

航空器导航系统飞参预测置信度评价方法研究



黄梦婵, 钟杰, 苗强

四川大学, 四川 成都 610065

摘要: 为了提高航空器的安全性能, 需量化飞参预测过程中的不确定性, 因此本文提出了基于预测模型的置信度评价流程。针对航空器导航系统中的飞参数据, 采用卷积神经网络开发预测算法, 对选定的飞参数据进行预处理和训练, 实现高精度的目标飞参预测。综合考虑了模型搭建中的认知不确定性和数据层面的偶然不确定性, 采用模型集成的方法来捕获认知不确定性, 通过双头网络捕获数据中的偶然不确定性。在此基础上, 构建多源不确定性模型, 实现了飞参预测模型的置信度评价。经过试验测试, 在正常飞参数据中植入噪声模拟实际工况的不确定性, 结果显示所提置信度评价方法能有效地表示飞参预测结果的准确性, 提高了航空器飞行决策过程中的安全性与可靠性。

关键词: 航空器; 飞行参数; 神经网络; 不确定性分析; 置信度

中图分类号: V241

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2024.02.014

导航系统是保证航空器安全稳定运行的重要系统之一^[1], 导航系统中含有丰富的飞行监测数据, 这些监测数据可以作为反映航空器飞行状态的指标。针对导航系统中的飞行参数(简称飞参)进行预测, 并进一步根据预测结果实现导航系统的异常检测与异常定位, 以提高航空器的安全性能^[2]。因此, 开展导航系统中的飞参预测具有重要的研究意义与应用价值。

航空器飞参数据具有大数据量、高维度以及强耦合的特点^[3]。基于模型的方法, 通过空气动力学方程和数学模型建立航空器导航系统仿真模型^[4], 从而实现飞参预测。然而, 导航系统的结构复杂度高, 难以建立精确的数学模型。因此, 采用基于模型的飞参预测方法对导航系统而言并不具优势, 在自适应性和鲁棒性上无法满足需求。基于数据驱动的预测方法从数据层面出发, 可以有效地针对大数据进行信息或特征挖掘。其中, 数据处理能力更强的神经网络能在数据预测层面达到更好的效果。

在实际工程应用中, 导航系统的异常检测十分注重结果的物理意义, 也更强调方法的可解释性。然而, 传统算法模型仅能输出单一预测和异常定位结果, 基于深度学习的

神经网络运算过程具有不可解释性, 无法对预测结果的置信度进行描述。因此, 对预测过程存在的不确定性进行量化评估, 继而对预测模型进行置信度评价十分有必要。

在深度学习研究领域, 普遍存在两种不确定性, 即认知不确定性和偶然不确定性^[5]。认知不确定性指的是模型中的不确定性, 一方面是由系统异常空间未知导致的, 另一方面是由历史数据集不充足造成的, 在数据集充足的条件下, 认知不确定性可以被有效降低。在数据采集集中, 由于环境或传感器固有特性导致采集数据中存在噪声, 从而使得预测结果中存在随机性, 因此此类不确定性为偶然不确定性。因而, 偶然不确定性在实际工程应用中是无法避免的。

对于认知不确定性的量化方法, 可以分为基于贝叶斯网络的方法和基于非贝叶斯网络的方法两类。麦吉尔大学的 Zhang Yingyue 等^[6]利用贝叶斯定理构建贝叶斯图卷积神经网络, 并利用混合隶属度随机块模型重构网络结构, 以解决同质信息网络中网络结构的不确定性问题。A.Graves 等^[7]提出用高斯变分后验证近似拟合神经网络上的权值, 在完成不确定性建模的同时, 通过剪枝方法成功缩小模型的参数。但是, 使用贝叶斯网络的方法时, 不准确的先验会

收稿日期: 2023-07-27; 退修日期: 2023-11-20; 录用日期: 2024-01-03

基金项目: 航空科学基金(201905019001)

引用格式: Huang Mengchan, Zhong Jie, Miao Qiang. Research on confidence evaluation method of flight parameter prediction in aircraft navigation system[J]. Aeronautical Science & Technology, 2024, 35(02): 112-118. 黄梦婵, 钟杰, 苗强. 航空器导航系统飞参预测置信度评价方法研究[J]. 航空科学技术, 2024, 35(02): 112-118.

导致不合理的预测不确定性。

基于非贝叶斯网络量化认知不确定性的方法,具有代表性的是基于模型集成的方法,通过集成多个基础网络模型,合成预测结果以减少方差,同时生成模型不确定性的分布估计,但此方法需要更高的内存和计算成本,在许多场景下难以进行模型部署。B. Lakshminarayanan等^[8]提出了一种简单且可扩展的方法来估计神经网络模型中的预测不确定性,通过训练多个独立的神经网络模型,并对各模型的预测结果进行聚合,可以获得更可靠的 uncertainty 估计结果。Y. Ovadia等^[9]根据受分布偏移影响的测试集评估不同的 uncertainty 量化方法,研究考虑了多种数据模式和架构,最终指出相对较小的集成模型对于 uncertainty 量化的任务已足够。相较其他对比方法,基于模型集成的方法在面对数据集迁移时显示出更强的鲁棒性。

对于偶然不确定性的量化方法,目前的研究相对较少。然而,真实工况数据的噪声、不一致性和多模态性使得数据层面的 uncertainty 变得不容忽视。M. Ott等^[10]针对机器翻译中存在多个合理的翻译版本以及训练数据中的噪声,提出了外在 uncertainty 评价工具和指标,然而最终量化的是模型输出中的 uncertainty。Chang Jie等^[11]针对人脸识别任务建模数据的不确定性,将数据的均值和方差表示为特征和 uncertainty,并同步进行训练。李艳等^[12]针对元学习中的 uncertainty 进行建模,建立了6种 uncertainty 表示方法。然而,这些方法是基于某些领域或特定条件提出的,且都是基于分类模型的 uncertainty 量化方法,没有提出一种通用方法来处理一般数据中的 uncertainty。在实际应用中,由于不同领域数据的差异性,不同领域间 uncertainty 量化方法和模型的迁移性和可扩展性较差。因此,构建一种通用且简单的 uncertainty 量化方法十分必要。

综上所述,已有不少研究在基于深度学习的神经网络中开展 uncertainty 量化,实现对网络模型的置信度评价。然而,现有研究仅单独分析了认知不确定性和偶然不确定性,缺乏综合考虑两种 uncertainty 对预测模型的影响。因此,本文在飞参预测模型的基础上,充分考虑多源不确定性的影响,构建多源 uncertainty 分析模型,实现飞参预测模型的置信度评价。

1 不确定性理论

航空器导航系统飞参预测中存在认知不确定性和偶然不确定性。认知不确定性是由于导航系统异常空间未知和历史数据集不充足而产生的。偶然不确定性是由于采集到

的数据所包含的噪声导致了预测结果的随机性。飞参预测任务中 uncertainty 可以表示为认知不确定性和偶然不确定性的总和。综合考虑多源 uncertainty,可以有效地评价飞参预测模型的置信度,从而提高预测结果的可靠性和鲁棒性。

1.1 认知不确定性

认知不确定性可以表示为模型中参数的概率分布。假设系统参数数据集为 $X = \{x_1, \dots, x_N\}$, $Y = \{y_1, \dots, y_N\}$, 模型为 $y = f^w(x)$, w 为模型参数,贝叶斯方法定义的模型似然表示为 $p(y|f^w(x))$ 。然而,精确计算后验分布较为困难,变分法通过最小化相对熵使得变分分布接近真实后验分布,因此可以使用变分法近似后验分布。

为了捕获认知不确定性,常用的方法有蒙特卡罗随机失活(MC Dropout)和模型集成。MC Dropout 通过在网络中的 Dropout 层进行推理,并进行多次采样来近似后验分布,适用于大型复杂模型。模型集成则通过训练多个同构模型,并对它们的输出进行均值和方差计算来获得预测结果和认知不确定性。考虑到单个预测模型的规模较小,并且为了提高计算效率,本文采用基于模型集成的认知不确定性捕获方法。集成式认知不确定性捕获方法的流程如图1所示。




图1 集成式认知不确定性捕获方法

Fig.1 Epistemic uncertainty capture method based on model ensemble method

在集成式认知不确定性捕获方法中,预测结果表示为

$$E(y_i) = \frac{1}{N} \sum_{n=1}^N f_n(x_i) \quad (1)$$

式中, N 为参数个数,即预测模型的个数; f_n 为第 n 个预测模型。

认知不确定性 EU 表示为

$$EU = \frac{1}{N} \sum_{n=1}^N f_n(x_i)^T f_n(x_i) - E(y_i)^T E(y_i) \quad (2)$$

1.2 偶然不确定性

偶然不确定性可以进一步分为同方差不确定性和异方差不确定性。同方差不确定性是指不同输入具有相同的不确定性,而异方差不确定性与输入 x 的噪声方差 σ 有关,描述了输入数据中噪声对预测结果 $\hat{y}$ 的影响。

本文针对异方差不确定性进行研究,基于数据建立的可学习异方差函数为

$$L(\theta) = \frac{1}{M} \sum_{i=1}^M \frac{1}{2} \sigma_i^{-2} \|y_i - \hat{y}_i\|^2 + \frac{1}{2} \log \sigma_i^2 \quad (3)$$

式中, M 为单批次样本数量。式(3)计算了最大后验估计,以找出单一权重 θ ,没有对权重执行变分推断,即此部分仅考虑数据层面的不确定性。

1.3 置信度评价

综合考虑认知不确定性和偶然不确定的输出结果,计算飞参预测结果的置信度。置信度评价公式为

$$u = 100 - (\lambda_{\text{cu}} \hat{\sigma}_{\text{cu}}^2 + \lambda_{\text{au}} \hat{\sigma}_{\text{au}}^2) / \varepsilon \quad (4)$$

式中, $\hat{\sigma}_{\text{cu}}^2$ 为认知不确定性; $\hat{\sigma}_{\text{au}}^2$ 为偶然不确定性; λ_{cu} 为认知不确定性权重; λ_{au} 为偶然不确定性权重; ε 为误差度量系数; u 为最终的置信度。

式(4)中的误差度量系数 ε 是为了将偶然不确定性和认知不确定性表示为0~100的置信度值。以飞参中的俯仰角为例,其满量程为 120° ,幅值容限为10%。若 $(\lambda_{\text{cu}} \hat{\sigma}_{\text{cu}}^2 + \lambda_{\text{au}} \hat{\sigma}_{\text{au}}^2)$ 为 12° 时,对应的置信度为60,则 ε 计算为 $12/(100 - 60) = 0.3$ 。

预测模型的置信度 u 在0~100范围内, u 越接近于0表示置信度越低,即预测结果越不可信; u 越接近于100表示置信度越高,即预测结果越可信。若 u 小于0,则被强制置为0。在本文中,每一个飞行参数都对应一个表示其预测结果的置信度。

2 基于飞参预测的不确定性模型

2.1 算法整体框架

本文提出了一种用于飞参预测置信度评价的不确定性模型分析框架,该网络模型的主体架构为卷积神经网络(CNN)。算法整体流程如图2所示。

首先,对飞参数据集中的数据进行预处理,采用线性函数归一化将所有数据映射到同一尺度,并通过滑动窗口将数据集划分为多个样本;其次,将划分好的训练集样本输入飞参预测不确定性模型进行训练;最后,得到预测结果和




图2 基于CNN的置信度评价框架

Fig.2 Confidence evaluation framework based on CNN

确定性量化值,完成飞参预测的置信度评价。

2.2 飞行数据预处理

为了使飞行参数数据适用于神经网络模型的训练和分析,在一开始进行数据预处理的工作。本文中数据预处理主要包括数据归一化与滑动窗口处理。

数据归一化是指将所有训练集和测试集的数据映射到同一尺度,以消除不同特征之间量纲和取值范围差异带来的影响。本文采用线性函数归一化,将原始数据等比缩放至[0,1]区间,归一化公式为

$$x'_i = \frac{x_i - x_i^{\min}}{x_i^{\max} - x_i^{\min}} \quad (5)$$

式中, $x_i (i = 1, 2, \dots, N)$ 为某飞行参数的原始数据, x'_i 为归一化后的数据, $x_i^{\max}$ 为该参数原始数据中的最大值; $x_i^{\min}$ 为该参数原始数据中的最小值; N 为参数总量。

在归一化的基础上,为了充分利用已有数据,对数据进行滑动窗口处理,通过滑动窗口和切片相结合的方式将训练集和测试集的数据划分成多个样本,作为最终输入模型的数据。设置滑动窗口的宽度 D 和滑动步长 s ,使用历史切片数据预测目标参数在当前时刻的数据。滑动窗口处理的表达式为

$$\begin{cases} X_t = \{x_{t-1}, x_{t-2}, \dots, x_{t-D}\} \\ Y_t = y_t \end{cases} \quad (6)$$

式中, $X_t \in \mathbb{R}^{N-1}$ 为 t 时刻输入模型的数据; Y_t 为 t 时刻待预测目标参数的原始值; x_{t-1} 为 t 时刻之前一个时刻的输入参数数据; D 为采样维度。本文设置滑动窗口的宽度为18,滑动步长为1,对数据集进行滑动窗口处理。

2.3 飞参预测模型构建

由于航空器飞参数据为多维时间序列信号,具有大数据量、高维度以及强耦合的特点,传统机器学习的预测方法

在自适应性和鲁棒性上无法满足需求,数据处理能力更强的神经网络得到关注,其中卷积神经网络能够有效地提取局部特征,并实现参数共享。因此,本文采用CNN建立单飞参预测模型,根据其他已知相关飞参数据对航空器目标飞参数据进行准确的预测。

CNN由卷积层、池化层和全连接层交叉堆叠而成。本文采用二维卷积神经网络建立预测模型,通过卷积层和池化层对输入的相关飞参数据的特征进行提取,最终得到目标飞参数据预测结果。

航空器的姿态数据采样频率为60Hz,实时描述了航空的飞行状态,本文选取了33个航空器姿态相关数据(包含速度类、角速度类、指令类、过载类、舵面位置类、高度类等),采用其中32个参数的已知数据预测一个目标参数的数据,滑窗宽度为18,因此输入数据的大小为 32×18 ,输出数据的大小为 1×1 。

2.4 不确定性模型构建与训练

本文所设计捕获预测过程中多源不确定性的网络架构如图3所示,其中 n 表示捕获集成式认知不确定性时所需的模型个数。为了同时捕获认知不确定性和偶然不确定性,在异方差偶然不确定性模型中放入权重分布,使得模型转化为贝叶斯神经网络。在设计过程中,贝叶斯神经网络模型输出需要包含两部分:一部分是由输入数据经过预测模型得到的预测结果及认知不确定性;另一部分是根据偶然不确定性模型得到的偶然不确定性。因此,建立基于双头网络的多源不确定性模型,包含综合特征提取网络、预测结果输出网络和偶然不确定性输出网络。

在多源不确定性模型中,综合特征提取网络用于提取输入数据的综合高级抽象特征与特征降维,综合特征提取




图3 多源不确定性模型结构

Fig.3 Multi-source uncertainty model structure

网络的结构如图4所示。

预测结果输出网络接收综合特征提取网络的低维特征输入,用于计算最终预测结果和认知不确定性;偶然不确定性输出网络接收综合特征提取网络的低维特征输入,用于计算预测结果的偶然不确定性。预测结果输出网络和偶然不确定性输出网络的结构一致,如图5所示。




图4 综合特征提取网络结构

Fig.4 Comprehensive feature extraction network structure




图5 结果输出网络结构

Fig.5 Output network structure

同时,考虑到集成式认知不确定性的捕获方法,本文选取 $n=5$,即建立5个同构多源不确定性网络模型,最终结果为所有同构模型输出的均值。

本文采用的训练损失函数为

$$L_2 = \frac{1}{M} \sum_{i=1}^M \frac{1}{2} \sigma_i^{-2} \|y_i - \hat{y}_i\|^2 + \frac{1}{2} \log \sigma_i^2 \quad (7)$$

式中, M 为单批次样本数量; σ 为噪声方差; y_i 为地面真实值; $\hat{y}_i$ 为模型预测值。式(7)中第一项为均方误差损失,计算了每个样本预测值与真实值之间的欧氏距离,并根据相应的噪声方差进行加权。第二项为不确定性正则化项,用于约束噪声方差的估计,防止模型无法收敛,并帮助提高模型的泛化能力。

3 测试验证

3.1 数据描述

本文所使用的试验数据均来自无人机的实际飞行数

据,该无人机为“Clouds”固定翼无人机,如图6所示。

试验数据利用Pixhawk 4采集得到,包含速度类、角速度类、指令类、过载类、舵面位置类、高度类等共33个传感器参数。无人机共进行18次飞行任务,部分任务全程平稳飞行,部分任务增加了大机动飞行。将其中12次飞行任务的飞参数据作为训练集,另外6次飞行任务的飞参数据作为测试集,训练集与测试集中均包含平稳飞行和大机动飞行的任务,旨在使模型具备不同工况下的预测能力并予以测试。



图6 “Clouds”固定翼无人机
Fig.6 “Clouds” fixed-wing UAV

3.2 预测结果对比

为了对比不同神经网络应用在试验数据集上的表现性能,将飞参预测模型的网络结构由CNN改为长短期记忆(LSTM)网络和全连接神经网络(FCNN),分别进行学习率为0.001的40轮网络训练,并将测试集输入训练完成的模型得到飞参预测结果。本文选择均方误差(MSE)和决定系数(R^2)作为评价指标,对33个飞参依次进行预测,将得到的33个MSE和 R^2 取均值得到最终该网络的预测指标结果,见表1。

表1 不同神经网络的预测指标对比

Table 1 Comparison of prediction indicators of different neural networks

网络结构	MSE	R^2
CNN	0.0002033	0.8102
LSTM	0.0002498	0.7115
FCNN	0.0002184	0.7953

根据对比试验的结果,本文所选取的CNN在飞参预测任务中的表现效果最好,其MSE是三个网络中最小的,而 R^2 是三个网络中最高的。由此可见,基于CNN的飞参预测模型对试验数据的拟合程度和预测能力都是最好的,这证明了本文预测模型所选网络的优越性和有效性。

3.3 噪声植入

为验证本文所提置信度评价方法的有效性,在正常飞参数据中植入噪声模拟实际工况下可能出现的不确定性。噪声植入的公式为

$$X' = X + \delta_{\text{snr}} \quad (8)$$

式中, X 为原始输入数据; δ_{snr} 为与 X 尺寸相同的噪声矩阵; X' 为植入噪声后的数据。 δ_{snr} 的计算公式为

$$\begin{cases} \text{snr} = 10 \log_{10} \frac{P_s}{P_n} \\ P_s = \sum_{t=1}^T x^2(t) \\ P_n = \sum_{t=1}^T n^2(t) \\ \delta_{\text{snr}} = \delta * \sqrt{P_n} \end{cases} \quad (9)$$

式中, x 为未加噪声的数据; n 为噪声; P_s 和 P_n 分别为原始数据和噪声的有效功率; δ 采样自标准正态分布。

3.4 结果测试

本文将测试数据植入不同信噪比的噪声,对预测模型开展置信度测试。以飞参中的俯仰角为例,在除俯仰角外的飞行参数中依次植入不同功率的噪声,使得数据的信噪比依次为50dB、20dB和10dB,然后将注入噪声的数据输入训练好的模型,观察并记录俯仰角预测值与真实值之间的差值以及置信度指标在不同噪声程度下的表现,结果如图7~图9所示。




图7 50dB信噪比下俯仰角预测结果

Fig.7 Prediction results of pitch angle under 50dB SNR

对比图7~图9可以发现,随着信噪比的逐步降低,俯仰角预测值逐渐偏离真实数据。当信噪比为50dB时,预测值跟随真实值的效果最好,在各个数据点的置信度也接近于100。同时,置信度指标的值也随着信噪比降低而下降,说明数据中含有的噪声越大,最终得到的预测值的置信度越低,也表示预测模型得到的结果越不可信。当飞参数据中




图8 20dB 信噪比下俯仰角预测结果

Fig.8 Prediction results of pitch angle under 20dB SNR




图9 10dB 信噪比下俯仰角预测结果

Fig.9 Prediction results of pitch angle under 10dB SNR

信噪比为 10dB 时,各个数据点对应的预测结果置信度甚至全为 0。这表明本文所提的置信度评价方法能有效地表示基于神经网络的飞参预测模型预测结果的准确度。

4 结论

本文针对高维度的导航系统飞参数据,进行飞参预测研究,采用卷积神经网络开发预测算法,对选定的飞参数据进行训练,实现了高精度的目标飞参预测。由于飞参预测模型基于神经网络,运算过程具有不可解释性,本文综合考虑了模型搭建中的认知不确定性和数据层面的偶然不确定性,采用模型集成的方法捕获认知不确定性,通过设计双头网络捕获数据中的偶然不确定性。在此基础上,构建多源不确定性模型,最终实现了飞参预测模型的置信度评价。经过试验测试,在正常飞参数据中植入噪声模拟实际工况下出现的不确定性,测试结果显示本文所提置信度评价方法能有效地表示飞参预测结果的准确性。

AST

参考文献

[1] 杨立钊.北斗卫星导航系统在民航导航中的应用分析[J].电子技术与软件工程,2020,193(23): 26-27.

Yang Lifan. Application analysis of Beidou navigation satellite system in civil aviation navigation[J]. Electronic Technology and Software Engineering, 2020, 193(23):26-27. (in Chinese)

- [2] Zhong Jie, Zhang Yujie, Wang Jianyu, et al. Unmanned aerial vehicle flight data anomaly detection and recovery prediction based on spatio-temporal correlation[J]. IEEE Transactions on Reliability, 2022, 71(1):457-468.
- [3] 叶子豪,张晓敏,刘亚飞,等.用于飞机模型参数辨识的飞行数据处理方法研究[J].航空科学技术,2022,33(8):78-87.
Ye Zihao, Zhang Xiaomin, Liu Yafei, et al. Research on flight data processing method for aircraft model parameter identification[J]. Aeronautical Science & Technology, 2022, 33(8):78-87. (in Chinese)
- [4] 钟伦珑,刘永玉,李雪艳.基于KL散度的紧组合导航欺骗式干扰检测方法[J].航空科学技术, 2022,33(11):76-83.
Zhong Lunlong, Liu Yongyu, Li Xueyan. Deception interference detection method for compact integrated navigation based on KL divergence[J]. Aeronautical Science & Technology, 2022, 33(11):76-83. (in Chinese)
- [5] Kendall A, Gal Y. What uncertainties do we need in bayesian deep learning for computer vision[C].31st Annual Conference on Neural Information Processing Systems (NIPS). Long Beach, 2017.
- [6] Zhang Yingyue, Pal S, Coates M, et al. Bayesian graph convolutional neural networks for semi-supervised classification[C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2019.
- [7] Graves A. Practical variational inference for neural networks [C].25st Annual Conference on Neural Information Processing Systems (NIPS). Granada Spain, 2011.
- [8] Lakshminarayanan B, Pritzel A, Blundell C. Simple and scalable predictive uncertainty estimation using deep ensembles [C].31st Annual Conference on Neural Information Processing Systems (NIPS). Long Beach, 2017.
- [9] Ovadia Y, Fertig E, Ren Jie, et al. Can you trust your model's uncertainty? Evaluating predictive uncertainty under dataset shift [C].33st Annual Conference on Neural Information Processing Systems (NIPS). Vancouver, 2019.
- [10] Ott M, Auli M, Grangier D, et al. Analyzing uncertainty in neural machine translation [C].35th International Conference

on Machine Learning (ICML). Stockholm, 2018: 3956-3965.

- [11] Chang Jie, Lan Zhonghao, Cheng Changmao, et al. Data uncertainty learning in face recognition[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, 2020: 5710-5719.

- [12] 李艳, 郭劼, 范斌. 元学习的不确定性特征构建及初步分析[J]. 计算机应用, 2022, 42(2): 343-348.

Li Yan, Guo Jie, Fan Bin. Uncertainty feature construction and preliminary analysis of meta-learning[J]. Computer Applications, 2022, 42(2): 343-348. (in Chinese)

Research on Confidence Evaluation Method of Flight Parameter Prediction in Aircraft Navigation System

Huang Mengchan, Zhong Jie, Miao Qiang

Sichuan University, Chengdu 610065, China

Abstract: To enhance the safety performance of aircraft, a confidence assessment process based on predictive modeling is proposed to quantify the uncertainty in flight parameter prediction. A convolutional neural network was employed to develop a prediction algorithm for flight parameter data in aircraft navigation systems. The selected flight parameter data was preprocessed and trained to achieve high-precision target parameter prediction. The modeling process incorporated both epistemic uncertainty in model construction and aleatoric uncertainty in the data by using ensemble methods to capture epistemic uncertainty and employing a dual-head network to capture aleatoric uncertainty. Based on this, a multi-source uncertainty model was constructed to evaluate the confidence of the flight parameter prediction model. Experimental testing, including the introduction of noise into normal flight parameter data to simulate real-world conditions, demonstrates that the proposed confidence assessment method effectively represents the accuracy of the flight parameter prediction results, and improves the safety and reliability of aircraft flight decision-making process.

Key Words: aircraft; flight parameter; neural networks; uncertainty analysis; confidence

Received: 2023-07-27; **Revised:** 2023-11-20; **Accepted:** 2024-01-03

Foundation item: Aeronautical Science Foundation of China(201905019001)