

## 基于分阶段自编码器与注意力机制的舰载机着舰航迹实时预测模型

李哲, 刘奕阳, 王可, 杨杰, 李亚飞, 徐明亮

引用本文

李哲, 刘奕阳, 王可, 杨杰, 李亚飞, 徐明亮. 基于分阶段自编码器与注意力机制的舰载机着舰航迹实时预测模型[J]. 计算机科学, 2024, 51(9): 273-282.

LI Zhe, LIU Yiyang, WANG Ke, YANG Jie, LI Yafei, XU Mingliang. Real-time Prediction Model of Carrier Aircraft Landing Trajectory Based on Stagewise Autoencoders and Attention Mechanism [J]. Computer Science, 2024, 51(9): 273-282.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

### 面向电台通信的CLU-Net语音增强网络

CLU-Net Speech Enhancement Network for Radio Communication

计算机科学, 2024, 51(9): 338-345. <https://doi.org/10.11896/jsjcx.230700200>

### CCSD:面向话题的讽刺识别方法

CCSD:Topic-oriented Sarcasm Detection

计算机科学, 2024, 51(9): 310-318. <https://doi.org/10.11896/jsjcx.230600217>

### 基于多尺度跨模态特征融合的图文情感分类模型

Image-Text Sentiment Classification Model Based on Multi-scale Cross-modal Feature Fusion

计算机科学, 2024, 51(9): 258-264. <https://doi.org/10.11896/jsjcx.230700163>

### 基于YOLOv5s和双稳随机共振的夜间车辆检测算法

Night Vehicle Detection Algorithm Based on YOLOv5s and Bistable Stochastic Resonance

计算机科学, 2024, 51(9): 173-181. <https://doi.org/10.11896/jsjcx.230600056>

### 重参数化增强的双模态实时目标检测模型

Re-parameterization Enhanced Dual-modal Realtime Object Detection Model

计算机科学, 2024, 51(9): 162-172. <https://doi.org/10.11896/jsjcx.230700106>

# 基于分阶段自编码器与注意力机制的舰载机着舰航迹实时预测模型

李哲<sup>1</sup> 刘奕阳<sup>1</sup> 王可<sup>1,2,3</sup> 杨杰<sup>1</sup> 李亚飞<sup>1,2,3</sup> 徐明亮<sup>1,2,3</sup>

1 郑州大学计算机与人工智能学院 郑州 450001

2 国家超级计算郑州中心 郑州 450001

3 智能集群系统教育部工程研究中心 郑州 450001

(zheli@gs.zzu.edu.cn)

**摘要** 航空母舰舰载机着舰过程中应沿相对固定的航迹下滑,以保证触舰点位于舰艉拦阻系统所在的区域,因此舰载机航迹是着舰信号官进行指挥决策的重要依据之一。舰载机航迹实时预测有助于着舰信号官判断着舰作业发展态势,及时形成正确的航迹纠偏引导指令。为此,提出一种基于分阶段自编码器与注意力机制的着舰航迹实时预测模型。第一阶段采用降噪自编码器对历史航迹数据进行特征提取;第二阶段基于长短期记忆网络构建时序自编码器,同时引入注意力机制对不同时刻的编码器输出分配不同的权重,自适应学习其对最终预测结果的影响强度。通过仿真实验将所提模型与6种基线模型进行对比,结果表明,所提模型的综合性能优于基线模型,能够满足着舰航迹实时准确预测的应用需求。

**关键词:** 舰载机着舰;航迹预测;长短期记忆网络;自编码器;注意力机制

中图分类号 TP391

## Real-time Prediction Model of Carrier Aircraft Landing Trajectory Based on Stagewise Autoencoders and Attention Mechanism

LI Zhe<sup>1</sup>, LIU Yiyang<sup>1</sup>, WANG Ke<sup>1,2,3</sup>, YANG Jie<sup>1</sup>, LI Yafei<sup>1,2,3</sup> and XU Mingliang<sup>1,2,3</sup>

1 School of Computer and Artificial Intelligence, Zhengzhou University, Zhengzhou 450001, China

2 National Supercomputing Center in Zhengzhou, Zhengzhou 450001, China

3 Intelligent Swarm System Engineering Research Center of the Ministry of Education, Zhengzhou 450001, China

**Abstract** During the landing process of an aircraft carrier, the carrier aircraft should fly along a relatively fixed trajectory to ensure that the touch point is located in the area where the stern arresting system is located. Therefore, the carrier aircraft trajectory is one of the important basis for the landing signal officer (LSO) to make decisions. The real-time prediction of carrier aircraft trajectory is helpful for the LSO to judge the situation of aircraft carrier landing operation and then form correct guidance instructions in time. Therefore, this paper proposes a real-time prediction of carrier aircraft landing trajectory based on stagewise autoencoders and attention mechanism. In the first stage, a denoising autoencoder is used to extract features from historical trajectory data; in the second stage, a timeseries autoencoder is constructed based on a long short-term memory (LSTM), and at the same time, the attention mechanism is introduced to assign different weights to the encoder output at different times, and adaptively learns its influence on the final prediction result. The proposed model is compared with six baseline models through simulation experiments, and the results show that the comprehensive performance of the proposed model is better than that of the baseline model, which can meet the application requirements of real-time and accurate prediction of the landing trajectory.

**Keywords** Carrier aircraft landing, Trajectory prediction, Long short-term memory, Autoencoder, Attention mechanism

到稿日期:2023-07-20 返修日期:2023-11-23

基金项目:国家自然科学基金重点项目(62036010);河南省自然科学基金(232300421235);国防科技工业海洋防务技术创新中心创新基金(JJ-2022-709-01);中国博士后科学基金(2020M682348);国家自然科学基金面上项目(61972362,62372416)

This work was supported by the Key Program of the National Natural Science Foundation of China(62036010), Natural Science Foundation of Henan Province, China(232300421235), Innovation Foundation of Ocean Defense Technology Innovation Center of National Defence of Science, Technology and Industry(JJ-2022-709-01), China Postdoctoral Science Foundation(2020M682348) and General Program of the National Natural Science Foundation of China(61972362,62372416).

通信作者:王可(iekwang@zzu.edu.cn)

## 1 引言

航空母舰(航母)是以舰载机为主要武器的海上综合作战平台,在现代海战中具有重要的战术和战略价值。舰载机的出动回收能力决定了航母的作战效能<sup>[1]</sup>,其中着舰是舰载机出动回收过程中最危险且事故率最高的阶段<sup>[2]</sup>。据美国统计数据,尽管舰载机着舰阶段仅占其飞行任务总时间的4%,但发生事故的数量却占舰载机事故总量的44.4%<sup>[3]</sup>。为了提高舰载机着舰的安全性和成功率,航母空中交通控制中心(Carrier Air Traffic Control Center, CATCC)与着舰信号官(Landing Signal Officer, LSO)会在特定阶段介入,指挥引导舰载机飞行员安全着舰。当舰载机距离航母50n mile时,CATCC

通过雷达信号对舰载机展开跟踪并告知其进近着舰、拦阻方式及初始着舰位置等信息。如图1所示,当舰载机捕获下滑航道后,位于甲板着舰区后部左舷的LSO综合分析舰载机的即时航迹、甲板运动状态、飞行姿态等关键信息,并通过菲涅耳透镜光学助降系统<sup>[5]</sup>、无线电指挥引导飞行员完成“对中”“保角”及“逃逸复飞”等一系列复杂判断和精准操作。然而,由于着舰作业的复杂性及非预知因素的干扰,CATCC和LSO的人工引导指挥存在一致性差、可靠性差、稳定性差的弊端,极端情况下甚至可能超出指挥员临场感知与决策能力的极限,导致无法及时向飞行员发出准确的航迹纠偏指令<sup>[6]</sup>。因此,对舰载机着舰航迹进行自动实时预测,能够降低LSO的临场认知负荷,辅助LSO进行临场决策,提高着舰的成功率和安全性。

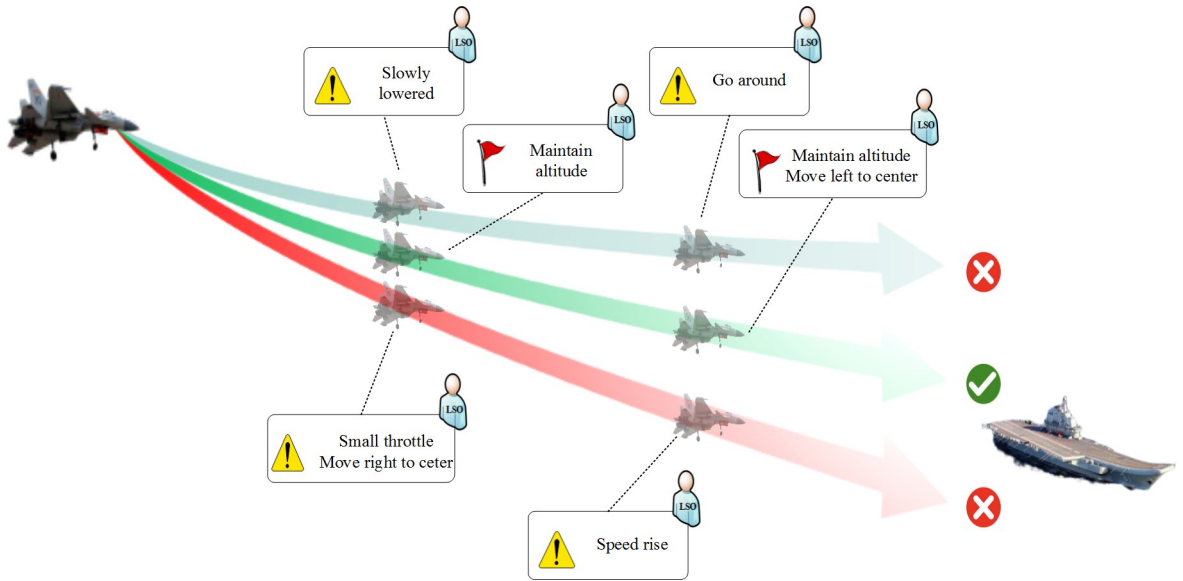


图1 基于舰载机航迹的着舰引导作业实例

Fig. 1 Example of landing guidance operation based on carrier aircraft trajectory prediction

本文提出了一种基于分阶段自编码器与注意力机制的着舰航迹实时预测模型,第一阶段采用降噪自编码器抑制航迹数据中的噪声,实现鲁棒的特征提取;第二阶段以长短期记忆网络为构建单元,实现编码器-解码器架构的时序自编码器,同时在编码器-解码器之间引入时间注意力层,为不同时刻的输出分配不同的权重,以调控不同时刻对未来航迹预测的影响强度,捕获航迹数据在时间序列上的相关性,从而提高预测精度。

## 2 相关工作

### 2.1 长短期记忆网络

长短期记忆网络(LSTM)是循环神经网络(RNN)的一种变体<sup>[7]</sup>,其核心在于引入“门”结构以及细胞状态 $c_t$ 。两者不同的是,RNN仅有一个单一的神经网络层(tanh层),而LSTM改进为4个神经网络层,提高了信息处理能力,并在RNN的基础上增加了遗忘门、更新门和输出门,用于控制特征的流通和损失。

LSTM的网络结构如图2所示,它包含多个LSTM单元,且每个单元结构一致。LSTM的基本思想为当前单元接收上一时刻的单元状态 $c_{t-1}$ ,并与信号输入 $x_t$ 共同产生单元

状态 $c_t$ 。其中,遗忘门 $f_t$ 主要用于决定是否遗忘 $x_{t-1}$ 和 $c_{t-1}$ 中的信息;更新门 $i_t$ 与遗忘门相反,主要用于决定是否保留 $x_t$ 和 $h_{t-1}$ 中的信息,并通过tanh层创建一个新的状态候选向量 $\tilde{c}_t$ 对 $c_t$ 进行更新;输出门 $o_t$ 主要用于计算 $c_t$ 中的哪些信息需要输出。为了避免梯度爆炸和梯度消失的问题,LSTM借助sigmoid函数将 $f_t$ 限制在 $[0,1]$ 范围内。




图2 LSTM的网络结构

Fig. 2 Network structure of LSTM

### 2.2 注意力机制

注意力机制源于人类视觉机制的选择注意力,即在某一时刻人类把注意力放在某些方面,以便从复杂的信息中提取关键信息<sup>[8]</sup>。后来有学者尝试将注意力机制用于自然语言处理领域,并取得了突破性进展,目前被广泛用于机器翻译

领域<sup>[9]</sup>。在神经网络中,模型往往会被输入大量数据并对其进行处理,但在某个特定的时刻,其学习到的特征对于任务的贡献是不同的,因此需采用注意力机制,通过分配不同的权重使模型自适应地聚焦于重要的信息,抑制无关的背景干扰信息。值得注意的是,注意力机制是一种通用的解决方案,它不依赖于任何模型,常用于缓解输入信息特征过多的问题。同时,注意力机制具有即插即用的特点,因此无需对网络进行复杂的改动,也不会使网络变得更加复杂<sup>[10]</sup>。大多数情况下,注意力机制使用编码器-解码器框架作为神经网络的研究模式。

### 2.3 航迹预测

舰载机的历史航迹数据中蕴含了舰载机速度、下滑降落角度及下沉速率等关键信息,具有规律性和顺序性,为基于机器学习方法和技术构建航迹预测模型提供了可能<sup>[11]</sup>。例如, Tastambekov 等<sup>[12]</sup>基于局部线性函数回归模型提出一种仅使用历史雷达轨迹的航迹预测模型。但与回归模型相比,神经网络具有逼近任意连续映射的能力,因此目前国内外有很多学者采用神经网络探究航迹预测的问题。Shi 等<sup>[13]</sup>基于 LSTM 提出一种不使用飞机物理模型的飞行航迹预测方法,利用航迹序列中相邻状态的动态依赖性准确预测 3-D 和 4-D 飞行航迹。Wu 等<sup>[14]</sup>基于 BP(Back Propagation)神经网络提出一种适用于 4-D 航迹的预测模型。由于 BP 神经网络的训练方法易使局部收敛不足,因此 Baklacioglu 等<sup>[15]</sup>提出一种基于遗传算法预测运输机下降阶段轨迹的模型,该方法原理简单且易于实现。受到航迹预测问题的不确定性、时序依赖性等特点的影响,Zhang 等<sup>[16]</sup>以一对一战斗机空战为背景,基于对历史数据具有动态记忆功能的 Elman 神经网络提出了一种 3-D 空战航迹预测模型。目前针对舰载机着舰航迹预测的工作较少,Zhang 等<sup>[17]</sup>提出一种基于径向基函数(Radial Basis Function, RBF)变结构神经网络的舰载机着舰航迹预测模型,实现着舰航迹的在线预测。同年,Zhang 等<sup>[18]</sup>在此基础上将舰载机着舰过程分为 X, IM, IC, AR, TC 5 个阶段,分别建立基于 RBF 的着舰航迹趋势预测网络,并在两个阶段的交界处引入最优线性集成以实现整体着舰航迹预测。然而 RBF 网络在处理时序数据预测问题时存在一定的局限性,它通常只能在给定一组输入的前提下进行计算并输出。倘若使用神经网络预测序列数据,则每一个输入将会与数以千计的时间节点相关联,这样会极大地增加训练成本。而 RNN 或 LSTM 可以有效地解决舰载机着舰航迹预测对时序高要求的问题。此外,相比 RNN, LSTM 在处理时序数据时具有更强的长期记忆能力<sup>[7]</sup>。另外,近年来逐渐兴起的注意力机制可直接计算不同序列点之间的依赖关系,有助于提取时序数据的动态变化特征<sup>[19]</sup>。

## 3 问题定义与动力学模型

### 3.1 航迹预测的问题定义

使用三维空间坐标  $x, y, z$  描述舰载机着舰航迹点数据,以航母重心所在位置为原点  $O$ ,以航母舰首方向为  $x$  轴正方向,以航母右舷轴方向为  $y$  轴正方向,以垂直海平面向上为  $z$  轴正方向。舰载机在  $i$  时间步的航迹点  $p_i$  为  $p_i(x, y, z)$ ,

则  $n$  个连续时间步的航迹点坐标可表示为  $p_i(x, y, z), \dots, p_{n+1}(x, y, z)$ 。本文通过舰载机  $i+1$  时间步的前  $n$  个时间步的航迹点坐标,预测第  $i+1$  时间步的航迹点坐标,即:

$$p_{i+1} = f(p_{i-n+1}, \dots, p_{i-1}, p_i) \quad (1)$$

### 3.2 舰载机着舰动力学模型

舰载机着舰动力学模型主要描述在预期的环境条件下,作用于舰载机的力和舰载机当前运动状态(如重力加速度、阻力、位置、倾斜角等)之间的关系。总能量模型(Total Energy Model, TEM)<sup>[20]</sup>及点质量模型(Point-Mass Model, PMM)<sup>[21]</sup>是应用较为广泛的两种模型。TEM 减少了传统降落程序中所需要的水平飞行阶段,从而提高了燃油效率并降低噪音,但是它缺少从着舰结束时的过剩能量状态中恢复需要的安全缓冲区<sup>[22]</sup>。因此,本文选取 PMM 作为舰载机着舰的动力学模型。

本文主要研究着舰航迹的短期预测,时间跨度为几分钟甚至更短,因此不需要考虑舰载机长期意图(如目标速度)和气象等状况<sup>[23]</sup>。现作出如下假设:1)舰载机在运动时,可以不考虑其大小与形状,将其视为质点;2)不考虑地球的自转角速度和曲率,以地面坐标系作为惯性参考系;3)忽略气流、温度等大气特性;4)忽略海拔与经纬度对重力加速度的影响。现对舰载机着舰的运动状态进行描述,建立质点模型:

$$\begin{cases} \dot{x} = v \cos \gamma \cos \psi \\ \dot{y} = v \cos \gamma \sin \psi \\ \dot{z} = v \sin \gamma \\ \dot{v} = g(n_x - \sin \gamma) \\ \dot{\gamma} = \frac{g}{v}(n_z \cos \mu - \cos \gamma) \\ \dot{\psi} = \frac{g}{v \cos \gamma} n_z \sin \mu \end{cases} \quad (2)$$

其中,  $w = [x, y, z, v, \gamma, \psi]^T$  是状态变量,  $u = [n_x, n_z, \mu]^T$  是控制变量。 $x, y$  和  $z$  分别表示舰载机的水平位置坐标和高度坐标,  $\gamma$  为爬升角,  $\psi$  为航向角,  $v$  为速度,  $\mu$  为滚转角,  $n_x$  为水平过载,  $n_z$  为纵向过载, 这些参数描述舰载机当前的运动状态。 $g$  是重力加速度, 为作用于舰载机上的力。

## 4 航迹实时预测模型

### 4.1 模型总体架构

本文提出了一种基于分阶段自编码器与注意力机制的舰载机着舰航迹的预测模型,其基本结构包括两个模块,分别为降噪自编码器(Denoising Autoencoder, DAE)模块和融合了注意力机制的时序编码器-解码器模块,包含时序编码器、时间注意力层和时序解码器 3 个部分,如图 3 所示。

该模型首先通过降噪自编码器对数据进行去噪和特征提取;然后利用时序编码器将历史航迹点的特征信息编码为高维隐藏状态张量;在此基础上,采用时间注意力层对时序编码器的输出进行权重分配,得到加权上下文向量  $c_i$ ;最后,时序解码器将加权上下文向量作为预测层的输入,完成对着舰航迹的预测。

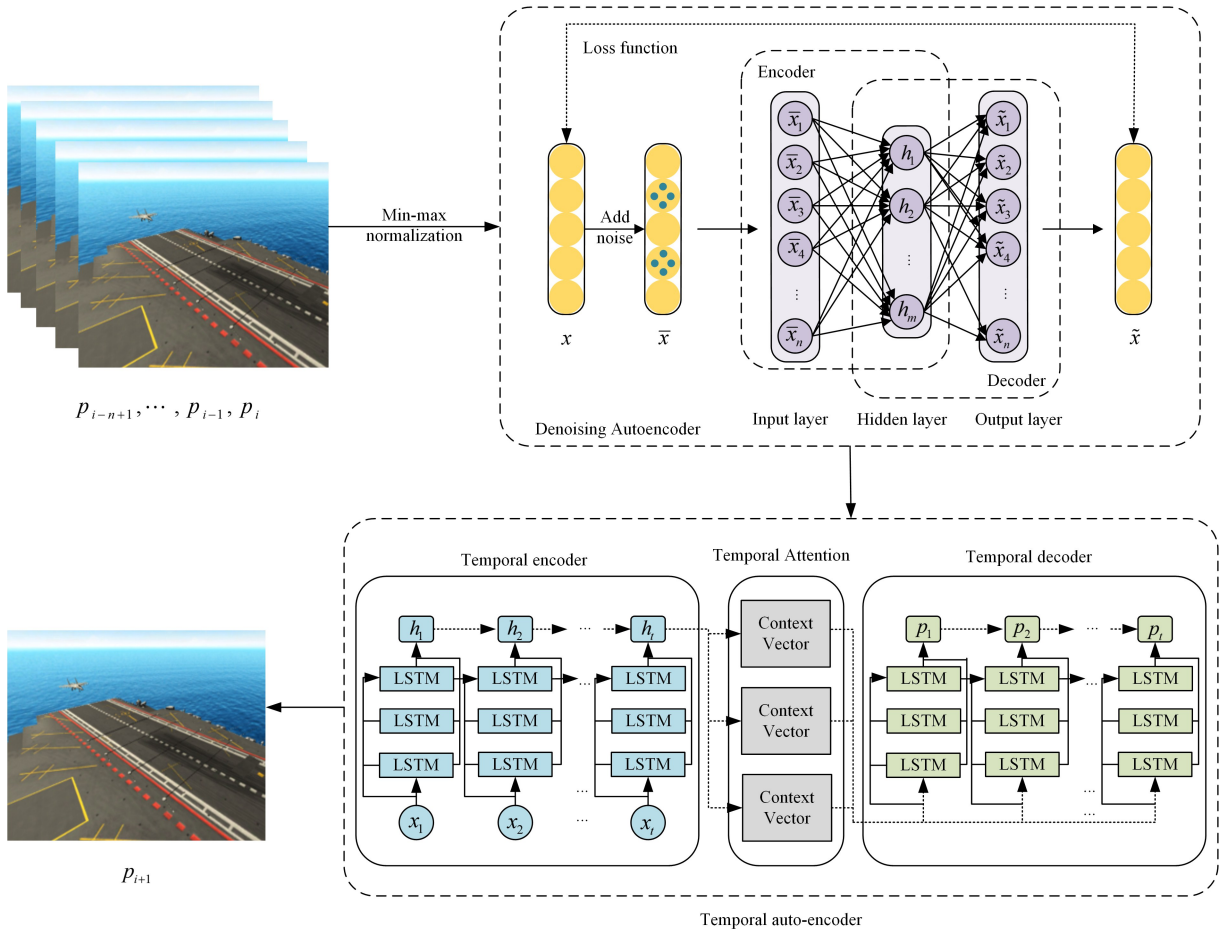


图3 模型总体架构

Fig. 3 Overall architecture of the proposed model

#### 4.2 降噪自编码器

航迹数据中通常会存在噪声和异常点,它们一般来源于传感器误差、环境因素干扰或定位计算误差等。这些噪声和异常点会影响航迹预测的准确性和可靠性。因此,需要通过降噪自编码器对航迹点数据进行无监督特征学习,抑制噪声的干扰。

降噪自编码器主要由输入层、隐藏层和输出层3层网络组成,其主要目的在于对输入的数据进行降噪处理,从而提高模型的鲁棒性和泛化能力<sup>[24]</sup>。基本的自编码器是通过训练编码器和解码器学习输入数据的一种压缩表示,再利用解码器将该压缩表示解码成原始数据。而降噪自编码器是把含有噪声的原始数据通过多个非线性变换映射到一个低维特征空间中,在提取数据特征的同时去除噪声。相应地,解码器的功能是把编码器提取的特征经过多个非线性变换后还原为不含噪声的数据,计算过程如下:

1) 噪声添加:

$$\bar{x} = x + e \quad (3)$$

其中, \$\bar{x}\$ 为加噪处理后的输入数据; \$x\$ 表示原始数据, \$e\$ 为服从高斯分布的随机噪声。

2) 编码器前向传播过程:

$$h = f(x) = s(w_1 \bar{x} + b_1) \quad (4)$$

其中, \$h\$ 是编码器的输出; \$s\$ 为 sigmoid 函数; \$w\_1\$ 为编码器权重; \$b\_1\$ 为编码器偏置向量。

3) 解码器反向传播过程:

$$\tilde{x} = g(h) = s(w_2 h + b_2) \quad (5)$$

其中, \$\tilde{x}\$ 是解码器的输出; \$w\_2\$ 为解码器权重; \$b\_2\$ 为解码器偏置向量。

4) 降噪自编码器优化过程 (\$\arg \min Loss(x, \tilde{x})\$):

降噪自编码器通过优化参数集合 \$\{w\_1, w\_2, b\_1, b\_2\}\$, 尽可能输出无噪声的原始数据, 其损失函数如下:

$$\begin{aligned} Loss(x, \tilde{x}) &= \frac{1}{2} \sum_{m=1}^M \|x^{(m)} - \tilde{x}^{(m)}\|^2 \\ &= \frac{1}{2} \sum_{m=1}^M \|x^{(m)} - g(f(\bar{x}^{(m)}))\|^2 \end{aligned} \quad (6)$$

其中, \$x^{(m)}\$ 表示第 \$m\$ 个无噪声的原始输入数据; \$\bar{x}^{(m)}\$ 表示第 \$m\$ 个有噪声的输入数据; \$M\$ 为样本数量。

对式(6)使用正则化技术和稀疏限制技术以防止过拟合:

$$Loss'(x, \tilde{x}) = Loss(x, \tilde{x}) + \frac{\lambda}{2} \|W\|^2 + \beta \sum_{j=1}^k KL(\rho \| \hat{\rho}_j) \quad (7)$$

其中, 散度 \$KL\$ 的定义为:

$$KL(\rho \| \hat{\rho}_j) = \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (8)$$

其中, \$\lambda\$ 和 \$\beta\$ 分别代表正则化系数和权重系数; \$\rho\$ 为稀疏性参数。在隐藏层中, \$k\$ 为神经元节点数, \$\hat{\rho}\_j\$ 为第 \$j\$ 个神经元的平均激活值。

### 4.3 基于 LSTM 的时序自编码器

循环神经网络编码器-解码器(RNN Encoder-Decoder)模型常用于解决序列到序列(Sequence-to-Sequence, 简称 Seq2Seq)的转换问题,而在着舰航迹的预测模型中,其输入和输出均为序列,因此可以看作是一个 Seq2Seq 问题。同时,着舰航迹点时间序列数据记录了舰载机在不同时间步的位置和状态信息,这些信息都与后续的预测密切相关,需要充分考虑数据的长期时序相关性。然而 RNN 并不能很好地解决长时依赖的问题,而 LSTM 的“门”结构在训练过程中会选择性地遗忘不重要的信息,同时保留关键信息。为此,本文设计了一种基于 LSTM 的时序自编码器,用于学习航迹数据的时序相关性。同时,舰载机着舰是一个复杂、连续的动态过程,当前飞行状态是对所有历史状态的综合反映,因此需要引入时间注意力层对编码器的输出分配不同的权重,提高模型的预测性能。

#### 4.3.1 编码器

对于舰载机在  $t$  时刻的着舰航迹点序列数据,通过降噪自编码器去除异常航迹点并进行特征提取后,把生成的特征向量  $\mathbf{z}(t)$  作为时序编码器的输入,并转化为该编码器的隐藏状态  $h_{\text{enc}}(t)$ :

$$h_{\text{enc}}(t) = f(h_{\text{enc}}(t-1), x(t); \mathbf{W}_{\text{enc}}), \mathbf{W}_{\text{enc}} \in \mathbb{R}^{(D_1+D_2) \times D_{\text{enc}}} \quad (9)$$

其中,  $\mathbf{W}_{\text{enc}}$  是 LSTM 的权重矩阵;  $D_{\text{enc}}$  为 LSTM 的网络维度。

#### 4.3.2 时间注意力层

舰载机航迹点的时间上下文序列  $h_t$  表示如下:

$$h_t = \{h_{\text{enc}}(1), h_{\text{enc}}(2), \dots, h_{\text{enc}}(t)\} \quad (10)$$

其中,  $h_{\text{enc}}(t)$  表示舰载机在  $t$  时刻的隐藏状态。

如图 4 所示,  $h_t$  作为时间注意力层的输入,用于计算注意力权重向量  $\alpha_t$ :

$$\alpha_t = \text{softmax}(\tanh(\mathbf{W}_t (h_t)^T)) \quad (11)$$

其中,  $\tanh$  为激活函数;  $\mathbf{W}_t$  是权重矩阵;  $T$  为矩阵的转置。由于使用了  $\text{softmax}$  函数,  $\alpha_t$  的权重之和为 1。




图 4 时间注意力层  
Fig. 4 Time attention layer

最后,着舰航迹预测模型结合  $\alpha_t$  和  $h_t$  输出一个加权时间向量  $c_t$ :

$$c_t = \sum_{i=1}^k \alpha_i h_i \quad (12)$$

其中,  $k$  为特征向量的数量。

#### 4.3.3 解码器

首先,解码器连接加权时间向量  $c_t$  与随机噪声  $r$ ,其表达式如下:

$$h_{\text{dec}}(t) = \text{DEC\_LSTM}(h_{\text{dec}}(t-1), c_t \oplus r; \mathbf{W}_{\text{dec}}), \mathbf{W}_{\text{dec}} \in$$

$$\mathbb{R}^{(D_{\text{enc}}+D_r) \times D_{\text{dec}}} \quad (13)$$

其中,  $\mathbf{W}_{\text{dec}}$  是学习参数;  $D_{\text{dec}}$  是 LSTM 网络的维度。

使用解码器的隐藏  $h_{\text{dec}}(t)$  生成预测航迹点坐标,其表达式如下:

$$p(t) = \psi(h_{\text{dec}}(t); \mathbf{W}_p), \mathbf{W}_p \in \mathbb{R}^{D_{\text{dec}} \times 2} \quad (14)$$

其中,  $\psi(\cdot)$  是全连接网络;  $\mathbf{W}_p$  是 LSTM 的权重矩阵。

#### 4.3.4 损失函数

本文使用预测坐标  $p_{\text{pred}}(t)$  和实际坐标  $p_{\text{true}}(t)$  之间的欧氏距离作为损失函数,计算方式为:

$$L_{\text{train}} = \frac{1}{N \times T} \sum_{i=1}^N \sum_{t=t_{\text{obs}}+1}^{t_{\text{obs}}+t_{\text{pred}}} \|p_{\text{pred}}(t) - p_{\text{true}}(t)\|_2^2 \quad (15)$$

其中,  $N$  是着舰航迹训练集的大小;  $T = t_{\text{pred}}$  是未来航迹的长度;  $t_{\text{obs}}$  是未来航迹开始时刻。

## 5 实验验证

### 5.1 数据集

由于场景的特殊性和敏感性,大规模的舰载机着舰作业数据难以从公开渠道获取,因此目前针对该领域的探索通常采用仿真数据集的方式<sup>[3]</sup>。同时,舰载机着舰航迹预测需要考虑其位置、速度、滚转角等多种数据的综合作用,为此本文基于少量真实数据样本,根据 3.2 节中的动力学模型生成了 346 条舰载机航迹,并设定每条航迹对应的飞行时间为 10 s,采样频率为 0.1 s,用于构建舰载机着舰作业的仿真数据集<sup>[25]</sup>,进而评估航迹预测模型的性能。

实验采用滑动窗口生成航迹样本数据集,如图 5 所示。具体地,设置历史窗口长度  $n$  和预测窗口长度  $m$ ,  $m$  和  $n$  可以根据实际需求和计算资源进行调整。例如,  $n=2, m=0.5$  表示从每条着舰航迹的起始位置开始,连续选取时长为 2s 的航迹序列作为一个训练样本,再选取随后 0.5s 内的航迹序列作为对应的标签,样本实例如图 6 所示。




图 5 通过滑动窗口生成数据样本  
Fig. 5 Generate data samples through sliding windows




图 6 训练样本实例

Fig. 6 Training sample instance

### 5.2 实验参数设置

本实验采用随机梯度下降算法的训练方式,降噪自编码

器的层数设置为 2 层,其中,第一层共包含 32 个神经元,第二层共包含 16 个神经元;LSTM-自编码器的层数设置为 2,每层分别包含 128 个神经元;数据集批处理大小为 128。具体数值如表 1 所列。

表 1 实验参数设置

Table 1 Experimental parameter settings

Parameter	numerical value	
DAE	Number of layers	2
	Neuron/layer	32;16
LSTM	Number of layers	2
	Auto-encoder Neuron/layer	128
Batch size		128
Train set;Test set		7:3

### 5.3 数据预处理

在生成数据集后,需要进一步对样本的各维度进行归一化处理。实验中采用 min-max 归一化对原始数据进行线性变换,将每个样本的所有维度都映射到[0,1]范围,转化公式如下:

$$y_i = \frac{x_i - \min x_i}{\max x_i - \min x_i}, i=1, 2, \dots, N \quad (16)$$

其中,  $N$  为样本数量;  $\min x_i$  和  $\max x_i$  分别为样本数据的最小值和最大值;  $y_i$  为归一化后的数据。

### 5.4 评价指标

本文选取时间序列预测中两个常用的评价指标:均方根误差(Root Mean Squared Error, RMSE)和平均绝对误差(Mean Absolute Error, MAE)<sup>[26]</sup>评估舰载机航迹预测模型的性能。RMSE 和 MAE 定义分别如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (q_i' - q_i)^2} \quad (17)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |q_i' - q_i| \quad (18)$$

其中,  $N$  为预测航迹点的样本数量;  $q_i'$  为  $i$  时刻模型在  $x$  轴

(或  $y$  轴或  $z$  轴)预测输出的着舰航迹点值;  $q_i$  为  $i$  时刻着舰航迹点在  $x$  轴(或  $y$  轴或  $z$  轴)的实际值。上述 RMSE 和 MAE 均为针对着舰航迹点坐标  $x, y, z$  分别进行计算的。因此,实验中还采用了三维坐标系内的平均绝对误差以及均方根误差来综合评估模型的性能,计算公式如下:

$$MAE_{xyz} = \frac{1}{3N} \sum_{i=1}^N (|x_i' - x_i| + |y_i' - y_i| + |z_i' - z_i|) \quad (19)$$

$$RMSE_{xyz} = \sqrt{\frac{1}{3N} \sum_{i=1}^N (x_i' - x_i)^2 + (y_i' - y_i)^2 + (z_i' - z_i)^2} \quad (20)$$

## 5.5 实验结果与分析

### 5.5.1 基于分阶段自编码器与注意力机制的航迹预测方法具体步骤

由于 LSTM 具有对突发变化的快速响应及高实时性,注意力机制具有长时依赖的性质,因此本文提出基于分阶段自编码器与注意力机制进行实时航迹预测,进一步提高定位及预测精度。实验流程如图 7 所示,具体步骤如下:

Step1 航迹数据生成。由式(2)初始化生成舰载机航迹数据  $p_i(x, y, z), \dots, p_{n+i}(x, y, z)$ 。

Step2 数据样本生成。采用滑动窗口生成航迹样本数据集后,由式(16)对样本数据集的各维度进行归一化处理,并根据表 1 设置训练集和测试集。

Step3 数据降维、特征提取。将预处理后的数据样本输入降噪自编码器中进行数据降维和特征提取。

Step4 模型训练。将训练集输入基于 LSTM 的时序自编码器中进行训练。

Step5 测试数据输入。将测试集输入训练好的模型中进行航迹预测。

Step6 航迹更新。输出舰载机航迹预测数据  $p_i(x, y, z), \dots, p_{m+i}(x, y, z)$ 。




图 7 实验流程图

Fig. 7 Experimental flowchart

### 5.5.2 舰载机航迹预测实验结果

首先随机选取 30 条舰载机着舰航迹,然后采用滑动窗口生成航迹样本数据集,滑动窗口大小设置为:  $n=5, m=1, n=10, m=1, n=15, m=1$ , 总共进行 30 次着舰航迹预测实验。对比实验中选取的基线模型为原始 LSTM<sup>[7]</sup>、Bi-LSTM(Bi-directional LSTM, 双向长短期记忆网络)<sup>[27]</sup>、原始 RNN<sup>[28]</sup>、原始 GRU(Gated Recurrent Unit, 门控循环单元)<sup>[29]</sup>、SGCN<sup>[30]</sup> 和 MANTRA<sup>[31]</sup>。其中 Bi-LSTM 由前向 LSTM 和后向 LSTM 组成,能够双向捕捉较长距离的依赖关系;SCGN 是一种用于预测行人轨迹的稀疏图卷积网络;MANTRA 基于记忆增强网络(MANN)学习过去和未来的轨迹,然后通过解码器观察过去的轨迹,以模拟未来编码进行轨迹预测。

由于舰载机机动速度快,如果单点预测耗时过长,则预测

结果意义非常有限<sup>[32]</sup>。为此,本文对不同基线模型的单航迹点预测耗时进行对比,对比实验结果如图 8 所示。




图 8 单航迹点预测时间对比实验结果

Fig. 8 Comparison experiment results of single track point prediction time

实验结果表明,原始 GRU 的单点预测时间最短,约为

0.07 s。这是由于 GRU 较 LSTM 网络结构更简单,它删除了输出门,只有重置门和更新门,因此在每个时间点计算的内部状态更少,学习速度更快。本文模型由于引入了降噪自编码器和注意力机制模块,模型复杂度增加,导致单航迹点预测时间有所上升,约为 0.08 s,但是该预测时间远小于飞行员的反应时间。以歼 20 战斗机飞行员为例,其选拔标准相当严苛,要求飞行员测试的反应时间应小于 3 s,因此本文所提模型能够满足航迹实时预测的要求。

为了评估所提模型的预测性能,本文对在不同模型下的航迹点三维空间位置坐标  $x, y, z$  的预测值与实际航迹点坐标进行对比,结果如图 9 所示。

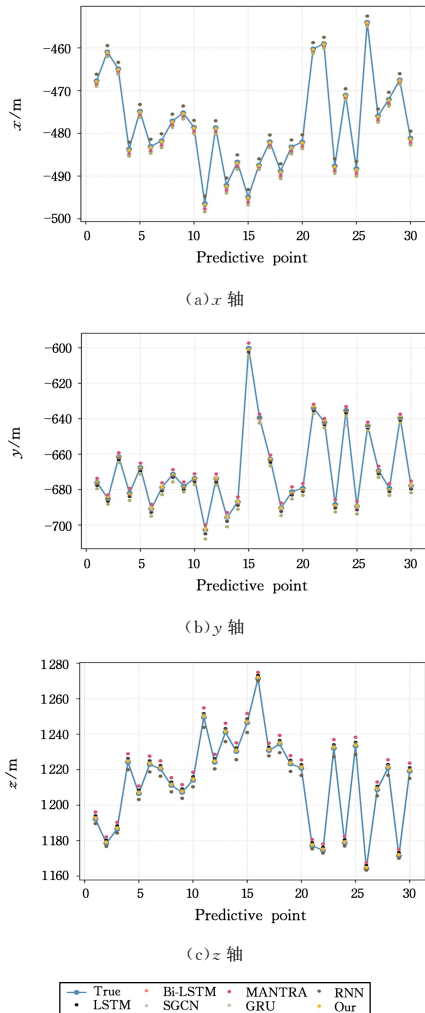


图 9 不同方法着舰航迹预测结果(电子版为彩图)

Fig. 9 Prediction results of carrier aircraft landing trajectory by different methods

不同模型在 30 个航迹点上的预测结果如图 9 所示。蓝色折线代表实际航迹点坐标值,橘红色点代表本文所提模型预测的航迹点坐标值。从图中可以观察到,二者基本吻合,而其他 6 种基线模型与实际航迹点坐标值相比偏差较大。这说明本文所提模型预测的航迹点坐标值更接近于实际航迹点坐标值。

接下来,分别计算并对比每种模型在  $x, y, z$  坐标上的 MAE 和 RMSE,结果如图 10 所示。

如图 10 所示,所有模型在给定坐标轴上预测结果的 MAE 与 RMSE 均较为接近,即  $MAE_x$  与  $RMSE_x$ 、 $MAE_y$  与  $RMSE_y$ ,以及  $MAE_z$  与  $RMSE_z$  较为接近,说明所有模型均未出现异常预测值,与实际航迹吻合度较高。此外,可以明显看出,本文模型的 MAE 与 RMSE 均小于基线模型,说明本文模型具有较高的预测精度。




图 10 不同方法着舰航迹预测精度对比

Fig. 10 Comparison of accuracy of carrier aircraft landing trajectory prediction by different methods

为了评估不同模型着舰航迹预测的综合表现,本文将 7 种模型的  $MAE_{xyz}$  及  $RMSE_{xyz}$  进行对比,判断着舰航迹点的整体误差,结果如图 11 所示。




图 11 航迹点三维坐标的预测误差

Fig. 11 Prediction error of three-dimensional coordinates of carrier aircraft landing trajectory points

从图 11 中可以明显观察到,本文模型的  $MAE_{xyz}$  及  $RMSE_{xyz}$  均小于基线模型的  $MAE_{xyz}$  及  $RMSE_{xyz}$ ,说明所提模型在航迹预测的综合精度上也优于其他基线模型。

### 5.5.3 舰载机着舰点预测实验结果

着舰点指舰载机降落时触舰的位置,是舰载机着舰航迹的终点,因此,着舰点预测是航迹预测的重要组成部分。与陆基着陆不同,舰载机着舰需要在有限的甲板空间内实现挂索、拦停,因此舰载机理想的着舰点需要精准的控制在一个较小的范围内,即第 2 道和第 3 道阻拦索之间,并且尽量接近甲板跑道的正中轴线。同时,在实际着舰训练中,如果舰载机触舰后成功挂锁,其时速将瞬间由 200 km/h 左右减至为零,飞行员需要承受巨大的过载压力,因此飞行员通常更多地侧重于在陆基模拟无阻拦索的条件下训练着舰,并根据着舰点的位置判断着舰作业是否成功。此外,阻拦索存在时,还涉及对阻拦着舰拉制状态的判定<sup>[33]</sup>,这是由于即使舰载机着舰点处于理想位置,仍有可能因为尾钩故障、触舰弹跳等出现拉制失败后的紧急逃逸复飞。综上所述,舰载机着舰点位置的判定在一定程度上决定了阻拦着舰是否成功。

为了评估不同模型的着舰点预测精度,本文随机选取

30条舰载机着舰航迹,并根据航迹的最后10个连续点预测最终的着舰点。当预测的航迹在y轴的坐标为0时,认为舰载机降落至甲板面。对比实验结果如图12所示。

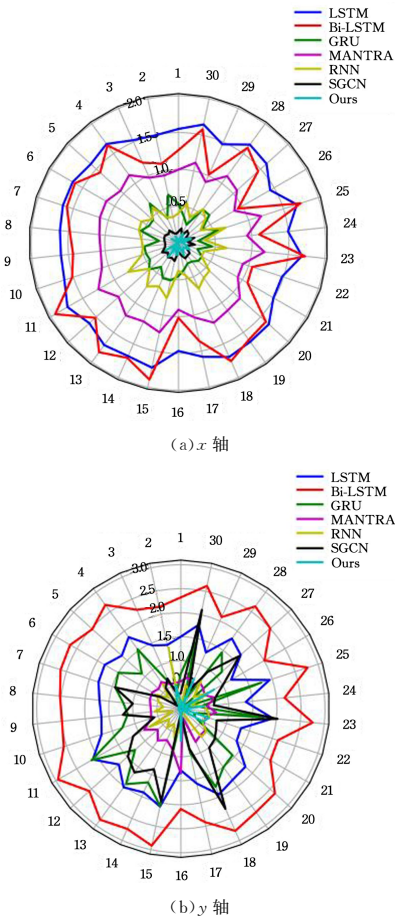


图12 不同模型的着舰点预测误差对比

Fig. 12 Comparison of carrier aircraft landing point prediction errors of different models

可以看出,本文模型预测的着舰点误差最小,且美国宇航局兰利研究中心的技术表明,一般6t以上的航母均会配备4~6根阻拦索,且每隔14m设一道,舰载机尾钩通常会钩住第2或第3道阻拦索滑行100m左右被拦停<sup>[34]</sup>,而本文模型预测的误差远小于舰载机在甲板面的降落范围(42~70m),与实际着舰点最为接近,不会对舰载机降落的指挥造成误判。综上所述,本文模型能够实现舰载机航迹及着舰点的实时精准预测,预测结果能为着舰指挥决策提供较为可靠的决策参考。

#### 5.5.4 消融实验

为了证明本文模型中降噪自编码器及注意力机制的有效性,本小节通过消融实验分析LSTM-自编码器、降噪自编码器以及注意力机制对预测性能的影响。具体地,采用LSTM-自解码网络作为基线模型,对基线模型增加3种关键设计选项:1)在基线模型前引入降噪自编码器;2)在基线模型编码器与解码器之间增加注意力机制模块;3)在基线模型前引入降噪自编码器,在基线模型编码器与解码器之间增加注意力机制模块。消融实验结果如表2所列,其中加粗表示最佳预测效果。

表2 消融实验结果对比

Table 2 Comparison of ablation experiment results

LSTM Auto-encoder	DAE	Temporal Attention	MAE <sub>xyz</sub>	RMSE <sub>xyz</sub>
✓	—	—	1.485	2.672
✓	✓	—	1.167	1.687
✓	—	✓	0.831	0.975
✓	✓	✓	<b>0.433</b>	<b>0.314</b>

由表2可以看出,LSTM-自编码器由于未引入降噪自编码器及注意力机制模块,预测精度明显低于其他3种算法。当LSTM-自编码器仅引入降噪自编码器时,由于该算法可以有效地应对不同条件下产生的细微噪声,因此MAE<sub>xyz</sub>及RMSE<sub>xyz</sub>有所下降;而当LSTM-自编码器仅引入注意力机制模块时,由于此时算法可以调控不同时刻对未来航迹预测的影响强度,捕获航迹数据在时间序列上的相关性,因此MAE<sub>xyz</sub>及RMSE<sub>xyz</sub>也有所下降。为此,对LSTM-自编码器综合引入降噪自编码器和注意力机制模块,可以明显看出此时模型在数据集上取得了最佳预测精度,MAE<sub>xyz</sub>及RMSE<sub>xyz</sub>分别下降约47.9%和67.8%。消融实验结果说明,引入降噪自编码器和注意力机制模块能够有效提升模型的预测性能。

#### 5.5.5 舰载机着舰航迹预测可视仿真系统

舰载机着舰作业被认为是航空领域中一项复杂且高风险的任务,在实际着舰训练中还会涉及高昂的飞行和维护成本。为了更直观地观察舰载机着舰预测的表现,本文基于Unity 3D互动内容创作平台初步搭建了一款舰载机着舰航迹预测可视仿真系统,如图13所示。通过对舰载机进行可视建模及舰载机起降参数的设置,分析着舰航迹预测的性能和效率,从而在真实环境中取得更好的表现,为后续的研究提供一种可视化的辅助手段。

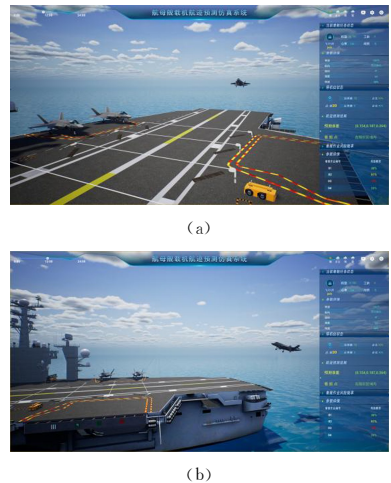


图13 舰载机航迹预测仿真系统

Fig. 13 Simulation system for carrier aircraft trajectory prediction

**结束语** 本文提出了一种分阶段自编码器与注意力机制的舰载机着舰航迹实时预测模型,第一阶段通过降噪自编码器实现鲁棒的特征学习,第二阶段基于长短期记忆网络构建时序自编码器,并在编码器和解码器之间引入时间注意力层,以调控不同时刻历史数据对未来航迹的影响,捕获航迹数据在时间序列上的相关性。舰载机航迹和着舰点预测的仿真实验结果表明,本文所提模型的预测精度优于基线模型,且能够

满足舰载机航迹预测的实时性的需求。未来工作中可将航迹预测的结果作为舰载机着舰指挥决策模型的输入之一,实现着舰自动引导或人机协同引导。

### 参 考 文 献

- [1] WANG K, XU M L, LI Y F, et al. A Robust Learning Model for Deck Motion Prediction of Aircraft Carrier[J/OL]. <https://doi.org/10.16383/j.aas.c210664>.
- [2] LIU G, YAN S, LI H, et al. Aviation Support Technology Development for Foreign Aircraft Carrier[J]. *Aeronautical Science & Technology*, 2020, 31(2): 1-11.
- [3] ZHU Q D, ZHANG Z, ZHANG W. Safe Takeoff and Landing Technology for Carrier Aircraft[M]. Harbin: Harbin Engineering University Press, 2016.
- [4] LIANG Y. Testing an Intelligent Landing Signals Officer(LSO) Agent for Conducting Pilot Training in a Helicopter Deck Landing Simulator[C]// 2005 International Conference on Neural Networks and Brain. Beijing, China: IEEE, 2005: 204-207.
- [5] HUANG X, HONG G X. Modeling and Simulation Research on Error Origin of Fresnel Lens Optical Landing System[J]. *Flight Dynamics*, 2010, 28(1): 92-96.
- [6] XU X Y. A Comprehensive Research on the Assessment Approaches of the Shipboard Aircraft's Landing Posture[D]. Wuhan: Huazhong University of Science and Technology, 2021.
- [7] HOCHREITER S, SCHMIDHUBER J. Long Short-Term Memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [8] RUSH A M, CHOPRA S, WESTON J. A Neural Attention Model for Abstractive Sentence Summarization[C]// Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. 2015: 379-389.
- [9] BAHDANAU D, CHO K, BENGIO Y. Neural Machine Translation by Jointly Learning to Align and Translate[J]. arXiv:1409.0473, 2014.
- [10] HE Y Q. Crowd Counting Based on Convolutional Neural Network[D]. Hefei: University of Science and Technology of China, 2023.
- [11] LIN Y, YANG B, ZHANG J, et al. Approach for 4-D Trajectory Management Based on HMM and Trajectory Similarity[J]. *Journal of Marine Science and Technology*, 2019, 27(3): 246-256.
- [12] TASTAMBEKOV K, PUECHMOREL S, DELAHAYE D, et al. Aircraft Trajectory Forecasting Using Local Functional Regression in Sobolev Space[J]. *Transportation Research Part C Emerging Technologies*, 2014, 39: 1-22.
- [13] SHI Z, XU M, PAN Q, et al. LSTM-based Flight Trajectory Prediction[C]// 2018 International Joint Conference on Neural Networks(IJCNN). Rio de Janeiro, Brazil: IEEE, 2018: 1-8.
- [14] WU Z, TIAN S, MA L. A 4D Trajectory Prediction Model Based on the BP Neural Network[J]. *Journal of Intelligent Systems*, 2020, 29(1): 1545-1557.
- [15] BAKLACIOGLU T, CAVCAR M. Aero-propulsive Modelling for Climb and Descent Trajectory Prediction of Transport Aircraft Using Genetic Algorithms[J]. *Aeronautical Journal*, 2014, 118(1199): 65-79.
- [16] ZHANG T, GUO J L, XU X M, et al. Air Combat Trajectory Prediction of a Fighter Based on Elman Neural Network[J]. *Flight Dynamics*, 2018, 36(5): 86-91.
- [17] ZHANG W, ZHU Q D, ZHANG Z, et al. An Online Prediction Method for Short Term Track of Shipborne Aircraft Landing: Chinese Patent, CN106339355B[P]. 2019-01-11. <https://pss-system.cponline.cnipa.gov.cn/conventionalSearch>.
- [18] ZHANG W, ZHANG Z. Carrier Landing Command Decision-making Algorithm Based on Trajectory Prediction[J]. *Journal of Harbin Engineering University*, 2019, 40(1): 181-188.
- [19] SUTSKEVER I, VINYALS O, LE Q V. Sequence to Sequence Learning with Neural Networks[C]// Proceedings of the 27th International Conference on Neural Information Processing Systems. 2014: 3104-3112.
- [20] EUROCONTROL EXPERIMENTAL CENTER. User Manual for the Base of Aircraft Data(BADA) Revision 3. 12[R]. EEC Technical Report No. 12/04, 2013.
- [21] WEITZ L A, SMITH E C. Derivation of a Point-Mass Aircraft Model used for Fast-Time Simulation[R]. MA, USA: MITRE Technical Report, 2015.
- [22] ZAMMIT B, ZAMMIT-MANGION D. Accuracy Considerations of a Simple Aircraft Trajectory Prediction Model for Idle Thrust Descents[C]// 2013 IEEE/AIAA 32nd Digital Avionics Systems Conference(DASC). East Syracuse, NY, USA, 2013: 1E2-1-1E2-16.
- [23] WANG Z, LIANG M, DELAHAYE D. Short-term 4D Trajectory Prediction Using Machine Learning Methods[C]// 7th SESAR Innovation Days. Belgrade, Serbia, 2017: 1-9.
- [24] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and Composing Robust Features with Denoising Autoencoders[C]// Proceedings of the 25th International Conference on Machine Learning(ICML '08). New York, NY, USA: Association for Computing Machinery, 2018: 1096-1103.
- [25] ZHANG X, MAHADEVAN S. Bayesian Neural Networks for Flight Trajectory Prediction and Safety Assessment[J]. *Decision Support Systems*, 2020, 131: 113246.
- [26] YAO Q, SONG D, CHENG H, et al. A Dual-stage Attention-based Recurrent Neural Network for Time Series Prediction[C]// Proceedings of the 26th International Joint Conference on Artificial Intelligence(IJCAI'17). Melbourne, Australia: AAAI Press, 2017: 2627-2633.
- [27] GRAVES A, FERNANDEZ S, SCHMIDHUBER J. Bidirectional LSTM Networks for Improved Phoneme Classification and Recognition[C]// Proceedings of the 15th International Conference on Artificial Neural Networks, Formal Models and Their Applications-Volume Part II (ICANN '05). Berlin, Heidelberg: Springer-Verlag, 2005: 799-804.
- [28] LITTLE W A. The Existence of Persistent States in the Brain[J]. *Mathematical Biosciences*, 1974, 19(1/2): 101-120.
- [29] CHO K, MERRIENBOER B V, GULCEHRE C, et al. Learning

Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation[J]. arXiv:1406.1078, 2014.

[30] SHI L, WANG L, LONG C, et al. SGCN: Sparse Graph Convolution Network for Pedestrian Trajectory Prediction[C]// 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). 2021:8990-8999.

[31] MARCHETTI F, BECATTINI F, SEIDENARI, et al. Mantra: Memory Augmented Networks for Multiple Trajectory Prediction[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). 2020:7143-7152.

[32] ZHONG G, ZHANG H, ZHOU J, et al. Short-Term 4D Trajectory Prediction for UAV Based on Spatio-Temporal Trajectory Clustering[J]. IEEE Access, 2022, 10:93362-93380.

[33] WANG K, LIU Y Y, YANG J, et al. Arrested Landing State Recognition of Carrier-Based Aircraft Based on Adaptive Feature Enhancement and Fusion [J/OL]. <https://doi.org/10.16183/j.cnki.jsjtu.2023.263>.

[34] SHERMAN W L. Generalization and Refinement of an Auto-

matic Landing System Capable of Curved Trajectories: 19770005089 [S]. USA: NASA Langley Research Center Hampton, 1976.



**LI Zhe**, born in 1995, Ph.D candidate, is a member of CCF (No. U4062G). Her main research interests include intelligent perception and learning and so on.



**WANG Ke**, born in 1985, Ph. D, lecturer, master's supervisor, is a member of CCF (No. P5447M). His main research interests include machine learning, deep learning, representation learning and their applications.

(责任编辑:何杨)

## 图灵奖获得者 JOHN HOPCROFT 教授将出席 CNCC2024 作特邀报告

John Hopcroft 教授,这位在计算机科学界熠熠生辉的名字,不仅是中国科学院外籍院士,还同时荣膺美国国家科学院、工程院以及艺术与科学院三院院士的崇高荣誉!他的研究深耕于理论计算机科学领域,成就斐然,包括 1986 年的 ACM 图灵奖、2010 年的 IEEE 冯诺依曼奖,以及 2017 年美国工程院的西蒙雷曼奖创始人奖等。

不仅如此, Hopcroft 教授还是一位杰出的教育家,拥有超过半个世纪的丰富教学经验,桃李满天下。近十年来,他更是积极参与中国高校的计算机人才培养改革,为推动计算机科学教育模式的创新与发展做出了卓越的贡献。

6 月 24 日,北京大学客座讲席教授、上海交通大学约翰·霍普克罗夫特计算机科学中心主任约翰·爱德华·霍普克罗夫特教授被授予中华人民共和国国际科学技术合作奖。

霍普克罗夫特是全球最具有影响力的计算机科学家之一,长期从事理论计算机科学研究。1986 年,他凭借在算法及数据结构设计和分析方面取得的奠基性成就获得计算机科学的最高荣誉——“图灵奖”。他的系列研究成果为计算机科学提供了坚实的理论基础,对现代算法设计、程序语言处理器和计算理论产生了深远持久的影响。

这是一次近距离聆听大师智慧、感受科学魅力的绝佳机会!赶快抢购 CNCC2024 的门票,与 John Hopcroft 教授共同见证思想的碰撞与智慧的火花!



扫码报名

据 CCF 微信公众号