{cases} k_{\text{SE}}(\mathbf{x}, \mathbf{x}') = \sigma^2 \exp\left(-\frac{(\mathbf{x} - \mathbf{x}')^2}{2l^2}\right) \\ k_{\text{Per}}(\mathbf{x}, \mathbf{x}') = \sigma^2 \exp\left(-\frac{2\sin^2(\pi(\mathbf{x} - \mathbf{x}')/p)}{2l^2}\right) \\ k_{\text{Lin}}(\mathbf{x}, \mathbf{x}') = \sigma_b^2 + \sigma_v^2(\mathbf{x} - l)(\mathbf{x}' - l) \\ k_{\text{RQ}}(\mathbf{x}, \mathbf{x}') = \sigma^2 \left(1 + \frac{(\mathbf{x} - \mathbf{x}')^2}{2\alpha l^2}\right)^{-\alpha} \end{cases} \quad (11)$$

以上基础核函数适用于描述特殊的数据结构特性:SE核假设函数具有平滑变化结构;Per核假设函数具有重复变化结构;Lin核假设函数具有线性变化结构;RQ核假设函数具有多尺度变化结构。基于“加”、“乘”等操作的复合核构造要满足(12)式所示的函数空间封闭性

$$\begin{cases} k_1 \leftarrow \lambda \cdot k_1 + \kappa \cdot k_2 \\ k_1 \leftarrow \lambda(k_1 \times k_2) \end{cases} \quad \lambda, \kappa \in \mathbf{R} \quad (12)$$

式中: k_1 表示当前核函数中的任意组件; k_2 表示任意类型的基础核。基于以上构造规则,传统ACKS算法可使用启发式算法搜索更优的复合核函数。但基于规则库的离散搜索内核语法非常昂贵,很难应用于对学习时间短的甲板运动预测。NKN与传统ACKS算法在基础核库和构造规则方面类似,但采用神经网络代替基于构造语法的离散搜索,能够有效提高复合核的构造效率。

3.2 NKN结构

NKN仍满足(12)式所要求的“加”、“乘”操作的封闭性,给定 $\mathbf{x}_1, \mathbf{x}_2 \in \mathbf{R}^d$ 作为NKN的输入,输出复合核函数 $k(\mathbf{x}_1, \mathbf{x}_2) \in \mathbf{R}$ (或 \mathbf{C})。NKN的结构与神经网络类似,第一层由基础核函数组成,随后的模块为线性层和乘积层交替排列,以通过“加”、“乘”运算将基础核组合成复合核,如图1所示。

基础核层:基础核函数可使用任何核函数,每个基础核函数都有对应的超参数,与神经核网络中的其他参数一同被优化。

线性层:类似深度神经网络中的全连接层,每一层 $\mathbf{h}_l = \mathbf{W}_l \mathbf{h}_{l-1}$ 表示前一层的非负线性组合。线性层实现核函数单元的“加”运算,可灵活地捕获到数据中隐含的复杂结构信息,如Lin核“加”Per核表示数据具有趋势周期变化结构。

乘积层:NKN采用固定连接模式的乘积层,每

个单元是上一层多个单元的乘积。乘积层可实现核函数单元的“乘”运算,该运算允许考虑核函数中不同维度输入对输出值的非线性影响,或不同结构核函数对输出值的非线性影响,即核函数对模型可能存在相似性的影响。

激活函数:NKN 每层可包含一个非线性激活函数,但需要保证核运算的封闭性,可以选择具有正系数的多项式或者指数函数 $f(z) = e^z$ 等。




图 1 NKN 结构图

3.3 NKN 训练

NKN 中所有可训练的参数可分组为 2 类:基础核函数中的超参数,如 SE 核中的长度尺度;线性层的参数,即线性组合的权重值。可通过最大化边际似然 $L(\phi)$ 联合学习上述参数。由于 NKN 架构是可微的,可使用基于梯度的优化方法优化所有参数。

3.4 NKN-GPR 甲板运动预测流程

NKN-GPR 应用于甲板运动预测的流程大致分为初始化、训练和预测 3 个阶段。初始化阶段,根据甲板运动数据的复杂性设定 NKN 基础核层核函数类型、副本数量、超参数初始值、最大迭代次数等。训练阶段,根据各维度甲板运动周期特点设定采样频率,将采样数据用于训练 NKN-GPR 模型参数。通过最大化边际似然 $L(\phi)$ 联合学习 NKN 中所有可训练的参数。训练参数不断迭代优化,直至达到最大迭代次数或停止条件。预测阶段,将外推时间序列作为输入数据,实现甲板运动的多步前向预测。

NKN 构造核函数的计算复杂度为 $O(N^2m)$,其中, N 为数据点数量, m 为网络层数。在此计算复杂度下,可根据甲板运动数据的变化快速重建复合核函数。在此基础上,运动预测的计算量主要在于核函数矩阵求逆,计算复杂度为 $O(N^3)$ 。因此,基于 NKN-GPR 的甲板运动预测与传统 GPR 具有相近的

计算成本。同时,与其他机器学习和复杂的混合预测模型相比,NKN-GPR 需要优化的参数数量更少,模型易于收敛,具有更好的泛化性。

4 仿真校验

4.1 实验模型设置

甲板运动可分为纵向运动和横侧向运动,纵向运动对理想着舰点产生的影响较大,作为本节的仿真对象。参考美国 F/A-18 舰载机着舰过程,飞机着舰前 12.5 s 需要将理想着舰点垂直运动的位置预测结果补偿到飞控系统。理想着舰点的垂直运动位置信号 H_{DM} 由 (13) 式给出

$$H_{DM} = H_V - L_{TD}\theta_V \quad (13)$$

式中: L_{TD} 为舰体俯仰中心至着舰点的距离; H_V 为甲板的纵向沉浮运动; θ_V 为甲板的俯仰运动。

实际应用中常用基于正弦波组合的甲板运动确定性模型和基于功率谱的甲板运动随机性模型。基于正弦波组合的甲板运动模型用多个正弦函数叠加来描述甲板运动。文献[24]给出了航母以 30 kn 速度航行时,海浪及海风作用下舰体运动公式

$$\begin{cases} H_V(t) = 1.22\sin(0.6t) + 0.3\sin(0.2t) \\ \theta_V(t) = 0.5\sin(0.6t) + 0.3\sin(0.63t) + 0.25 \end{cases} \quad (14)$$

基于功率谱的甲板运动模型是白噪声通过与功率谱相对应的成型滤波器得到的频域运动函数。文献[25]给出了美国 ESSEX 级航母在 8 kn 航速、航向左舷 60° 、浪高 5.18 m 且海况主要为浪涌时的沉浮与俯仰运动公式

$$\begin{cases} H_V(s) = 0.353568s(s + 0.04)/(f_1(s) \cdot f_2(s)) \\ \theta_V(s) = 0.334034s/(f_3(s) \cdot f_4(s)) \end{cases} \quad (15)$$

式中

$$\begin{cases} f_1(s) = s^2 + 2 \times 0.2 \times 0.4s + 0.4^2 \\ f_2(s) = s^2 + 2 \times 0.2 \times 0.55s + 0.55^2 \\ f_3(s) = s^2 + 2 \times 0.2 \times 0.5s + 0.5^2 \\ f_4(s) = s^2 + 2 \times 0.3 \times 0.64s + 0.64^2 \end{cases}$$

本文在正弦波组合模型产生的沉浮和俯仰运动数据基础上,添加高斯噪声数据,作为用于运动预测的仿真数据。同样地,选取基于功率谱模型产生的沉浮运动数据。由舰体运动特征频率可知理想着舰点垂直运动周期为 6~13 s,预测器观测数据的采样时间选为 0.5 s。

仿真中使用 Lin、SE、RQ 和 Per 核 4 种基本核,经过 NKN 的线性层和乘积层构造出新的核函数,来描述 2 个数据点 \mathbf{x}_1 和 \mathbf{x}_2 之间关系。为提高模型的预测能力,NKN 第一层基本核的数量可为多个。线性层和乘积层交替进行,且乘积层使上一层的核数量减半。用 Linear P 表示经过加法层得到的 P 个核函数,用 Product Q 表示经过乘积层得到的 Q 个核函数,当第一层每种基本核数量为 2 和 4 个时,各层作用后对应核函数分别表示为 Linear16-Product8-Linear8-Product4-Linear1 和 Linear16-Product8-Linear8-Product4-Linear4-Product2-Linear1,如图 1 所示。

为验证 NKN 方法的有效性,给出基于 AR 模型的对比结果。其中,AR 模型的参数估计使用最小二乘法。对仿真结果,使用误差绝对值指标对每一步预测结果进行评估,使用误差平方和对整体预测及趋势进行评估,使用均方误差 (E_{MS}) 和均方根误差 (E_{RMS}) 对预测模型的整体精度进行评估,计算公式为

$$\begin{cases} E_{MS} = \frac{1}{m} \sum_{i=1}^m (f_i - y_i)^2 \\ E_{RMS} = \sqrt{\frac{1}{m} \sum_{i=1}^m (f_i - y_i)^2} \end{cases} \quad (16)$$

式中: y_i 为运动模型(14) 式或(15) 式产生的结果,不加噪声作为真实值; f_i 为模型的输出结果。作为运动的预测值, E_{MS} 和 E_{RMS} 的值越小,表明运动预测的结果越准确。

4.2 正弦波组合模型数据仿真与分析

针对正弦波组合的甲板沉浮运动模型,分别采用 NKN-GPR 和最小二乘法进行预测,最小二乘法阶数为 30。具体地,利用前 50 s 历史运动数据,预测未来 3 s(6 步)的运动,总预测时间为 25 s。运动数据采集存在均值为 0,方差为 0.1 的高斯噪声。NKN 第一层各个基础核数量为 2,经线性层和乘积层作用后各层的核函数为 Linear8-Product4-Linear4-Product2-Linear1。算法的对比仿真实验结果如图 2 ~5 所示。




图 2 甲板沉浮运动预测对比图




图 3 甲板沉浮运动预测误差绝对值




图 4 甲板沉浮运动预测误差平方值




图 5 甲板沉浮运动预测均方误差和均方根误差

NKN-GPR 预测误差绝对值最大为 0.42,均方误差为 0.044,均方根误差为 0.21;最小二乘法预测的误差绝对值最大为 0.95,均方误差为 0.21,均方根误差为 0.46。整体来看,NKN-GPR 预测精度提高 54%,预测误差更小,外推预测拟合度更高。另一方

面,如图 6 所示,NKN-GPR 预测结果更为平滑,能够更好地反映出甲板运动数据的趋势、周期性等属性。




图 6 甲板沉浮运动预测局部放大图

针对正弦波组合的甲板俯仰运动模型,分别采

用 NKN-GPR 和最小二乘法进行预测。由于俯仰运动周期较长,因此利用 75 s 的历史运动数据,预估未来 3 s(6 步)的运动,总预测时间为 25 s。噪声添

加及 NKN 结构与沉浮运动预测采用相同设置,最小二乘法阶数为 55。对比仿真结果如图 7~10 所示。




图 7 甲板俯仰运动预测对比图

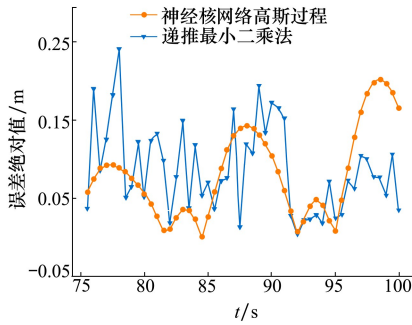


图 8 甲板俯仰运动预测误差绝对值




图 9 甲板俯仰运动预测误差平方值




图 10 甲板俯仰运动预测均方误差和均方根误差

仿真结果显示,NKN-GPR 预测误差的绝对值最大为 0.20,均方误差为 0.01,均方根误差为 0.10;与之对应,最小二乘法预测误差的绝对值最大为 0.24,均方误差为 0.01,均方根误差为 0.11。整体来看,NKN-GPR 预测精度提高 9%,预测误差更小,外推预测拟合度更高。同时 NKN-GPR 预测更加平滑,能够更好地反映出甲板运动数据的趋势、周期性等属性。

NKN-GPR 在预测时长上具有明显优势。仍然针对正弦波组合的甲板沉浮运动模型,分别采用 NKN-GPR 和最小二乘法进行较长时间预测。具体地,利用 50 s 的历史运动数据,预测 5 s(10 步)的运动,总预测时间为 25 s。噪声添加及 NKN 结构同上,最小二乘法阶数为 30。对比仿真结果如图 11~12 所示。

根据仿真结果,采用最小二乘法已不能进行有效预测,而 NKN-GPR 则不受预测时长影响,仍能够准确反映出甲板运动数据的趋势、周期性等,实现长时间外推预测。NKN-GPR 具有预测时长的明显优




图 11 甲板沉浮运动预测(5 s)对比图




图 12 甲板沉浮运动预测(5 s)误差绝对值

势,可以通过对历史数据的快速学习建模,做出长时间准确的预测。对于甲板运动预测,长时间的预测更加有利于预测理想着舰点位置,提升舰载机着舰的成功率和安全性。

4.3 功率谱模型数据实验及分析

针对功率谱模型的甲板沉浮运动模型,分别采用 NKN-GPR 和最小二乘法进行预测。具体地,利用 50 s 历史运动数据,预测 3 s(6 步)的运动,总预测时间为 25 s。由于功率谱模型产生的仿真数据结构比较复杂,设定基础核各为 4 个,层数排序为 Lin-

ear16-Product8-Linear8-Product4-Linear4-Product2-Linear1,最小二乘法阶数为 8。由于基于功率谱模型的甲板运动数据结构复杂,NKN-GPR 采用迭代方

式进行预测,即根据数据变化特性,按照一定时长,基于新的观测数据,建立新的学习模型并进行预测。对比仿真结果如图 13~16 所示。




图 13 甲板沉浮运动预测对比图




图 14 甲板沉浮运动预测误差绝对值




图 15 甲板沉浮运动预测误差平方值




图 16 甲板沉浮运动预测均方误差和均方根误差

仿真结果显示,NKN-GPR 预测的误差绝对值最大为 0.80 m,均方误差为 0.18 m²,均方根误差为 0.42 m,而最小二乘法已无法实现有效预测。基于功率谱模型的甲板运动预测难度较大,NKN-GPR 在预测过程中虽然有一定的相位滞后,但是仍然能够较准确地反映出数据的部分递减及周期属性。

5 结论

针对传统甲板运动预测方法的局限,本文使用概率机器学习中的 NKN-GPR 模型对甲板运动预测进行研究,研究结论如下:

1) 对比 AR 模型中的最小二乘法,2 种工程模型下的 3 种代表性甲板运动仿真结果均表明 NKN-GPR 模型预测精度高,在正弦波组合甲板沉浮和俯仰运动上预测精度分别提高 54%,9%,且预测结果平滑,能准确反映观测数据的结构属性,直接给出预测置信区间;

2) 将神经网络形式的结构运用于 GPR 的复合核自动搜索,能够快速地构造出适合数据特性的核结构,准确捕获隐含的内在数据结构特性,实现观测数据到预测结果端到端自动生成,不需依赖人工先验经验;

3) NKN-GPR 通过对历史观测数据学习进行快速预测,提高了甲板运动预测的精度和时长,预测时长超过 5 s,为舰载机自动安全着舰提供了有效理论支撑。

参考文献:

[1] 朱齐丹,张智,张雯. 航母舰载机安全起飞、着舰技术[M]. 哈尔滨: 哈尔滨工程大学出版社, 2016
 ZHU Qidan, ZHANG Zhi, ZHANG Wen. Aircraft carrier aircraft safe takeoff and landing technology[M]. Harbin: Harbin Engineering University Press, 2016 (in Chinese)

[2] SUN Q, TANG Z, GAO J P, ZHANG G C. Short-term ship motion attitude prediction based on LSTM and GPR[J]. Applied Ocean Research, 2022, 118: 102927

[3] KAPLAN P. A study of prediction techniques for aircraft carrier motions at sea[C]//AIAA 6th Aerospace Sciences Meeting, 1968: 68-123

- [4] YUMORI I. Real time prediction of ship response to ocean waves using time series analysis[C]//Proceedings of OCEANS 81, 1981: 1082-1089
- [5] JIANG H, DUAN S L, HUANG L, et al. Scale effects in AR model real-time ship motion prediction[J]. Ocean Engineering, 2020, 203: 107202
- [6] KHAN A, BIL C, MARION K E. Ship motion prediction for launch and recovery of air vehicles[C]//Proceedings of OCEANS 2005 MTS/IEEE, 2005: 2795-2801
- [7] LUO W, REN J. On the identification of coupled pitch and heave motions using support vector machine[C]//2016 Chinese Control and Decision Conference, 2016: 3316-3321
- [8] YIN J, ZOU Z, XU F. On-line prediction of ship roll motion during maneuvering using sequential learning RBF neural networks[J]. Ocean Engineering, 2013, 61: 139-147
- [9] SILVA K M, MAKI K J. Data-driven system identification of 6-DoF ship motion in waves with neural networks[J]. Applied Ocean Research, 2022, 125: 103222
- [10] XU C Z, ZOU Z J. Online prediction of ship roll motion in waves based on auto-moving grid search-least square support vector machine[J]. Mathematical Problems in Engineering, 2021, 2021: 2760517
- [11] SKULSTAD R, LI G, FOSSEN T, et al. A cooperative hybrid model for ship motion prediction[J]. Modeling Identification and Control, 2021, 42(1): 17-26
- [12] 张彪, 彭秀艳, 高杰. 基于 ELM-EMD-LSTM 组合模型的舰船运动姿态预测[J]. 舰船力学, 2020, 24(11): 1413-1421
ZHANG Biao, PENG Xiuyan, GAO Jie. Ship motion attitude prediction based on ELM-EMD-LSTM integrated model[J]. Journal of Ship Mechanics, 2020, 24(11): 1413-1421 (in Chinese)
- [13] ZHANG G, TAN F, WU Y. Ship motion attitude prediction based on an adaptive dynamic particle swarm optimization algorithm and bidirectional LSTM neural network[J]. IEEE Access, 2020, 8: 90087-90098
- [14] NIE Z, SHEN F, XU D, et al. An EMD-SVR model for short-term prediction of ship motion using mirror symmetry and SVR algorithms to eliminate EMD boundary effect[J]. Ocean Engineering, 2020, 217: 107927
- [15] 何志昆, 刘光斌, 赵曦晶, 等. 高斯过程回归方法综述[J]. 控制与决策, 2013, 28(8): 1121-1129
HE Zhikun, LIU Guangbin, ZHAO Xijing, et al. Overview of Gaussian process regression[J]. Control and Decision, 2013, 28(8): 1121-1129 (in Chinese)
- [16] 余敏, 罗建军, 王明明. 基于机器学习的空间翻滚目标实时运动预测[J]. 航空学报, 2021, 42(2): 195-205
YU Min, LUO Jianjun, WANG Mingming. Real-time motion prediction of space tumbling targets based on machine learning[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(2): 195-205 (in Chinese)
- [17] DUVENAUD D, LLOYD J, GROSSE R, et al. Structure discovery in nonparametric regression through compositional kernel search[C]//Proceedings of the 30th International Conference on Machine Learning, PMLR, 2013: 1166-1174
- [18] RICHARDSON R R, OSBORNE M A, HOWEY D A. Gaussian process regression for forecasting battery state of health[J]. Journal of Power Sources, 2017, 357: 209-219
- [19] 胡伟杰, 黄增辉, 刘学军, 等. 基于自动核构造高斯过程的导弹气动性能预测[J]. 航空学报, 2021, 42(4): 289-302
HU Weijie, HUANG Zenghui, LIU Xuejun, et al. Missile aerodynamic performance prediction of Gaussian process through automatic kernel construction[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(4): 289-302 (in Chinese)
- [20] SUN S, ZHANG G, WANG C, et al. Differentiable compositional kernel learning for Gaussian processes[C]//Proceedings of the 35th International Conference on Machine Learning, PMLR, 2018: 4828-4837
- [21] 王可, 徐明亮, 李亚飞, 等. 一种面向航空母舰甲板运动状态预估的鲁棒学习模型[J]. 自动化学报, 2021, 48(1): 1-9
WANG Ke, XU Mingliang, LI Yafei, et al. A robust learning model for deck motion prediction of aircraft carrier[J]. Acta Automatica Sinica, 2021, 48(1): 1-9 (in Chinese)
- [22] SCHULZ E, SPEEKENBRINK M, KRAUSE A. A tutorial on Gaussian process regression: modelling, exploring, and exploiting functions[J]. Journal of Mathematical Psychology, 2018, 85: 1-16
- [23] WILSON A, ADAMS R. Gaussian process kernels for pattern discovery and extrapolation[C]//Proceedings of the 30th International Conference on Machine Learning, PMLR, 2013: 1067-1075
- [24] 杨一栋, 余俊雅. 舰载飞机着舰引导与控制[M]. 北京: 国防工业出版社, 2007
YANG Yidong, YU Junya. Shipboard aircraft landing guidance and control[M]. Beijing: Defense Industry Press, 2007 (in Chinese)

nese)

[25] HODGES L H, SCHON D A. An analysis of teminal flight path control in carrier landing[R]. AD606040, 1970

Deck motion prediction using neural kernel network Gaussian process regression

QIN Peng, LUO Jianjun, MA Weihua, WU Liming

(School of Astronautics, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: Deck motion prediction and compensation are critical technologies for carrier-based aircraft automatic landing. Traditional deck motion prediction methods rely on precision of motion models and parameter adjustments, facing challenges in adaptability to complex sea conditions, different types of carriers, changes in flight conditions, and limitations in prediction duration, as well as reliability issues. This paper proposes a deck motion prediction method based on the neural kernel network Gaussian process regression (NKN-GPR) model. The NKN-GPR model can utilize a neural kernel network (NKN) to automatically construct the Gaussian process regression (GPR) model's composite kernel, effectively addressing the limitations of the automated kernel search (ACKS) algorithm, which heavily depends on manual prior knowledge. Simulation data is generated using a combination of sine wave and power spectrum models, and the NKN-GPR model is compared with an autoregressive (AR) model based on least squares in a simulated validation. The simulation results demonstrate that the NKN-GPR model exhibits significant advantages in motion prediction accuracy, smoothness, and prediction duration, which confirms the effectiveness of the proposed algorithm. This study provides theoretical support for safe automatic landing of carrier-based aircraft.

Keywords: automatic carrier landing; deck motion prediction; Gaussian process regression; neural kernel networks; automatic composite kernel construction

引用格式: 秦朋, 罗建军, 马卫华, 等. 基于神经核网络高斯过程回归的甲板运动预测[J]. 西北工业大学学报, 2024, 42(3): 377-385

QIN Peng, LUO Jianjun, MA Weihua, et al. Deck motion prediction using neural kernel network Gaussian process regression[J]. *Journal of Northwestern Polytechnical University*, 2024, 42(3): 377-385 (in Chinese)