

DOI:10.16356/j.1005-2615.2023.05.006

## 基于机器学习的机翼气动载荷重构及传感器优化布置

余柏杨<sup>1,2</sup>, 王明振<sup>4</sup>, 王婷婷<sup>3</sup>, 虞建<sup>1,2</sup>, 刘学军<sup>1,2</sup>, 吕宏强<sup>3</sup>

(1. 南京航空航天大学计算机科学与技术学院 / 人工智能学院, 模式分析与机器智能工业和信息化部重点实验室, 南京 211106; 2. 软件新技术与产业化协同创新中心, 南京 210023; 3. 南京航空航天大学航空学院, 南京 210016; 4. 中国特种飞行器研究所高速水动力航空科技重点实验室, 荆门 448035)

**摘要:** 风洞实验通过在机翼表面布置传感器来测量相应位置的气动载荷, 由于传感器布置数量有限, 难以直接得到整个机翼全息气动载荷分布。本文采用机器学习方法通过有限传感器数据重构机翼表面全息气动载荷, 并提出了利用仿真数据对传感器进行优化布置的方法。从计算流体力学(Computational fluid dynamics, CFD)计算所得的机翼全息气动数据中选取有限位置数据模拟传感器实验数据, 对比深度学习模型、高斯过程回归(Gaussian process regression, GPR)、支持向量回归(Support vector regression, SVR)与BP神经网络(Neural network, NN)对气动载荷的重构精度。通过评估由传感器数据重构的全息载荷精度对传感器布置方式进行优化设计。以M6机翼为例在给定的两个工况条件下验证本文所提出的方法。实验结果表明, GPR模型获得了最高气动载荷重构精度; 给出了M6机翼在不同传感器总数下最优的截面数和单个截面布点数, 最低传感器布置数下的最优布置方式, 以及流场变化相对剧烈的前缘区域与展向截面的传感器布置方式。

**关键词:** 计算流体力学; 机翼气动载荷重构; 压强系数; 风洞实验; 机器学习

中图分类号: V19 文献标志码: A 文章编号: 1005-2615(2023)05-0798-10

## Aerodynamic Load Reconstruction of Wing and Optimal Sensor Layout Based on Machine Learning Technique

YU Baiyang<sup>1,2</sup>, WANG Mingzhen<sup>4</sup>, WANG Tingting<sup>3</sup>, YU Jian<sup>1,2</sup>, LIU Xuejun<sup>1,2</sup>, LYU Hongqiang<sup>3</sup>

(1. School of Computer Science and Technology / School of Artificial Intelligence, Nanjing University of Aeronautics & Astronautics, Key Laboratory of Mode Analysis and Machine Intelligence, Ministry of Industry and Information Technology, Nanjing 211106, China; 2. Collaborative Innovation Center for New Software Technology and Industrialization, Nanjing 210023, China; 3. School of Aeronautics, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China; 4. Key Laboratory of High-Speed Hydrodynamic Aviation Science and Technology, China Special Vehicle Research Institute, Jingmen 448035, China)

**Abstract:** In wind tunnel experiments, sensors are normally placed on wing surfaces to measure the aerodynamic load at the corresponding positions. Due to the limited number of the placed sensors, it is difficult to directly obtain the holographic aerodynamic load distribution of the whole wing. In this paper, we use machine learning methods to reconstruct the holographic aerodynamic load on the wing surface from the limited sensor data, and propose a method to optimize the placement of sensors using the simulation data. We select limited position data from the wing holographic aerodynamic data calculated by computational fluid

**基金项目:** 航空科学基金(2018ZA52002, 2019ZA052011); 空气动力学国家重点实验室基金(SKLA20180102); 气动噪声控制重点实验室基金(ANCL20190103)。

**收稿日期:** 2022-08-15; **修订日期:** 2022-11-14

**通信作者:** 刘学军, 女, 教授, 博士生导师, E-mail: xuejun.liu@nuaa.edu.cn。

**引用格式:** 余柏杨, 王明振, 王婷婷, 等. 基于机器学习的机翼气动载荷重构及传感器优化布置[J]. 南京航空航天大学学报, 2023, 55(5): 798-807. YU Baiyang, WANG Mingzhen, WANG Tingting, et al. Research on aerodynamic load reconstruction of wing and optimal sensor layout based on machine learning technique[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2023, 55(5): 798-807.

dynamics(CFD) to simulate the sensor experimental data, and compare the reconstruction accuracy of the deep learning model, Gaussian process regression(GPR), support vector regression(SVR) and BP neural network(NN) to the aerodynamic load. The sensor layout is optimized by evaluating the holographic load accuracy reconstructed by the sensor data. The M6 wing is taken as an example to verify the proposed method under two given working conditions. The experimental results show that the GPR model achieves the best accuracy of aerodynamic load reconstruction. The optimal section number and single section number of M6 wing under different total number of sensors, the optimal arrangement under the lowest number of sensors, and the arrangement of sensors in the leading edge area and spanwise section where the flow field changes greatly are all given.

**Key words:** computational fluid dynamics(CFD); aerodynamic load reconstruction of wing; pressure coefficient; wind tunnel experiment; machine learning

机翼表面气动载荷分布是衡量机翼气动性能的一个重要依据<sup>[1]</sup>,在实际机翼外形设计流程中<sup>[2]</sup>,机翼表面稀疏传感器测量的气动载荷只能对气动性能做局部评估,而一次性获得整个机翼表面的气动载荷能够对整个机翼的气动性能做全面评估,极大地缩短设计流程的时间消耗,提高设计效率。风洞实验是获得气动载荷的重要手段,通过放置在机翼表面特定位置的传感器获得相应位置的气动载荷信息。如何利用这些有限传感器测量的空气动力系数重构机翼表面全息气动载荷,是一个有待研究的问题。

随着机器学习的不断发展<sup>[3]</sup>,其强大的非线性拟合能力为采用少量实验数据重构整个空间域信息提供了新的解决途径。AKBARI等<sup>[4]</sup>利用支持向量回归和多层感知器建模非线性流体流动现象,对不同比例缺失数据的速度场进行了重构;Li等<sup>[5]</sup>提出了一种包含对称深度神经网络的数据驱动模型,通过测量超音速级联通道壁上的离散压力值重建级联通道中的流场结构;Yu等<sup>[6]</sup>提出了一种基于具有几何信息特征的卷积神经网络的实用粒子重建方法,该方法可以从任何传统的基于代数重建技术方法产生的非常粗糙的粒子分布初始猜测中细化粒子重建;Qu等<sup>[7]</sup>利用机翼表面稀疏传感器数据构建了基于长短期记忆网络(Long and short term memory network, LSTM)的深度模型对全机气动载荷进行重构,该模型能够捕获机翼截面上相邻点之间的空间依赖关系,但模型较为复杂不易训练,且文献[7]中只采用了机翼表面125(5个截面、每个截面25个点)个传感器节点进行气动载荷重构实验。因传感器数量过少只对局部参与实验的少数截面进行精度验证,缺少对全息气动载荷重构精度的充分验证。本文通过查阅国内外流场重构的相关文献得知,目前文献[7]是关于机翼表面全息气动载荷重构的为数不多的相关文献,因此本文在文献[7]的基础上采用仿真数据开展多类

机器学习模型全息气动载荷重构精度的全面对比研究。

此外,利用有限传感器测量的空气动力系数重构全息气动载荷时,传感器的分布方式也是一个重要因素<sup>[8]</sup>。传感器的布置数量能够影响风洞实验的结果,放置数量过少会导致全息气动载荷的重构精度较低,而放置数量过多又可能引起流场结构发生变化从而导致传感器的测量误差<sup>[9]</sup>。在传感器布置方式的研究中,易贤等<sup>[10]</sup>提出了一种高效确定结冰传感器安装位置的方法,其基本思路是采用数值计算的手段,获得不安装结冰传感器飞机流场的水滴容积分数分布;再根据水滴收集率的定义,得到传感器拟安装区域不同位置的水滴收集率,并与机翼表面的水滴收集率对比,从保证传感器可以起到预警作用的角度出发,进而给出传感器的安装位置;杨庆东<sup>[11]</sup>利用神经网络对两种数控机床的热变形进行研究分析,确定了机床上传感器放置的数量和位置;Semaan<sup>[12]</sup>分析了基于不同驱动条件下二维非定常雷诺平均Navier-Stokes模拟得到的流场数据,利用随机森林确定了DLR-F15翼型上的最佳传感器位置,并与当前最大本征正支分解(Proper orthogonal decomposition, POD)模态振幅位置标准进行比较,以及扫描所有可能的传感器组合的蛮力方法进行比较;Kapteyn等<sup>[13]</sup>利用最优树分类器在翼展无人机的机翼上通过稀疏传感器的测量数据进行可解释的结构评估,得到了最优传感器的位置。以上工作均通过对比研究获得了不同物理场中理想的传感器布置方式,但目前还未见以机翼气动载荷重构为目的的传感器布置研究。

本文采用计算流体力学(Computational fluid dynamics, CFD)计算获得机翼全息气动数据,选取有限位置数据模拟传感器实验数据,并选取压强系数 $C_p$ <sup>[14]</sup>作为气动性能重构对象,在指定工况下采用机器学习技术获得稀疏样本点的坐标参数到压强系数的映射规律,从而重构指定工况下的全息压

强系数。对比了基于LSTM的深度模型、高斯过程回归(Gaussian process regression, GPR)、支持向量回归(Support vector regression, SVR)和BP神经网络(Neural network, NN)4种机器学习模型进行气动载荷重构的性能。研究指定工况下机翼表面传感器的优化布置方式以最大限度提高载荷重构精度,首先研究在不同的传感器总数下放置传感器的截面数量和每个截面放置传感器数量的最优值,从而利用有限传感器达到最高重构精度。同时对放置传感器的最少数量以及最少数量下的最优布置方式进行实验研究,以避免传感器数量过大对流场结构的影响。此外,对于流场变化相对剧烈的前缘区域以及展向截面的传感器布置方式进行了研究。本文以M6机翼为例验证了所提方法的应用效果。本文工作对机翼气动载荷风洞实验的传感器布置具有参考作用。

## 1 研究方案

本文研究方案分为3个部分,如图1所示:(1)仿真数据生成。首先生成机翼的三维网格,然后通过CFD获得机翼全息气动数据。(2)气动载荷重构方法对比。为避免数据不同数值范围对建模效果的影响,首先将数据归一化,然后分别采用基于LSTM的深度模型和GPR、SVR、BPNN三种机器学习模型建立指定工况下的三维坐标参数到压强系数的映射关系,对比4种模型对气动载荷的重构精度。(3)传感器布置优化。对CFD计算数据进行离散采样,模拟风洞实验的传感器布置方式。首先给定传感器总数,研究实验截面数量和每个截面传

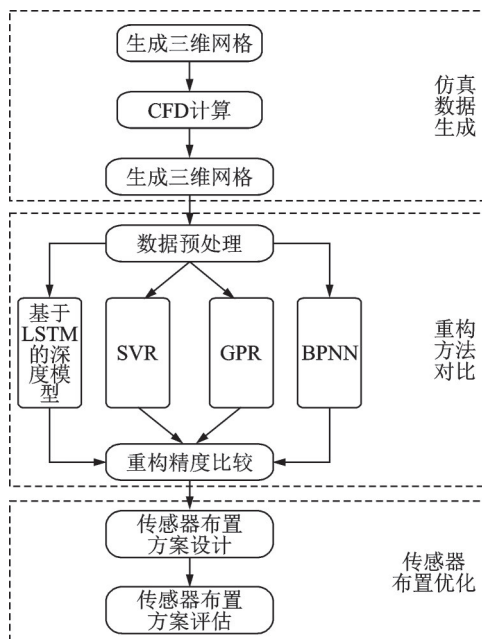


图1 研究方案

Fig.1 Research scheme

感器数量的最优设置方案,同时研究最低传感器数量下的最优布置方式。其次,对于流场变化相对剧烈的前缘区域以及展向截面研究了传感器布置方式,以保证整个机翼气动载荷重构精度。

### 1.1 数据生成

本文以M6机翼为例验证研究方案的应用效果。使用CFD方法生成M6机翼表面压强系数的模拟数据集,数据生成过程包括网格划分、数值求解和后处理。

首先对计算域进行网格划分,设置附面层第一层高度为0.02 mm,整个流场计算域总长约为10倍的机翼长度。根据M6机翼几何外形,生成结构化面网格如图2所示。采用有限体积法进行RANS方程数值求解,其中湍流模型采用SST  $k-\epsilon$  湍流模型。本文选取压强系数  $C_p$  作为气动性能重构对象。生成以三维坐标参数作为输入,压强系数作为输出的模拟数据集,共两个算例,其工况参数如表1所示。




图2 M6机翼面网格

Fig.2 Surface mesh on the M6 wing

表1 工况参数

Table 1 Working condition parameters

工况序号	$Ma$	迎角/(°)	侧滑角/(°)
1	0.6	4.0	3.0
2	0.85	7.0	5.0

数据包括M6机翼表面19 200个样本点,如图3所示。整个机翼包括80个截面,每个截面240个样本点,每个样本点的参数包含三维坐标参数和压强系数。在指定工况下,实验对机翼表面的样本点进行有规律的采样,采样点作为训练数据,其余样本点作为测试数据验证全息流场的重构精度。

为避免参数不同数值范围对建模效果的影响,将数据进行归一化处理,归一化公式为




图3 M6机翼表面样本点

Fig.3 Sample points on the M6 wing surface



$$\bar{x}_j^i = \frac{x_j^i - \mu_j}{\sigma_j} \quad (1)$$

式中: $x_j^i$ 为第*i*个样本的第*j*个特征; $\mu_j$ 为第*j*个特征的均值; $\sigma_j$ 表示第*j*个特征的标准差; $\bar{x}_j^i$ 为 $x_j^i$ 归一化后的结果。

## 1.2 模型介绍

### 1.2.1 BP神经网络

BPNN<sup>[15]</sup>模型拓扑结构包括输入层、隐藏层和输出层。输入层的个数与特征数相关,输出层的个数与类别数相同,隐藏层的层数若干个。同层神经元之间没有联系,异层神经元之间向前连接,结构如图 4 所示。图中 $x_1, x_2, \dots, x_n$ 表示*n*维输入; $y_1, y_2, \dots, y_n$ 表示隐藏层权重; $z_1, z_2, \dots, z_n$ 表示*k*维输出。

BPNN 是一种按误差逆传播算法训练的多层前馈网络,计算过程由正向计算过程和反向计算过程组成,实现从输入空间到输出空间的任意非线性函数的映射。在正向计算过程中,信号作用于输入层,经过隐藏层处理后到达输出层,输出层输出结果信号<sup>[16]</sup>。如果输出结果与预期输出的结果不匹配,则将误差进行反向计算,将误差分配给该层的所有单元,并校正这些单元的权重。该过程一直循环直到输出层的误差小于设置值或达到预设的学习时间。




图 4 BPNN 模型  
Fig.4 BPNN model

### 1.2.2 高斯过程回归模型

高斯过程(Gaussian process, GP)<sup>[17]</sup>可以看作定义在函数 $f(x)$ 上的一个分布,其性质由均值函数和协方差函数决定

$$m(x) = E[f(x)] \quad (2)$$

$$k(x, x') = E[(f(x) - m(x))(f(x') - m(x')))] \quad (3)$$

$$f(x) \sim GP(m(x), k(x, x')) \quad (4)$$

式中: $x, x' \in \mathbf{R}^d$ , $d$ 为输入向量维数, $m(x)$ 为均值函数; $k(x, x')$ 为协方差函数。

本文使用的协方差函数有 Radial-basis function (RBF) 核、Rational quadratic (RQ) 核、Exp-Sine-Squared (ESS) 核和 Matern 核<sup>[18]</sup>。这些

核函数均可通过参数设置支持各向同性以及各向异性的输入变量。其中 ESS 核可对周期性函数进行建模,Matern 核可控制结果函数的平滑程度。

### 1.2.3 支持向量回归模型

给定以  $P(x, y)$  为概率的观测样本集  $(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l) \in \mathbf{R}^n \times \mathbf{R}$ 。设回归函数  $F = \{f|f(x) = \mathbf{w}^T \Phi(x) + b, \mathbf{w} \in \mathbf{R}^n\}$ 。

引入下述结构风险函数

$$R_{\text{reg}} = \frac{1}{2} \|\mathbf{w}\|^2 + c \cdot R_{\text{emp}}^\epsilon[f] \quad (5)$$

式中: $\Phi(x)$ 为线性变化函数; $R_{\text{reg}}$ 为正则化函数; $\mathbf{w}$ 为模型参数; $b$ 为偏差; $c$ 是惩罚系数; $R_{\text{emp}}^\epsilon$ 含义为误差控制函数,上标 $\epsilon$ 为参数空间限制边界。式中 $c$ 为惩罚系数,其本质是正则化系数,表征的是 SVR<sup>[19]</sup>模型对于误差的容忍度,在经验风险和模型复杂度之间进行折中, $c$ 越大,越容易过拟合, $c$ 越小,越容易欠拟合。

利用拉格朗日函数、对偶原理和 Karush Kuhn Tucker(KKT)<sup>[20]</sup>条件可得回归函数 $f(x)$ 的表达式为

$$f(x) = \sum_{i=1}^l (a_i - a_i^*) K(x, x_i) + b \quad (6)$$

式中: $a_i, a_i^*$ 为拉格朗日系数; $K(x, x_i) = \Phi^T(x) \Phi(x_i)$ 为一个满足 Mercer 条件<sup>[21]</sup>的核函数。该函数可在不知非线性变换的具体形式下实现算法的非线性化。

本文使用的协方差函数为 RBF 内核,其定义为

$$k(x, z) = \exp\left(-\frac{d(x, z)^2}{2 \times \sigma^2}\right) = \exp(-\gamma \cdot d(x, z)^2) \quad (7)$$

式中: $x, z$ 分别为目标样本和参考样本 $d(\cdot)$ 为距离函数,计算 $x$ 与 $z$ 间的相关性; $\sigma$ 为标准差。式中 $\gamma$ 为 RBF 核函数的超参数,该参数隐含地决定了数据映射到新的特征空间后的分布, $\gamma$ 越大,支持向量越少, $\gamma$ 值越小,支持向量越多。支持向量的个数影响训练与预测的速度。

### 1.2.4 基于 LSTM 的深度模型

基于 LSTM 的深度模型<sup>[7]</sup>分成 3 个模块:(1)将低维的输入数据通过 3 层反卷积映射至高维隐含空间,增加输入数据对物理规律的描述性,使得后续模块能够在高维隐含空间中拟合出复杂的非线性映射关系;(2)使用 LSTM 对经过反卷积模块升维之后的输入数据进行空间序列建模,来捕捉单个翼型截面上多个点之间的空间依赖关系;(3)使用感知器对 LSTM 模块输出的高维空间序列依赖关系做降维处理,获得最终的压强系数。

本文设置模型反卷积核大小为  $3 \times 3$ ,步长为

2; LSTM序列长度为5,层数为3;感知器层数为4。

### 1.3 全息压强系数重构的评价指标

采用均方误差(Mean square error, MSE)<sup>[22]</sup>来评估气动载荷重构的准确性, MSE反映估计量与被估计量之间差异程度的一种度量,当预测值与真实值越接近时, MSE越小,模型越精确, MSE测量了模型在整个测试集上的平均性能。

MSE损失函数定义为

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (8)$$

式中:  $y_i$ 表示真实值;  $\hat{y}_i$ 为对应的预测值;  $n$ 为样本数。MSE越小表示预测精度越高。

## 2 实验

### 2.1 模型选择

为了比较不同回归模型对整个机翼气动载荷的重构性能,本文利用不同模型重构指定工况下的全息压强系数,工况如表1所示。通过对不同的GPR核函数、NN结构和SVR参数进行实验测试,得到载荷重构精度最高的模型参数设置。

#### 2.1.1 GPR核函数选择

为了比较GPR模型不同核函数的载荷重构效果,本文按不同的数据集比例(1.2%、2.5%、3.7%、5%和6.2%)随机采样得到训练数据,每次将剩下的数据用于对模型载荷重构精度的测试。图5显示了使用不同比例训练数据的各核函数的GPR模型重构误差。由图5可知,随着训练集增大,各核函数GPR模型的重构误差均呈下降趋势。其中采用ESS核的GPR重构精度最低,说明气动数据中不存在周期结构特性;工况1中采用Matern核的GPR在所有训练集比例下都能得到较高的重构精度,而工况2中采用RQ核的GPR在所有训练集比例下都能得到较高的重构精度,因此本文工况1中GPR选取Matern核,工况2中GPR选取RQ核。

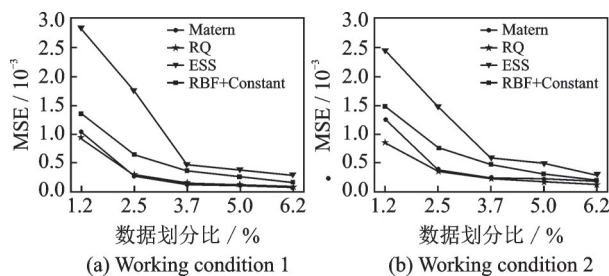


图5 不同核函数GPR模型重构误差实验结果

Fig.5 Experimental results of reconstruction error of GPR model with different kernel functions

#### 2.1.2 NN结构选择

本文采用不同隐含层结构NN模型进行实验对比,不同NN隐含层结构如表2所示。每层网络之间添加ReLU激活函数以增强模型的非线性,ReLU函数公式为

$$f(x) = \max(0, x) \quad (9)$$

式中:  $x$ 为激活层输入。在NN训练阶段设置学习速率为 $1e-4$ ,迭代次数为10 000,采用Adam优化器迭代更新网络权重,实验结果如图6所示。由图6可知,对于本文工况1、2,随着网络复杂度提高,气动载荷的重构精度也得到提高,6层NN与7层NN的精度相差不大,这表明进一步提高模型复杂度已不能显著提升模型性能,最终NN选取7层结构。

表2 不同的NN模型隐含层结构

Table 2 Different structures of hidden layers for NN models

NN隐含层数	各隐含层神经元数量
2	30, 20
3	30, 40, 20
4	40, 60, 40, 10
5	20, 40, 60, 30, 10

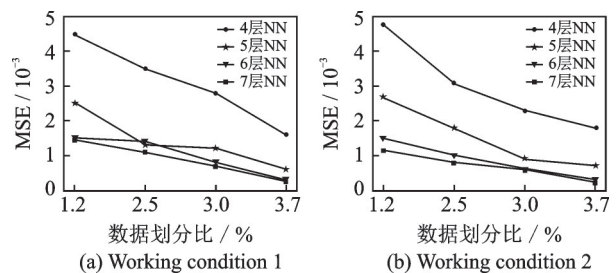


图6 不同网络结构的NN模型重构误差实验结果

Fig.6 Experimental results of reconstruction error of NN model with different network structures

#### 2.1.3 SVR参数选择

本文SVR的核函数选取RBF核,SVR有两个重要超参数 $c$ 和 $\gamma$ ,  $c$ 为惩罚系数,  $\gamma$ 为RBF核函数自带的超参数,  $\gamma$ 计算公式为

$$\gamma = \frac{1}{2 \cdot \sigma^2} \quad (10)$$

为了比较 $c$ 和 $\gamma$ 在不同取值下的载荷重构效果,本文将1.2%的样本划分为训练数据,将剩下的数据用于对模型载荷重构精度的测试,通过设置不同的 $c$ 和 $\gamma$ 取值进行重构精度对比。图7显示了参数 $c$ 和 $\gamma$ 不同取值下的SVR模型重构误差。由图7可知,在不同参数设置下模型精度较为接近,对于工况1,SVR的参数 $c$ 设为100、 $\gamma$ 设为25;对于工况2,SVR的参数 $c$ 设为50、 $\gamma$ 设为35。




图 7 不同  $c$  和  $\gamma$  的下 SVR 模型重构误差实验结果

Fig.7 Experimental results of reconstruction error of SVR model with different  $c$  and  $\gamma$

2.1.4 回归模型选择

为了比较 GPR、NN、SVR 与基于 LSTM 的深度模型的载荷重构效果,本文将 Matern 核的 GPR、7 层 NN、最优回归参数的 SVR 与基于 LSTM 的深度模型按不同的数据集比例(1.2%、2.5%、3.7%、5% 和 6.2%)随机采样得到训练数据,每次将剩下的数据用于对模型载荷重构精度的测试。图 8 显示了使用不同比例的训练数据的 4 种模型重构误差。由图 8 可知,对于本文给定的工况 1、2,随着训练集增大,各模型的重构误差均呈下降趋势,其中 SVR 的重构误差下降趋势逐渐趋于平缓,在不同的数据划分比下 GPR 模型的重构误差均最低,而基于 LSTM 的深度模型的重构误差最高,这是由于全息气动载荷重构在每个工况下翼面每个位置得到的训练数据较少,这对于深度模型容易造成过拟合,且 M6 机翼表面压强系数变化在大多数区域内并没有较强的非线性,因此深度模型并不适用于本文的重构问题,而适用于小样本学习的传统浅层模型获得了较高的载荷重构精度。因此本文工况 1 采用 GPR 模型(Matern 核)、工况 2 采用 GPR 模型(RQ 核)继续用于后续传感器布置优化设计实验。

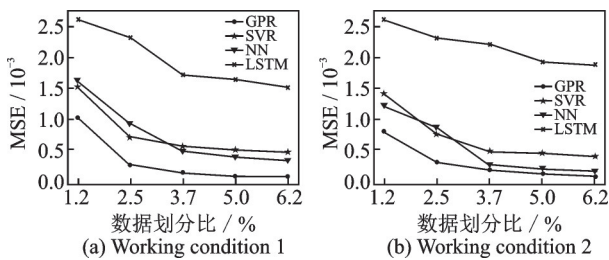


图 8 不同模型重构误差实验结果

Fig.8 Experimental results of reconstruction error of different models

2.2 传感器布点设计实验

指导风洞实验布置传感器的具体流程为:(1)首先给定风洞实验预布置的传感器数量以及工况设置,利用 CFD 计算获得该工况下的全息数据,然后进行布点设计。(2)根据预布置的传感器数量,

设计截面数和每个截面布点数的不同组合方案,通过重构精度比较确定最优的截面数和每个截面布点数。(3)在确定了截面数和每个截面布点数的情况下,对布点分布,即对机翼前缘加密布置和展向截面布置进行研究,最终得到该工况下最为合理的传感器布置方式用于风洞实验。本文分别对指定工况下的 M6 机翼仿真气动数据进行传感器布点实验,工况如表 1 所示。

2.2.1 最优传感器布置

为了研究机翼在给定传感器总数的前提下,放置传感器的截面数量和每个截面放置的传感器数量对机翼重构载荷精度的影响,本文模拟风洞实验的传感器布置设计,对表 1 中 M6 翼型的 2 个工况分别进行均匀采样,即截面之间间距相同且同一截面的采样点之间间距相同,将离散的采样点当作风洞实验放置传感器的节点,控制采样点的总数相同,设置不同的布点截面数和单个截面布点数,比较不同布点方式下机翼气动载荷重构误差。图 9~11 显示了不同采样点总数下不同布点方式的重构误差。

由图 9~11 可知,对于本文的两个工况,当采样点总数为 960、1 200 时,单个截面的采样点数为 60 的采样方式重构精度最高;当采样点总数为 480、720 时,单个截面的采样点数为 40 的情况重构精度最高;当采样点总数为 240 时,工况 1 中单个截面采样点数为 30 的重构精度最高,而工况 2 中单个截面的采样点数为 20 的重构精度最高。

不同的传感器截面数量及每个截面布点数下的最优传感器空间分布如图 12 所示。分图题表示“截面数/单个截面布点数”。可见在给定传感器总数的前提下,单个截面上的布置的传感器并不是越多越好,而是在截面数和单个截面传感器数之间有一个平衡,使传感器在机翼表面总体呈近似均匀分布。

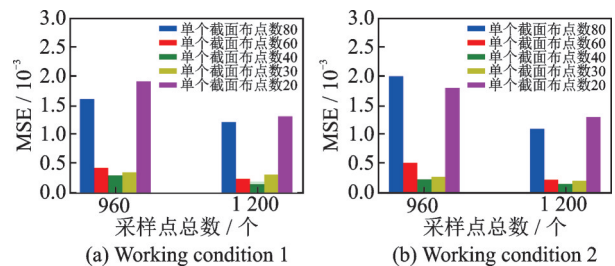


图 9 采样点总数为 960、1 200 时,不同布点方式下机翼气动载荷重构误差

Fig.9 Experimental results of reconstruction error of aerodynamic load of wing under different sensor placements with sample number 960 and 1 200



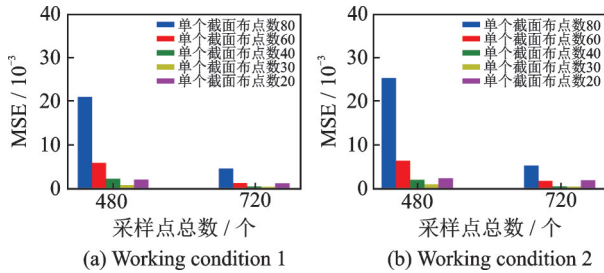


图10 采样点总数为480、720时,不同布点方式下机翼气动载荷重构误差

Fig.10 Experimental results of reconstruction error of aerodynamic load of wing under different sensor placements with sample number 480 and 720

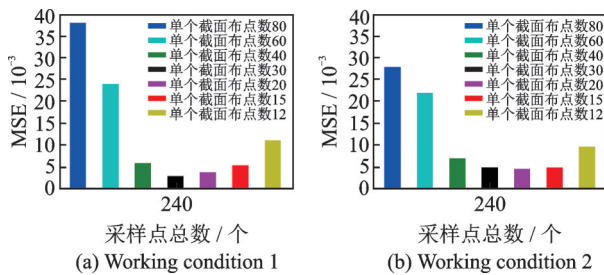


图11 采样点总数为240时,不同布点方式下机翼气动载荷重构误差

Fig.11 Experimental results of reconstruction error of aerodynamic load of wing under different sensor placements with sample number 240

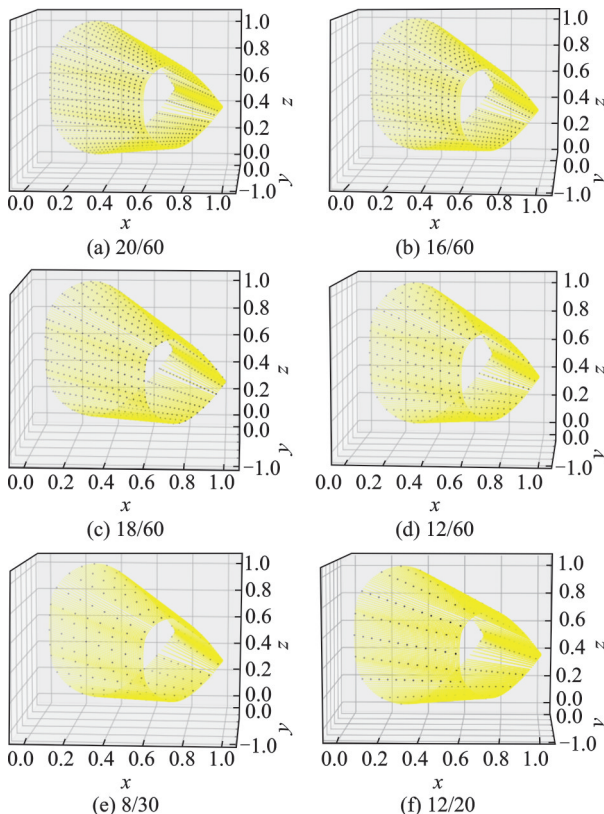


图12 不同传感器布点总数的最优传感器空间分布

Fig.12 Optimal sensor spatial placements under different numbers of sensors

2.2.2 最低传感器布置数

为了避免传感器布置对流场结构的影响,同时保证传感器的布置数量能够准确重构全息气动载荷,需要设计最低传感器布置数。将MSE小于0.01作为评判标准,当MSE小于0.01则可认为全息气动载荷的重构精度较高。本节对单个截面布点数(30、20、15、12)和截面数(16、12、8、6)的组合情况进行进一步比较实验,确定所需最低传感器布置数。图13显示了表1两个工况中不同单个截面布点数和截面数组合的重构误差。由图13可知,对于给定的工况1,MSE低于0.01且最接近0.01的布点方式为截面数8、单个截面布点数15;对于给定的工况2,MSE低于0.01且最接近0.01的布点方式为截面数6、单个截面布点数20,因此工况1和2的最低传感器布置数均为120。然后,通过比较图13中布点总数为120的布点方式的重构精度,得到了图13中的方框显示的最低传感器布置数下的最优布置方式,即工况1中单个截面布点数为20、截面数为6,工况2中单个截面布点数为15、截面数为8,两种最优布点方式的传感器空间分布如图14所示,分图题表示“截面数/单个截面布点数”。

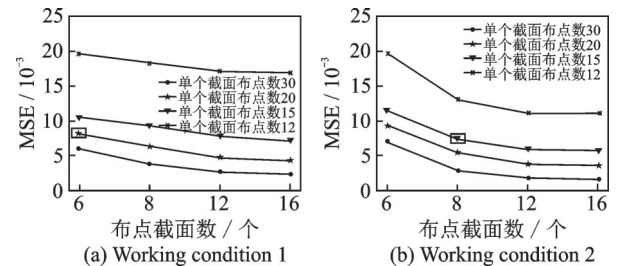


图13 不同截面数和单个截面布点数组下重构误差实验结果

Fig.13 Experimental results of reconstruction error of different combinations of section number and sensor number per section




图14 最低传感器总数下的两种最优传感器布置

Fig.14 Two optimal sensor placements given the lowest sensor number

图15、16显示了上、下翼面工况1下单个截面布点数为20、截面数为6的布点方式和工况2下单

个截面布点数为 15、截面数为 8 的布点方式的重构载荷云图与真实载荷云图的对比结果。由图 15、16 可知,这 2 种布点方式分别在工况 1、2 下获得了与真实云图接近的载荷重构云图,验证了最低传感器总数下的最优传感器布置方式的可靠性。图 17、18 显示了两个测试截面 1、2 压力分布的真实值与预测值对比,训练截面和测试截面的 Z 坐标如表 3 所示。该对比结果显示重构载荷在测试截面上获得了与真实结果较为一致的压力分布,这表明本文工况 1、2 分别对应的最优布点方式用较少传感器可获得较高载荷重构精度。




图 15 最低传感器总数下最优传感器布置方式的重构载荷云图与真实云图对比(上翼面)

Fig.15 Comparison between reconstructed load cloud image and real cloud image of optimal sensor arrangement with the lowest number of sensors (Upper wing)

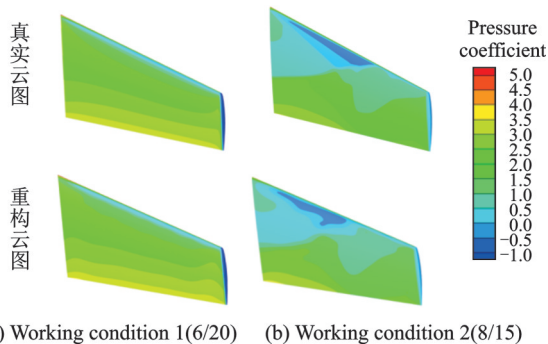


图 16 最低传感器总数下最优传感器布置方式的重构载荷云图与真实云图对比(下翼面)

Fig.16 Comparison between reconstructed load cloud image and real cloud image of optimal sensor arrangement with the lowest number of sensors (Lower wing)

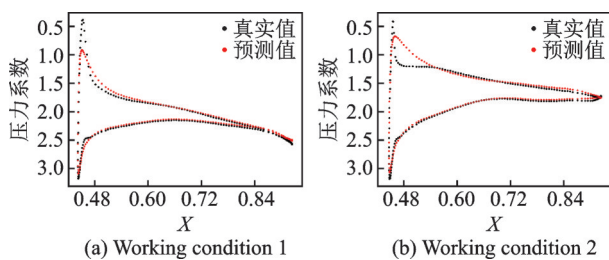


图 17 部分截面压力分布的真实值与预测值(截面 1)

Fig.17 True and predicted values of partial section pressure distribution (Section 1)

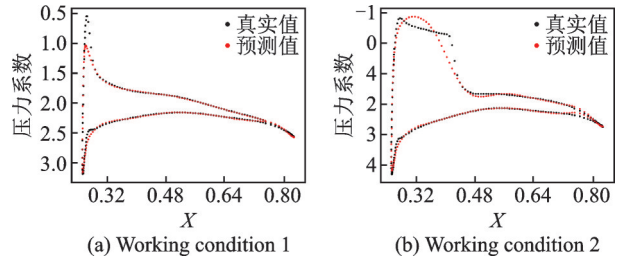


图 18 部分截面压力分布的真实值与预测值(截面 2)

Fig.18 True and predicted values of partial section pressure distribution (Section 2)

表 3 截面 Z 坐标

Table3 Section Z coordinate

训练截面 Z 坐标/m	测试截面 Z 坐标/m
0	
0.24	0.56(截面 1)
0.48	
0.71	
0.95	0.87(截面 2)
1.18	

### 2.2.3 前缘加密布点

因风洞实验中机翼前缘周围的流场规律较为复杂,前缘区域的气动载荷变化相对剧烈,因此本节验证前缘是否需要加密布点。本文进行两组比较实验,每组实验将均匀采样和两种不同的前缘加密方式进行比较,实验设置如表 4 所示。不同布点方式下的载荷重构精度如图 19、20 所示。由图 19、20 可知,在工况 1、2 下,两组实验几乎都是均匀布点方式获得了较高的重构精度。因前缘加密方式二中前缘布点过多,而非前缘区域布点过少从而导致该加密方式下的重构误差较大,因此前缘加密时需保持前缘与非前缘区域布点的合适比例。

表 4 均匀采样和前缘加密布点方式的两组设置

Table 4 Two settings of uniformly and densely placed sensors at leading edge area

单个截面布点数	均匀布点间隔	前缘加密	
		(方式 1)前缘布点数/非前缘区域布点数	(方式 2)前缘布点数/非前缘区域布点数
30	8	10/20	20/10
60	4	20/40	40/20

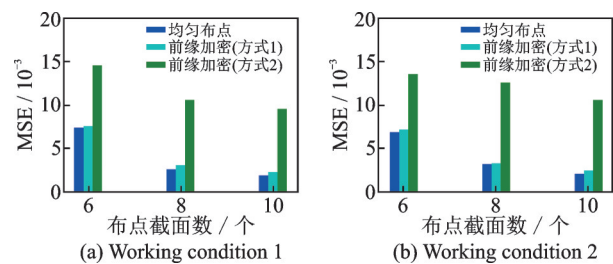


图 19 单个截面布点数 30 的均匀采样与前缘加密的实验对比  
Fig.19 Experimental comparison between uniformly sampling of 30 points per section and densely sampling at leading edge



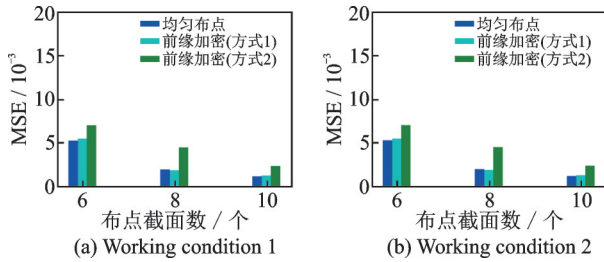


图20 单个截面布点数60的均匀采样与前缘加密的实验对比  
Fig.20 Experimental comparison between uniformly sampling of 60 points per section and densely sampling at leading edge

本文工况1、2的迎角均在 $10^\circ$ 以内,迎角较小可能会使前缘区域的气动载荷变化不够剧烈,因此本节增加1组较大迎角的算例,如表5所示。不同布点方式下的载荷重构精度如图21、22所示。由图21、22可知,除单个截面布点数30、截面数为6时均匀布点获得了略高于前缘加密方式1的重构精度,其余情况下前缘加密方式1均获得了较高的重构精度,这证明了在高迎角下前缘区域传感器加密布置有助于提高载荷重构精度。

**表5 工况参数**  
**Table 5 Working condition parameters**

工况序号	Ma	迎角/( $^\circ$ )	侧滑角/( $^\circ$ )
3	0.65	-30.0	3.0




图21 单个截面布点数30的均匀采样与前缘加密的实验对比(迎角 $-30^\circ$ )

Fig.21 Experimental comparison between uniformly sampling of 30 points per section and densely sampling at leading edge (Angle of attack  $-30^\circ$ )




图22 单个截面布点数60的均匀采样与前缘加密的实验对比(迎角 $-30^\circ$ )

Fig.22 Experimental comparison between uniformly sampling of 60 points per section and densely sampling at leading edge (Angle of attack  $-30^\circ$ )

2.2.4 展向截面布置

为了对展向截面的布置和流场关联进行研究,本节进行1组比较实验,将3种不同的截面布置方式进行比较,截面布置的数量为6,单个截面的布点数为20,实验设置如表6所示。其中1号截面离机身最近,80号截面离翼尖最近。图23显示了不同的截面布置方式在工况1、2下的比较结果。由图23可知,由于工况1的侧滑角较小,截面间的气动载荷变化不够剧烈,因此均匀布置获得了较高的重构精度;而工况2的侧滑角相对较大,工况2在靠近机身部分的气动载荷变化相对剧烈,因此在工况2中机身到翼尖方向由密变稀的布置方式得了较高的重构精度。

**表6 展向截面布置**  
**Table 6 Spanwise section layout**

截面布置方式	所选截面	截面间距
均匀布置	1、17、33、49、65、80	16
机身到翼尖方向由密变稀	1、9、21、37、57、80	间距从8开始,增加的步长为4
翼尖到机身方向由密变稀	1、24、44、60、72、80	间距从24开始,递减的步长为4




图23 不同的截面布置方式比较  
Fig.23 Comparison of different section layout modes

3 结 论

(1) 本文分别比较了不同回归模型对整个机翼气动载荷的重构性能,通过对不同的GPR核函数、NN结构和SVR回归参数进行实验测试,得到载荷重构精度最高的模型及参数设置。本文对比了采用最优核的GPR、7层NN、最优回归参数的SVR与基于LSTM的深度模型的载荷重构精度,实验结果表明GPR模型获得了最高精度的载荷重构。

(2) 采用M6机翼的仿真数据模拟风洞实验数据,研究在传感器总数固定时放置传感器的截面数量和每个截面放置的传感器数量,比较不同布点方式的重构误差,得到不同传感器总数下的最优布点方式。结果表明,在传感器总数一定的前提下,单个截面上的布置的传感器并不是越多越好,而是在截面数和单个截面传感器数之间有一个平衡,使传感器在机翼表面总体呈近似均匀分布。此外,为避免传感器布置对流场结构的影响,同时保证传感器的布置数量能够准确的重构全息流场,本文研究了不

同工况下最低传感器布置数下的最优布置方式,以及前缘区域和传感器和展向截面的布置方式。

(3) 在传统的传感器布置设计中通常需要依靠技术人员的经验确定传感器布置的位置和数量,对人员的专业性过于依赖,本文提出了利用有限实验数据重构机翼全息气动载荷,并提出了通过利用仿真数据评估载荷重构精度对传感器进行优化布置的设计流程,该设计流程可应用于其它物理模型表面的传感器布置设计,从而减少对人工经验的依赖。

#### 参考文献:

- [1] 谭剑锋. 直升机旋翼对尾桨非定常气动载荷的影响[J]. 航空学报, 2015, 36(10): 3228-3240.  
TAN Jianfeng. Influence of helicopter rotor on unsteady aerodynamic load of tail rotor[J]. Acta Aeronautica et Astronautica Sinica, 2015, 36(10): 3228-3240.
- [2] 朱自强, SOBIECZKY H. 一种近无激波机翼修型的工程设计方法[J]. 航空学报, 1987, 8(7): 327-334.  
ZHU Ziqing, SOBIECZKY H. An engineering design method of near shock free wing modification[J]. Acta Aeronautica et Astronautica Sinica, 1987, 8(7): 327-334.
- [3] BUTLER K T, DRAIVES D W, CARTWRIGHT H, et al. Machine learning for molecular and materials science[J]. Nature, 2018, 559(7715): 547-555.
- [4] AKBARI G, MONTAZERIN N. Flow based features and validation metric for machine learning reconstruction of PIV data[EB/OL]. (2021-07-022) [2022-03-22]. Http://arXiv preprint arXiv:2105.13429, 2021.
- [5] LI Y, CHANG J, KONG C, et al. Flow field reconstruction and prediction of the supersonic cascade channel based on a symmetry neural network under complex and variable conditions[J]. AIP Advances, 2020, 10(6): 065116.
- [6] YU J, HESTHAVEN J S. Flowfield reconstruction method using artificial neural network[J]. AIAA Journal, 2019, 57(2): 482-498.
- [7] QU X Y, LIU Z J, AN W, et al. Predicting pressure coefficients of wing surface based on the transfer of spatial dependency[J]. AIP Advances, 2022, 12(5): 1-15.
- [8] 华林, 康建雄, 王富生, 等. 基于混合算法的机翼多功能盒段传感器优化布置[J]. 科学技术与工程, 2019, 19(6): 257-262.  
HUA Lin, KANG Jianxiong, WANG Fusheng, et al. Optimal placement of sensors in multi-functional box section of wing based on hybrid algorithm[J]. Science Technology and Engineering, 2019, 19(6): 257-262.
- [9] SAMARA P A, FOUSKITAKIS G N, SAKEL-LARIOU J S, et al. A statistical method for the detection of sensor abrupt faults in aircraft control systems[J]. IEEE Transactions on Control Systems Technology, 2008, 16(4): 789-798.
- [10] 易贤, 李维浩, 王应宇, 等. 飞机结冰传感器安装位置确定方法[J]. 实验流体力学, 2018, 32(2): 48-54.  
YI Xian, LI Weihao, WANG Yingyu, et al. Method for determining the installation position of aircraft icing sensor[J]. Journal of Experiments in Fluid Mechaics, 2018, 32(2): 48-54.
- [11] 杨庆东. 神经网络补偿机床热变形误差的机器学习技术[J]. 机械工程学报, 2000, 36(1): 92-95  
YANG Qingdong. Machine learning technology for neural network compensation of thermal deformation error of machine tool[J]. Chinese Journal of Mechanical Engineering, 2000, 36(1): 92-95.
- [12] SEMAAN R. Optimal sensor placement using machine learning[J]. Computers & Fluids, 2017, 159: 167-176.
- [13] KAPTEYN M G, WILLCOX K E. From physics-based models to predictive digital twins via interpretable machine learning[EB/OL]. (2021-03-10) [2022-03-22]. Http://arXiv preprint arXiv:2004.11356, 2020.
- [14] 朱自强, 陈迎春, 吴宗成, 等. 高升力系统外形的数值模拟计算[J]. 航空学报, 2005, 26(3): 257-262.  
ZHU Ziqing, CHEN Yingchun, WU Zongcheng, et al. Numerical simulation of high lift system shape[J]. Acta Aeronautica et Astronautica Sinica, 2005, 26(3): 257-262.
- [15] FEINDT M, KERZEL U. The NeuroBayes neural network package[J]. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 2006, 559(1): 190-194.
- [16] LE H S, OPARIN I, ALLAUZEN A, et al. Structured output layer neural network language model[C]//Proceedings of 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). [S.l.]: IEEE, 2011: 5524-5527.
- [17] 胡伟杰, 黄增辉, 刘学军. 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): 524093.  
HU Weijie, HUANG Zenghui, LIU Xuejun. Aerodynamic performance prediction of Missile Based on Gaussian process of automatic kernel construction[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(4): 524093.
- [18] WILSON A, ADAMS R. Gaussian process kernels for pattern discovery and extrapolation[C]//Proceedings of International Conference on Machine Learning. [S.l.]: PMLR, 2013: 1067-1075.
- [19] 李元诚, 方廷健, 于尔铿. 短期负荷预测的支持向量机方法研究[J]. 中国电机工程学报, 2003, 23(6): 55-59.  
LI Yuancheng, FANG Tingjian, YU Erkeng. Research on support vector machine method for short-term load forecasting[J]. Proceedings of the CSEE, 2003, 23(6): 55-59.
- [20] DREVES A, FACCHINEI F, KANZOW C, et al. On the solution of the KKT conditions of generalized Nash equilibrium problems[J]. SIAM Journal on Optimization, 2011, 21(3): 1082-1108.
- [21] LYU S. Mercer kernels for object recognition with local features[C]//Proceedings of 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE, 2005, 2: 223-229.
- [22] THEOBALD C M. Generalizations of mean square error applied to ridge regression[J]. Journal of the Royal Statistical Society: Series B (Methodological), 1974, 36(1): 103-10.