面向低空海洋物联网的分布式传感器驱动航迹关联与融合方法

王倩[1, 2]，左逸凡[1, 2]，姜微[1]，朱辉杰[3]，张寅[4]，钱丽萍[5]

（1. 浙江工业大学 网络空间安全研究院，浙江 杭州 310023；2. 杭州市滨江区浙工大人工智能创新研究院，浙江 杭州 310051；3. 中国电子科技集团公司第三十六研究所，浙江 嘉兴 314000；4. 中国联合网络通信有限公司浙江省分公司，浙江 杭州 310000；5. 中山大学 海洋工程与技术学院，广东 珠海 519082）

摘 要：在低空海洋物联网场景中，搭载机载雷达、AIS 接收机等异构传感器的多架无人机按需部署，构成覆盖特定海域的分布式感知网络，各平台独立跟踪目标并生成局部航迹；对多平台产生的多源局部航迹进行关联与融合，是实现高精度海上目标状态估计的核心任务。然而，无人机动态场景导致各平台观测时间窗口差异显著，加之机动飞行引入传感器标定偏差，传统航迹关联与融合方法在此条件下精度大幅下降，难以满足实际需求。针对上述问题，本文提出以时间重合度为调节变量、通过自适应权重动态平衡局部相似度特征与全局形态特征贡献的航迹关联方法；并针对传统协方差加权方法依赖精确协方差估计的问题，提出一种基于混合时序网络 CNN-LSTM 的航迹融合方法，同时预测自适应融合权重与位置修正量。实验结果表明：在航迹关联任务中，本文方法关联正确率达 96.68%，优于支持向量机等对比方法；在航迹融合任务中，协方差失配场景下均方根误差相比最优线性无偏估计方法降低了 21.7%。

关键词：多传感器信息融合；航迹关联；航迹融合；时间重合度；CNN-LSTM；海上目标监测

中图分类号：TN953

文献标志码：A

doi：10.11959/j.issn.2096−3750.WLW26187

Distributed Sensor-Driven Track Association and Fusion Method for Low-Altitude Maritime Internet of Things

Wang Qian[1,2], Zuo Yifan[1,2], Jiang Wei[1], Zhu Huijie[3], Zhang Yin[4], Qian Liping[5]

1. Institute of Cyberspace Security, Zhejiang University of Technology, Hangzhou 310023, China

2. Binjiang Institute of Artificial Intelligence, ZJUT, Hangzhou 310051, China

3. The 36th Research Institute of China Electronics Technology Group Corporation (CETC), Jiaxing 314000, China

4. Zhejiang Branch, China United Network Communications Co., Ltd., Hangzhou 310000, China

5. School of Marine Engineering and Technology, Sun Yat-sen University, Zhuhai 519082, China

Abstract: In low-altitude maritime IoT scenarios,UAVs equipped with airborne radar, AIS receivers, and other het- erogeneous sensors are increasingly deployed on demand over maritime areas, each platform generating its own local target track within a distributed sensing network. Associating and fusing these multi-source local tracks is fundamental to accurate target state estimation in low-altitude maritime IoT applications. Two practical difficulties arise: on-demand deployment makes the temporal overlap between track pairs from different UAVs highly variable, while maneuvering flight degrades sensor calibration and renders covariance estimates unreliable —both of which break conventional association and fusion strategies. We tackle these difficulties separately but within a unified pipeline. For track association, the temporal overlap ratio is introduced as an explicit regulating variable, and adap- tive weights are learned to shift the balance between local motion-similarity features and global shape features as

Key words: multi-sensor information fusion; track association; track fusion; temporal overlap degree; CNN-LSTM; maritime target surveillance

收稿日期：XXXX−XX−XX；修回日期：XXXX−XX−XX

overlap changes. For track fusion, we target the core limitation of covariance-based methods —their reliance on accurate covariance estimates —and propose a CNN-LSTM network with dual output heads that simultaneously predicts fusion weights and position corrections, eliminating covariance inputs altogether. On a radar/AIS dataset, the association method reaches a correct-association rate of 96.68%, surpassing SVM and other baselines. Under covariance mismatch, our fusion method cuts RMSE by 21.7% relative to BLUE.

0 引言

我国拥有广阔海域，党的二十大报告明确将“发展海洋经济、保护海洋生态环境、加快建设海洋强国”列为国家战略任务 [1]。准确获取船舶目标的实时位置信息，对非法船舶监管、外籍船舶监控等工作具有重要意义 [2, 3]。当前海上目标监测依托由岸基雷达（Radar）、船舶自动识别系统（AIS，Automatic Identification System）、高频地波雷达（HFSWR，High Frequency Surface Wave Radar）等固定传感器构建的基础感知网络 [4, 5]，这些固定站点各有优势，但受限于部署位置，存在覆盖盲区且难以对特定海域进行灵活响应。近年来，低空无人机（UAV，Unmanned Aerial Vehicle）凭借机动灵活、按需部署的特点， 作为灵活感知节点融入海洋物联网监测体系：搭载机载雷达、AIS 接收机等传感器的 UAV 可按任务需求飞赴重点海域，对目标实施独立跟踪并生成局部航迹，有效补充固定传感器的覆盖短板 [6, 7]。当多架 UAV 协同执行监测任务时，各平台在各自覆盖范围内对同一目标独立感知，产生来自不同平台的多条局部航迹；对这些多源局部航迹进行关联（判断是否来自同一目标）与融合（合并为精度更高的融合结果），是实现高精度目标状态估计的核心任务，也是本文的研究对象。然而，低空物联网场景与岸基固定传感器网络存在显著差异，由于 UAV 动态场景导致各平台间航迹时间重合度差异显著，以及机动飞行引入传感器标定偏差使误差协方差难以精确获取，导致传统航迹关联与融合方法难以直接移植。

在基于无人机的分布式多传感器融合架构下，航迹关联（T2TA，Track-to-Track Association）是实现海上多目标跟踪的前提。现有方法大致分三类：统计假设检验方法，轨迹形态相似度方法以及深度学习的方法，但上述方法在低空 UAV 监测场景下均存在明显局限。统计假设检验方法包含 K 近邻、全局最近邻、联合概率数据关联及多假设跟踪等算法[8-11]。其判决以精确误差协方差为前提；UAV 机动飞行引入的动态标定偏差使协方差估计长期失准，此类方法在低空场景中性能难以保证。轨迹形态相似度方法以 DTW 、Hausdorff 距离等度量全局运动相似性 [12, 13]。对协方差依赖较弱，但固定特征策略无法感知时间重合度的变化；UAV 动态场景造成的时间重合度持续变化使全局特征在低重合度下受非重合段数据污染，可靠性严重受限。深度学习类方法通过端到端训练提升了关联特征的判别能力：CNN 方法利用一维卷积提取局部时序运动模式 [14-15] ；图神经网络将多传感器航迹建模为异构图，显式建模航迹间拓扑关系 [16-18]；异步采样匹配方法解决了不同传感器采样率不一致下的时序对齐问题[19-21]；跨模态融合方法通过特征投影或对比学习处理雷达与 AIS 等异质传感器的匹配 [22-25]。然而，上述方法均未将时间重合度纳入特征可靠性建模，尤其在 UAV 动态监测场景下，时间重合度持续变化，特征判别效用随重合度显著波动，关联性能不稳定[26]。

完成航迹关联后，航迹融合（T2TF ，Track-to- Track Fusion）将不同无人机采集到的局部航迹合并为精度更高的融合结果。多传感器数据融合在海上目标跟踪领域已有广泛应用，AIS 与岸基雷达联合使用以及 HFSWR 超视距探测均已积累丰富工程经验 [27-30]; 上述工作多聚焦于量测级融合，航迹级融合无需实时传输原始量测数据，更适合大规模分布式物联网部署。在融合方法层面，传统线性加权类方法以最优线性无偏估计（BLUE，Best Linear Unbi- ased Estimation）和协方差交叉（CI，Covariance In- tersection）为代表，分别在误差协方差已知和互相关未知两种前提下实现最优线性融合 [31] ；但两者均高度依赖精确协方差估计，一旦传感器标定偏差或或目标机动导致协方差失配，加权策略失效、性

能大幅退化。数据驱动类方法以 CNN、时序卷积网络（TCN ， Temporal Convolutional Network）等时序网络为代表，通过学习历史窗口特征

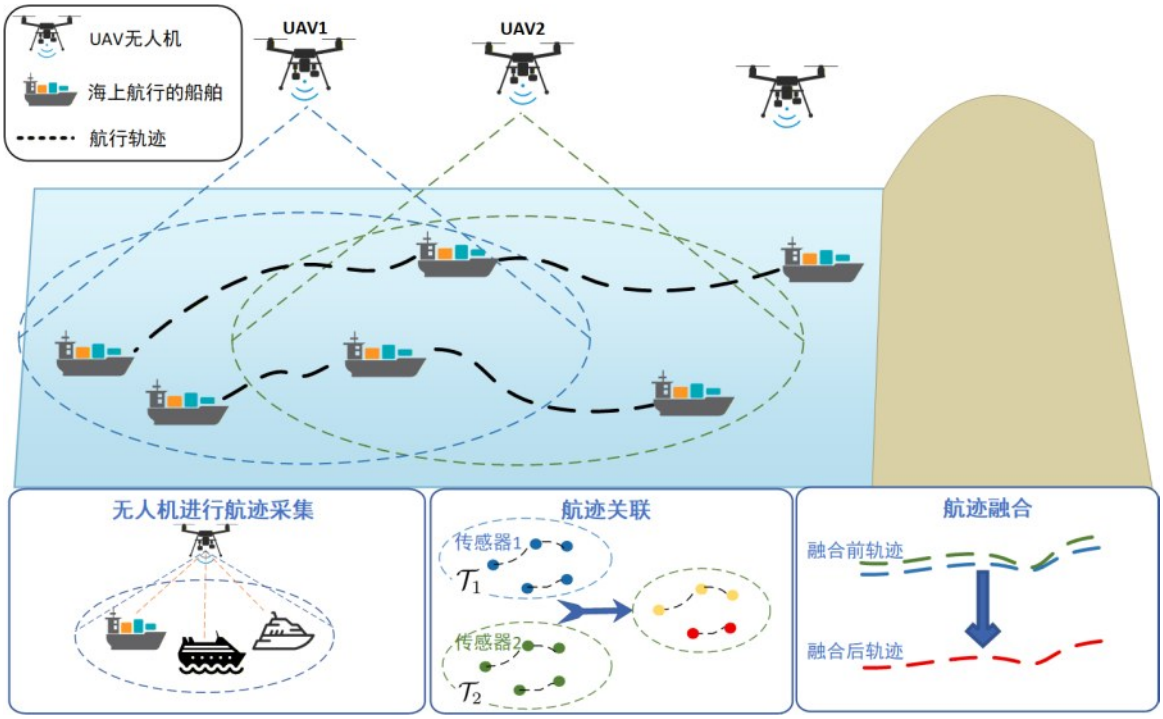

图 1　双无人机海上目标探测场景示意图：两架无人机独立探测目标，分别生成局部航迹 $T1$ 和 $T2$。

自适应确定融合权重，对协方差误差具有天然鲁棒性 [32, 33]；但直接回归融合位置的无约束端到端结构容易引入整体性位置漂移，制约了方法在实际系统中的可靠性。

针对上述问题，本文聚焦于海上目标监测场景，基于无人机分布式多传感器融合架构，对航迹关联与融合方法开展了系统研究，主要工作与贡献如下：

（1）提出以时间重合度为调节变量、动态平衡局部与全局特征贡献的航迹关联方法，有效解决不同重合度场景下的关联不稳定问题；

（2）提出基于 CNN-LSTM 双头输出的航迹融合方法，通过同时预测融合权重与位置修正量替代协方差加权，有效规避对精确协方差估计的依赖，提升了方法在传感器标定偏差场景下的鲁棒性；

（3）在 MTAD 雷达/AIS 数据集上对上述方法进行实验验证：航迹关联任务中，本文方法在不同时间重合度场景下整体正确率达 96.68%，优于支持向量机、DTW 等对比方法；航迹融合任务中，协方差失配场景下 RMSE 相比 BLUE 方法降低 21.7%。

1　动态特征平衡驱动的航迹关联方法

1.1　问题建模

航迹关联的核心是判断来自不同传感器的两段航迹是否源于同一物理目标。本节将这一判断过程形式化为二元假设检验问题，明确了算法的输入、输出和评判标准，为后续特征提取与判决方法提供统一的数学语言。图 1 给出了双无人机海上目标探测场景示意图。

设由不同无人机所搭载的传感器 1 和传感器 2 分别感知到 N 和 M 条航迹，航迹集合分别为 $\mathcal{T}_1 = \{T_{1,i}\}_{i=1}^{N}$ 和 $\mathcal{T}_2 = \{T_{2,j}\}_{j=1}^{M}$，每条航迹为带时间戳的二维位置序列：

$$T_{1,i} = \left\{(\hat{p}_{1,i,k}, t_{1,i,k})\right\}_{k=1}^{n}, \quad T_{2,j} = \left\{(\hat{p}_{2,j,k}, t_{2,j,k})\right\}_{k=1}^{m} \quad \#(1)$$

其中，$\hat{p}_{s,i,k} \in \mathbb{R}^2 (s = 1,2)$ 为传感器 s 第 i 条航迹第 k 个时间步的二维位置估计，$t_{s,i,k}$ 为对应时间戳，n 和 m 分别为航迹 $T_{1,i}$ 和 $T_{2,j}$ 的长度即传感器的采样点数。对任意待关联航迹对 $(T_{1,i}, T_{2,j})$，存在两种假设：H1（关联，属于同一目标）和 H0（不关联）。

1.2　时间不对齐下的航迹预处理

实际系统中，不同传感器的采样周期和启动时间各不相同，导致待关联航迹的时间戳往往错位。若直接对原始航迹计算距离，错位的时间点对会引

入系统性偏差，严重影响特征可靠性。因此，任何特征计算的前提是解决时间对齐问题。本节首先提取两条航迹的时间重合区间，将时间上无交集的航对

直接排除；对有重合的航迹对，则通过中值滑窗滤波消除异常点后，以线性插值将航迹重采样到统一时间格点，为后续所有相似度度量提供一致的计算基础。

定义时间重合区间$[ts, te]$如下：

$$[t_s, t_e] = [\max(t_{1,i,1}, t_{2,j,1}), \min(t_{1,i,n}, t_{2,j,m})] \#(2)$$

其中，t_s为两条航迹时间段的重合起始时刻，t_e为重合终止时刻。

图2 给出了三种典型的时间重合情况。无重合时直接判为不关联（图 2a）；重合度较短时局部特征样本不足（图 2b）； 重合度较长时局部特征更加可靠（图 2c）。当$t_s > t_e$时直接判为不关联。在重合区间内，先对异常值进行中值滑窗替换，再通过线性插值实现时间对齐，得到统一时间格点上的航迹对$(\tilde{T}_{1,i}, \tilde{T}_{2,j})$。

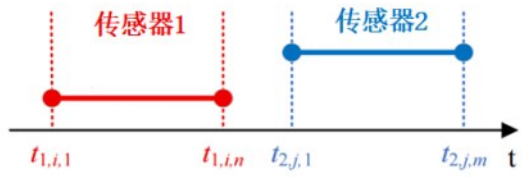

(a)　无时间重合区间（$ts > te$，直接判为不关联）

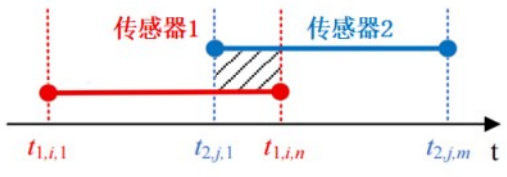

(b)　时间重合度较短（局部特征样本不足，可靠性低）

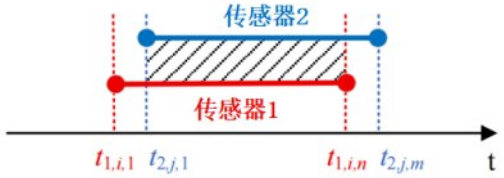

(c)　时间重合度较长（局部特征充分，可靠性高）

图 2　三种典型时间重合度情况示意图（斜线区域为重合段）

1.3　局部与全局相似度特征提取

判断两条航迹是否关联时，单一的距离度量往往难以全面反映航迹间的关联程度，现有的几种度量方式如：平均欧氏距离对整体偏差敏感但忽略局部抖动，豪斯多（Hausdorff ）夫距离能捕捉最坏情况偏差但对异常点脆弱，全局形态指标则在重合度较低时会受到非同源数据污染。为了鲁棒地描述关联性，本节从两个互补维度构建特征：一是基于对齐后的局部特征，刻画短时的匹配程度；二是基于完整原始航迹的全局特征，刻画整体运动趋势的相似度。两类特征相互补充，构成多维相似度描述，也为后续自适应时间重合度调节机制提供依据。

局部特征。局部特征基于时间对齐后的重合段构建，局部特征向量$\boldsymbol{F}_{local}$定义为：

$$\boldsymbol{F}_{local} = [D_e^{(i,j)}, D_h^{(i,j)}, D_f^{(i,j)}] \#(3)$$

其中，$[D_e^{(i,j)}, D_h^{(i,j)}, D_f^{(i,j)}]$为三类距离度量：

（1）为了反映平均位置偏差，我们定义平均欧氏距离$D_e^{(i,j)}$：

$$D_e^{(i,j)} = \frac{1}{L}\sum_{l=1}^{L} \| \hat{p}_{1,i}(t_l) - \hat{p}_{2,j}(t_l) \| \#(4)$$

其中，L为重合区间内均匀对齐的时间格点总数，$t_l (l = 1, \cdots, L)$为第l个格点时刻，$\hat{p}_{s,i}(t_l)$为航迹$T_{s,i}$在t_l处经线性插值得到的二维位置估计。

（2）为了捕捉最不匹配点对，我们定义 Hausdorff 距离$D_h^{(i,j)}$：

$$D_h^{(i,j)} = \max\{ d_h(\tilde{T}_{1,i}, \tilde{T}_{2,j}), d_h(\tilde{T}_{2,j}, \tilde{T}_{1,i}) \} \#(5)$$

其中，$d_h(A,B) = \max\limits_{a \in A} \min\limits_{b \in B} \| a - b \|$ 为从点集A到点集B的有向 Hausdorff 距离，$\tilde{T}_{s,i}$为对齐到统一时间格点后的航迹点集

（3）为了反映形态相似性，我们定义分段加权 Fréchet 距离$D_f^{(i,j)}$，将航迹均匀划分为R个子段计算加权平均。

全局特征。全局特征则基于完整原始航迹构建，全局特征向量$\mathbf{F}_{global}$定义为：

$$\mathbf{F}_{global} = [D_c^{(i,j)}, D_{bbox}^{(i,j)}, D_d^{(i,j)}] \#(6)$$

其中，重心距离$D_c^{(i,j)}$用于衡量整体中心位置差异；包围盒距离$D_{bbox}^{(i,j)}$用于衡量空间覆盖范围差异；标准化动态时间规整距离（Dynamic Time Warping，DTW）$D_d^{(i,j)}$用于衡量整体形态相似性。

1.4　局部与全局特征动态平衡

上一节构建的局部与全局特征虽然互补，但存在一个根本性问题：二者的可靠性都高度依赖于时间重合度R_{ov}。当重合度极低时，重合段过短，局

部特征因样本不足而方差极大，难以反映真实的相似性；此外，全局特征所使用的完整航迹中包含大量非重合段，这些非同源数据会稀释两航迹共同行经区域的匹配信号。反之，当重合度很高时，局部特征更为精确，全局特征的优势反而不明显。因此，一个好的关联系统应当能够根据重合度动态调整两类特征的置信权重。为了更好的动态调节两类特征的置信权重，我们引入基于Sigmoid函数的时间重合度调节机制，通过贝叶斯优化在验证集上自动学习调节参数，使系统在不同时间重合度场景下均能自适应调节不同特征的权重。

（**1**）时间重合度调节。首先，我们定义了时间重合度 $R_{ov}^{(i,j)}$：

$$R_{ov}^{(i,j)} = \frac{t_e - t_s}{\max(t_{1,i,n}, t_{2,j,m}) - \min(t_{1,i,1}, t_{2,j,1})} \#(7)$$

其中，分母为两条航迹时间跨度的并集长度 $(\max(t_{end_A}, t_{end_B}) - \min(t_{start_A}, t_{start_B}))$，取值范围为 $[0,1]$，短航迹对和长航迹对均可适用。

（**2**）贝叶斯优化加权融合。其次，我们对局部和全局特征分别进行加权融合。以 $r \in \{1,2,3\}$ 为特征序号，局部特征 $D_{\mathrm{loc},r}^{(i,j)}$ 依次对应 $D_e^{(i,j)}$、$D_h^{(i,j)}$、$D_f^{(i,j)}$；全局特征 $D_{\mathrm{glo},r}^{(i,j)}$ 依次对应 $D_c^{(i,j)}$、$D_{\mathrm{bbox}}^{(i,j)}$、$D_d^{(i,j)}$，局部和全局特征分别进行加权融合定义如下：

$$S_{local} = \sum_{r=1}^{3} \alpha_r D_{\mathrm{loc},r}^{(i,j)}, \quad S_{global} = \sum_{r=1}^{3} \beta_r D_{\mathrm{glo},r}^{(i,j)} \#(8)$$

其中，权重 $\{\alpha_r\}$ 和 $\{\beta_r\}$ 满足归一化约束 $\sum_{r=1}^{3} \alpha_r = 1, \sum_{r=1}^{3} \beta_r = 1$。

接着，我们引入Sigmoid函数 $w(\cdot)$ 构造权重调节函数：$w(R_{ov}) = a + (b - a) \cdot \sigma(\gamma(R_{ov} - \delta)) \#(9)$ 其中，$\sigma(\cdot)$ 为标准Sigmoid函数。参数通过贝叶斯优化在验证集上以最大化分类准确率为目标学习，使用高斯过程代理模型，搜索空间：$a \in [0, 0.3]$，$b \in [0.7, 1]$，$\gamma \in [5, 20]$，$\delta \in [0.3, 0.7]$，最大迭代50次，最终取得参数值 $a = 0.12$，$b = 0.88$，$\gamma = 11.3$，$\delta = 0.50$。参数敏感性分析表明，在 $\gamma \in [8, 15]$、$\delta \in [0.4, 0.6]$ 范围内，关联正确率波动不超过0.5%，方法具有较好的鲁棒性。值得一提的是，贝叶斯优化所学参数 $\{a,b,\gamma,\delta\}$ 刻画的是Sigmoid调节曲线的整体形态，与具体场景的轨迹细节无关，因此具备较强的跨分布迁移能力，即便目标场景的时间重合度分布与训练域存在显著差异，固定参数亦无需重新搜索（详见第3节表3）。最后，利用 $w(\cdot)$ 对局部和全局得分进行自适应调节：

$$S_{local-adj} = S_{local} \cdot (1 - w(R_{ov})) \#(10)$$

$$S_{global-adj} = S_{global} \cdot w(R_{ov}) \#(11)$$

将上述两个调节得分与原始得分、时间重合度拼接，构成5维最终特征向量：

$$\boldsymbol{S}_{fused} = [S_{local-adj}, S_{global-adj}, S_{local}, S_{global}, R_{ov}] \#(12)$$

其中，$S_{local-adj}$ 与 $S_{global-adj}$ 为经时间重合度调节后的加权得分，直接反映当前重合度下两类特征的有效贡献；S_{local} 与 S_{global} 为未经调节的原始相似度得分，保留各类特征独立的判别信息，避免单一调节路径导致信息损失；Rov 显式提供时间重合度上下文，使分类器能进一步学习得分与重合度之间的非线性交互关系。将 $\mathbf{S}_{fused}$ 输入随机森林（Random Forest, RF）分类器进行最终关联判决：

$$y_{i,j} = \mathrm{RF}(\mathbf{S}_{fused}) \in \{0,1\} \#(13)$$

RF采用100棵决策树（n_estimators通过袋外误差曲线确定），整体方法采用5折交叉验证评估。图3展示了特征重要性随时间重合度的变化规律。当时间重合度较低时，两条航迹仅在较短时间段内重叠，局部特征直接反映了重合区间内两条航迹的空间接近程度，对同源判别最为直接；而全局特征所使用的完整航迹中包含大量非重合段数据，这些非同源段会引入噪声，使其判别力相对有限，因此局部特征重要性在低重合度区间较高。随着时间重合度升高，重合区间逐渐覆盖航迹的大部分，局部特征所能提供的信息已被全局特征充分包含；同时，全局特征（DTW、包围盒、重心距离等）能够更完整地刻画两条航迹的整体运动形态差异，判别能力随之增强，因此全局特征重要性在高重合度区间占主导。上述规律验证了引入时间重合度调节变量、动态平衡两类特征贡献的必要性。

2　基于 CNN-LSTM 的航迹融合方法

2.1　问题建模

完成航迹关联后，融合系统需要将来自两个传感器的、对同一目标的观测序列合并为精度更高的融合航迹。BLUE等传统方法在此依赖两个假设：传感器噪声协方差已知且准确、目标运动模型与滤波器匹配。然而在实际海上物联网场景中，传感器标定偏差、海况变化和目标机动均会导致这两个假设失效，进而使协方差加权产生系统性偏差。为

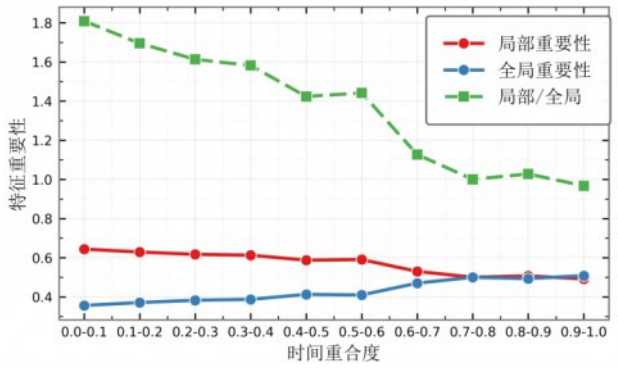

图 3　特征重要性（随机森林 feature_importances_ 归一化值）随时间重合度的变化。

此，本文转向数据驱动路线，设计端到端学习框架以自适应替代协方差加权。框架的第一步是构建能够隐式编码传感器可靠性的多层次特征：速度与航向差分越大意味着航迹越不稳定，应被赋予更低权重；跨航迹差异特征则使模型在协方差失配时能够依据运动一致性而非协方差大小来动态分配融合比例。

图4给出了本文CNN-LSTM融合方法的整体框架：两条关联后的局部航迹输入特征构建模块，经CNN层提取局部时序特征、LSTM层建模长期依赖后，由双头输出层同时预测融合权重与位置修正量，最终合成高精度融合航迹。

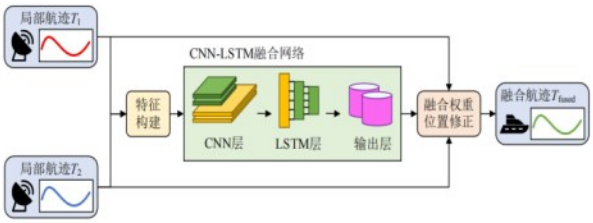

图4　CNN-LSTM航迹融合方法整体框架

设经过关联的两条局部航迹 T_1、T_2 经时间对齐后，传感器 $i(i=1,2)$ 在第 k 个时间步的状态向量 $\hat{\mathbf{x}}_{i,k}$ 为：

$$\hat{\mathbf{x}}_{i,k}=[\hat{x}_{i,k},\hat{y}_{i,k},\hat{v}_{i,k},\hat{c}_{i,k}]^T \#(14)$$

其中，$\hat{x}_{i,k}$、$\hat{y}_{i,k}$ 为经纬度位置估计，$\hat{v}_{i,k}$ 为速度估计，$\hat{c}_{i,k}$ 为航向角估计（取值[0°,360°)）。

以当前时刻 k 为基准，截取长度为 $W=20$ 的历史滑动窗口，由两条航迹的状态序列派生出 11 维特征矩阵 $\mathbf{S}_k \in \mathbb{R}^{W\times 11}$，具体分为三类：

（1）位置特征（4维）：两传感器在各时间步的经纬度位置估计 $(\hat{x}_{1,k},\hat{y}_{1,k},\hat{x}_{2,k},\hat{y}_{2,k})$，为网络直接提供空间坐标信息。

（2）运动平滑性特征（4维）：各传感器速度差分 $\Delta\hat{v}_{i,k}=\hat{v}_{i,k}-\hat{v}_{i,k-1}$ 与航向差分 $\Delta\hat{c}_{i,k}=\hat{c}_{i,k}-\hat{c}_{i,k-1}$（$i=1,2$，共4维）。差分越大表明该传感器观测在当前时刻越不稳定，模型据此隐式降低其融合权重。

（3）跨航迹差异特征（3维）：两航迹的位置差 $\|\hat{\boldsymbol{p}}_{1,k}-\hat{\boldsymbol{p}}_{2,k}\|$、速度差 $|\hat{v}_{1,k}-\hat{v}_{2,k}|$ 与航向差 $|\hat{c}_{1,k}-\hat{c}_{2,k}|$，直接刻画双传感器在同一时刻观测的运动吻合程度，帮助模型在协方差失配时依据运动一致性而非协方差大小确定融合权重。所有特征在送入网络前均经过零均值归一化处理。

2.2　时序特征编码

特征矩阵 $\mathbf{S}_k$ 经CNN-LSTM两阶段编码后输出时序表征，为双头输出提供融合依据。CNN模块采用空洞卷积（空洞系数 $d_1=1,d_2=2$）与组归一化（GroupNorm）结构，在长度 $W=20$ 的窗口内提取局部运动模式：

$$\mathbf{Z}_k=\mathrm{CNN}(\mathbf{S}_k)\in\mathbb{R}^{W\times C} \#(15)$$

其中，$C=128$ 为卷积通道数。在本文场景中，若某传感器在当前时间窗内出现速度或航向的异常抖动，CNN捕获的局部模式可使模型相应降低该传感器的融合权重。然而，海上目标运动模式常在较长时间尺度上发生切换（如匀速直线进入协调转弯阶段），单一窗口内的局部信息不足以捕捉这种持续性变化。为此，在CNN之后串联2层堆叠LSTM（隐藏层维度H = 64，Dropout系数0.1），利用门控记忆机制跨时间步保留历史依赖：

$$h_k=\mathrm{LSTM}(\mathbf{Z}_k)\in\mathbb{R}^{H} \#(16)$$

CNN与LSTM二者级联使模型能够同时感知窗口内传感器的短时抖动与跨窗口的运动模式切换，为后续双头输出提供完整的时序表征 h_k。其中，空洞系数 $d_1=1$ 与 $d_2=2$ 的组合使CNN在不增加参数量的前提下同时捕获逐帧位移变化与两步速度趋势，而组归一化在批量较小的海上目标数据场景下相比批归一化具有更稳定的特征分布，进一步提升了编码器对稀疏采样场景的适应性。

2.3　显式融合结构设计

若网络直接输出融合位置（如对比方法TCN-p），在协方差失配场景下容易将训练集的系统性偏移误学为融合规律，产生整体性位置漂移。为此，本文设计双头显式融合结构：时序表征 h_k 经两个独立全连接层，分别预测两传感器的融合权重原始

logit ($\hat{\alpha}_{1,k}$,$\hat{\alpha}_{2,k}$) 和位置修正量原始输出 ($\hat{b}_{x,k}$,$\hat{b}_{y,k}$)，拼接为4维向量：

$$\theta_k = [\hat{\alpha}_{1,k}, \hat{\alpha}_{2,k}, \hat{b}_{x,k}, \hat{b}_{y,k}] \#(17)$$

网络输出的原始值需经结构约束变换为物理可解释的参数。权重 logit 经 Softmax 归一化，确保 $\alpha_{1,k} + \alpha_{2,k} = 1$，使融合结果始终为两传感器位置的凸组合；修正量原始输出经 Tanh 限幅至 $[-\Delta_{\max}, \Delta_{\max}]$ ($\Delta_{\max} = 50$ m)，防止过大的修正量将融合结果拉离两条原始航迹，经过上述处理我们得到了归一化之后的融合权重 $[\alpha_{1,k}, \alpha_{2,k}]$ 以及位置修正量 $[b_{x,k}, b_{y,k}]$：

$$[\alpha_{1,k}, \alpha_{2,k}] = \mathrm{Softmax}([\hat{\alpha}_{1,k}, \hat{\alpha}_{2,k}]) \#(18)$$

$$[b_{x,k}, b_{y,k}] = \tanh([\hat{b}_{x,k}, \hat{b}_{y,k}]) \cdot \Delta_{\max} \#(19)$$

用上述归一化权重对两传感器位置 $\hat{\boldsymbol{p}}_{s,k} \in \mathbb{R}^2 (s = 1,2)$ 加权求和，再叠加残余修正量，得到最终融合位置：

$$\hat{\boldsymbol{p}}_{fused,k} = \alpha_{1,k}\hat{\boldsymbol{p}}_{1,k} + \alpha_{2,k}\hat{\boldsymbol{p}}_{2,k} + [b_{x,k}, b_{y,k}]^T \#(20)$$

其中，修正项用于补偿传感器标定偏差或运动模型失配引起的残余系统偏差。上述设计将”凸组合加权”与”小量修正”的物理先验编码进网络结构，使模型学习目标从无约束的黑盒回归转变为有边界的参数估计，从根本上规避了 TCN-p 整体性漂移问题。

2.4　联合损失函数与训练

若仅以位置均方误差（Mean Squared Error，MSE）作为训练信号，模型可能在逐点位置误差最小化的同时忽视航迹的运动连续性，导致相邻时间步之间出现方向突变。为此，本文设计由位置误差项与方向正则化项构成的联合损失函数 $\mathcal{L}$：$L = \mathcal{L}_{\text{pos}} + \lambda_{\text{dir}}\mathcal{L}_{\text{dir}} \#(21)$ 其中，$\mathcal{L}_{\text{pos}}$ 为主导项，直接度量融合位置与真值之间的误差；$\mathcal{L}_{\text{dir}}$ 为辅助正则化项，惩罚融合航向偏差，约束轨迹的方向平滑性；λ_{dir} 为平衡两项贡献的权重系数。位置误差损失 $\mathcal{L}_{\text{pos}}$ 定义为对有效时间步取均值的加权 MSE：

$$\mathcal{L}_{pos} = \frac{1}{\sum_k m_k} \sum_k m_k \| \hat{\boldsymbol{p}}_{fused,k} - \boldsymbol{p}_{gt,k} \|^2 \#(22)$$

其中，$p_{gt,k} \in R^2$ 为第 k 步的真值位置，$m_k \in \{0,1\}$ 为有效性掩码（$m_k = 1$ 表示该步真值可用，否则为 0，用于处理航迹长度不一致的情形）。方向正则化损失 $\mathcal{L}_{\text{dir}}$ 对融合航向与真值航向之间的角度偏差进行惩罚：

$$\mathcal{L}_{dir} = \frac{1}{\sum_k m_k} \sum_k m_k (\Delta\phi_k)^2 \#(23)$$

其中，$\Delta\phi_k$ 为融合航向 ϕ_k^{fused} 与真值航向 ϕ_k^{gt} 的归一化角度差，采用 *atan*2 形式以消除角度回绕问题。

$$\Delta\phi_k = atan2(\sin(\phi_k^{fused} - \phi_k^{gt}), \cos(\phi_k^{fused} - \phi_k^{gt})) \# (24)$$

权重 λ_{dir} 通过网格搜索在 $\{0.01, 0.05, 0.1, 0.5\}$ 中确定，实验结果表明 $\lambda_{\text{dir}} = 0.1$ 时验证集 RMSE 最低，在引入方向平滑约束的同时不过度牺牲位置精度。网络采用 Adam 优化器（学习率 1×10^{-4}）训练 50 轮，批大小 32，在 RTX 4060 Ti 上完成训练。

3　实验结果与分析

3.1　航迹关联实验

本研究采用多源航迹关联数据集（MTAD）[34]，以真实 AIS 航迹为基础，添加不同类型噪声构建包含两信源的模拟航迹。从 100 个场景中选取两两组合，筛选得到 12 204 组样本（关联对 4 068 组，不关联对 8 136 组），划分训练集与测试集时以场景为单位进行 8:2 划分。确保同一场景的全部样本对仅出现在同一子集中，避免数据泄露。

对比方法参数配置。为保证可复现性，表 1 列出了各对比方法的关键参数配置，所有方法在相同特征集和数据划分下训练与评估。

表 1　关联对比方法参数配置

方法	关键参数
阈值法	欧氏距离阈值 τ=1000 m，固定决策边界
LR	C = 1 .0 ，solver=lbfgs ，max_{iter}=1000
SVM	RBF 核，C=1 .0 ，γ=scale（sklearn 默认）
RF	n_estimators=100（袋外误差确定），5 折交叉验证

评估指标：评价航迹关联性能主要依据关联正确率 P_{CA} 以及关联错误率 P_{FA}。P_{CA} 衡量真实关联对被正确识别的比例，P_{FA} 衡量预测关联结果中误判的比例，定义如下：

$$P_{\text{CA}} = \frac{TP}{TP + FN}, \quad P_{\text{FA}} = \frac{FP}{FP + TP} \#(25)$$

其中，*TP* 为真正例（预测关联且实际关联），*FP* 为假正例（预测关联但实际不关联），*FN* 为假负例（预测不关联但实际关联）。

特征重要性分析。将时间重合度按 0.1 步长划分为 10 个区间，分析两类特征重要性随时间重合

度的变化规律，如图3 所示。结果表明：在低重合度区间（$R_{ov} < 0.5$），局部特征的归一化重要性均值高于全局特征，这是因为重合段较短时，局部特征能直接捕捉目标在共同观测时段内的精确位置匹配程度，判别信号最为直接。随着重合度升高，二者重要性在$R_{ov} \approx 0.5$附近发生交叉，高重合度区间（$R_{ov} > 0.6$）全局特征逐渐主导，因为此时全局轨迹形态已足够充分。这一规律印证了本文以$\delta = 0.50$为 Sigmoid 函数过渡中心的参数设计合理性。

不同时间重合度分区间性能对比。表2给出了低（0% - 30%）、中（30% - 70%）、高（70% - 100%）三个时间重合度区间下的性能对比。从分区结果来看，自适应方法在低重合度区间（0% - 30%）将 PCA 从 RF（局部）的 85.29% 提升至 95.45%（提升 10.16pp），证明在重合段较短、局部特征可靠性不足时，通自适应权重动态降低局部特征比重并引入全局特征能有效稳定关联判决。中重合度区间（30% - 70%）自适应方法达 97.28%，高重合度区间（70% - 100%）更进一步达到 99.08%，三区间均呈单调改善趋势，验证了自适应动态权重调节机制能在全重合度范围内保持鲁棒性。

表 2　不同时间重合度区间下的关联性能对比

重合度	方法	*P*CA (%)	*P*FA (%)
低（0 - 30%）	RF（局部）	85.29	17.57
	RF（局部 + 全局）	93.85	18.56
	RF（自适应）	**95.45**	**17.55**
中（30 - 70%）	RF（局部）	83.38	12.93
	RF（局部 + 全局）	94.86	10.80
	RF（自适应）	**97.28**	**10.55**
高（70 - 100%）	RF（局部）	80.73	11.11
	RF（局部 + 全局）	93.58	8.92
	RF（自适应）	**99.08**	**8.47**

超参数跨分布迁移验证。为验证贝叶斯优化参数在数据集分布变化下的适用性，构造两种分布偏移场景：场景 A（高重合度偏移）通过对高重合度样本（Rov ≥ 0.5）上采样、低重合度样本（Rov < 0.3）降采样模拟 UAV 长时间固定航路巡逻场景，高重合度样本占比从 11.8% 升至 28.7%；场景 B（均匀分布）使各重合度区间样本数均衡。在每种分布下分别采用固定参数（$a = 0.12, b = 0.88, \gamma = 11.3, \delta = 0.50$）和网格重新搜索的最优参数，比较 5 折交叉验证的PCA，结果如表 3 所示

表 3　不同分布下固定参数与重新搜索参数的 *P*CA 对比（%）

数据集	固定参数	最优 γ	最优 δ	重新搜索	差值 (pp)
原始分布	96.68	11.3	0.50	96.68	0.00
场景 A（高重合度）	97.25	12.6	0.50	97.32	+0.07
场景 B（均匀分布）	97.19	11.5	0.50	97.37	+0.18

三种分布下固定参数与重新搜索的 PCA 差值均不超过 0.2 pp，表明贝叶斯优化参数具备较强的跨分布迁移能力，在目标场景重合度分布发生显著变化时无需重新执行参数搜索。这一鲁棒性来源于两点：其一，Sigmoid 函数的过渡区间平缓，参数在搜索空间内的扰动对关联正确率影响有限；其二，RF 分类器本身具有较强的非线性拟合能力，可自适应补偿参数次优性带来的特征差异。

不同关联方法性能对比。表4给出了完整测试集上各方法的性能对比，本文方法在 *P*CA 和 *P*FA 两项指标上均优于所有对比方法。在包含 14 对真实关联航迹的完整复杂场景测试中，本文方法正确关联 13 对，仅 1 对未能正确识别。关联结果可视化如图5所示。

表 4　不同关联方法整体性能对比

方法	*P*CA (%)	*P*FA (%)
阈值法	77.64	17.06
LR	83.91	20.77
SVM	94.10	15.64
RF（本文方法）	**96.68**	**13.61**

3.2　航迹融合实验

仿真设置：构建两部二维传感器的分布式跟踪系统：传感器 1 位于[0, 2500] m（测距误差 20 m，测角误差 0.2°),传感器 2 位于[2500, 0] m（测距误差 10 m，测角误差 0.6°)。目标初始位置随机生成，运动模式为匀速直线（CV）与协调转弯（CT）交替的混合模型[35]，单条航迹持续 120 个时间步（采样间隔 1 s），共生成 2000 条独立航迹样本。

协方差失配场景设置。在失配实验中，额外引入匀加速（CA）运动模式，传感器 1 的测距误差增大至 30 m、测角误差增大至 0.5°, 导致卡尔曼滤

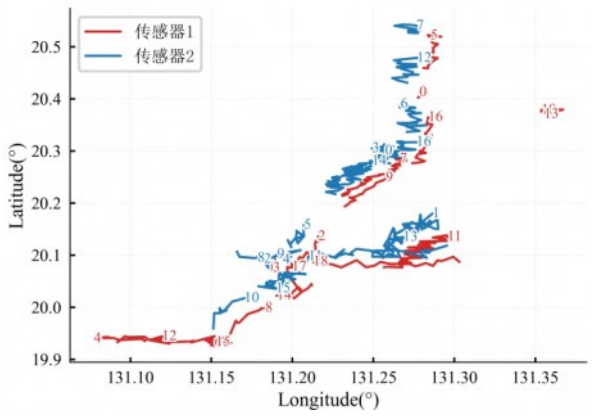

(a)　关联前

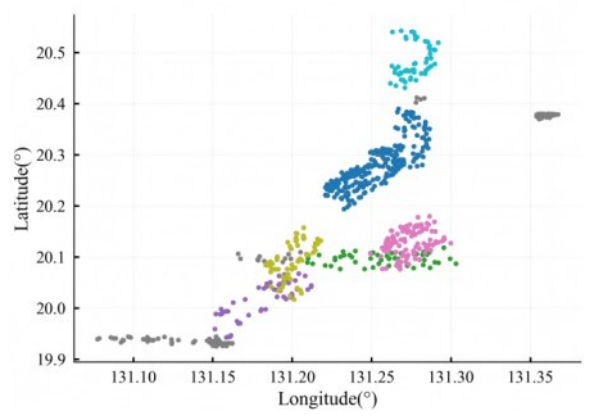

(b)　关联后

图 5　完整场景的航迹关联结果（14 对关联航迹中正确识别 13 对）

波器使用的标称协方差矩阵与真实噪声协方差严重失配。BLUE 和 CI 方法直接使用滤波器输出的标称协方差进行加权，因此在失配条件下性能大幅退化；CNN-LSTM 方法则通过数据驱动方式自适应确定权重，对协方差估计误差具有天然鲁棒性。

评估指标为均方根误差（Root Mean Square-dEr- ror，RMSE）和最大位置误差（MaxError），随机抽样次数为 100 次。

特征消融实验。表 5 从网络结构和输入特征两个维度对本文设计选择进行消融验证。网络结构层面，比较 CNN 单独、LSTM 单独、CNN-LSTM 级联三种配置，以评估两者协同编码的必要性；特征维度层面，在 CNN-LSTM 级联结构下依次从 4 维位置特征扩展至 8 维再到 11 维，以量化各类特征的贡献。

消融结果显示：单独使用 CNN 或 LSTM 的 RMSE 分别为 4.673 m 和 4.585 m，二者性能相近，表明单一模块不足以充分建模局部抖动与跨窗口依

表 5　CNN-LSTM 模型消融实验结果

模型配置	RMSE(m)	MaxError(m)
CNN（单独）	4.673	15.187
LSTM（单独）	4.585	15.063
CNN-LSTM（4D，仅位置）	4.456	14.387
CNN-LSTM（8D ，+ 质量指标）	4.231	13.927
CNN-LSTM（11D ，+ 差异特征）	**4.162**	**13.537**

赖的双重时序信息。引入 CNN-LSTM 级联后，即便仅使用 4 维位置特征，RMSE 即降至 4.456 m；进一步补充运动平滑性特征后降至 4.231 m（较 4D 提升 5.0%）；最终加入跨航迹差异特征后 RMSE 进一步降至 4.162 m（较 4D 提升 6.6%），验证了多层次特征体系的逐步贡献。MaxError 从 4D 的 14.387 m 降至 11D 的 13.537 m，说明跨航迹差异信息亦有助于抑制极端误差峰值。

双头结构消融实验。验证权重头与位置修正头各自的贡献，在相同骨干网络和训练设置下对三种结构进行对比，结果如表 6 所示。

表 6　CNN-LSTM 双头结构消融实验

头结构配置	协方差匹配		协方差失配	
	RMSE (m)	MaxEr- ror (m)	RMSE (m)	MaxEr- ror (m)
仅权重头	7.998	19.309	12.808	48.759
仅修正头	3.255	13.080	8.934	30.635
双头完整模型	**3.137**	**12.104**	**8.276**	**28.622**

去除位置修正头（仅保留权重头）时，匹配场景 RMSE 升至 7.998m（相比完整模型退化 155.0%），失配场景 RMSE 升至 12.808m（退化 54.8%），最大误差在失配场景下更升至 48.759m，两种场景均出现显著退化；去除权重头（仅保留位置修正头，$\alpha = 0.5/0.5$）时，匹配场景 RMSE 为 3.255m（退化 3.8%），失配场景 RMSE 为 8.934m（退化 7.9%），降幅均有限。结果表明，位置修正头（Δ头）是双头结构的主要贡献来源：协方差失配场景下，CV 滤波器对机动运动产生的系统性偏差须依靠显式修正项加以补偿，仅靠权重调节无法消除该偏差；权重头（α头）在此基础上进一步自适应调节传感器置信度，在匹配与失配场景中均提供稳定的边际增益，两者协同使完整模型在两种场景下均达到最优精度。

窗口长度消融实验。表 7 给出了不同观测窗口长度 W 对融合 RMSE 的影响 (Δmax=50m，

λ_{dir}=0.1)。

表 7　不同窗口长度 W 下的融合 RMSE

W(时间步)	RMSE(m)	Std(m)
10	7.234	3.667
15	6.843	3.272
20	**6.488**	**2.838**
25	6.458	2.700
30	6.395	2.674

结果表明，W 从 10 增至 20 时 RMSE 累计 10.3%，Std 从 3.667m 降至 2.838m，精度与预测稳定性均显著提升；W 超过 20 后两项指标边际收益趋于平缓（RMSE 仅再降 1.5%）。这是由于 W=20 已能完整覆盖转弯机动的典型持续时长，继续增大窗口对模型获取新增运动信息的贡献有限，而计算量随 W 线性增大。综合考虑，本文选取 W=20 作为最终配置。

Δ_{max} 依据物理先验设定：低空无人机机载传感器的安装矩阵偏差在典型海况下通常不超过 50m，取 Δ_{max}=50m 已覆盖实际失配范围。λ_{dir} 作为辅助正则项调控航迹平滑性，过小时平滑约束失效，过大时对机动转向段的方向惩罚会抑制模型对目标运动突变的响应；取 λ_{dir}=0.1 在保持直飞段平滑性的同时为机动转向保留足够响应余量。

各方法融合性能对比。表 8 分别在协方差匹配和失配条件下对比了不同航迹融合方法的性能。

表 8　协方差匹配与失配场景下各方法融合性能对比

场景	方法	RMSE(m)	MaxError(m)
匹配	传感器 1	5.346	25.559
	传感器 2	5.379	23.490
	BLUE	3.250	15.165
	CI	3.556	19.405
	CNN-LSTM	**3.137**	**12.104**
失配	传感器 1	13.416	51.548
	传感器 2	14.889	54.996
	BLUE	10.572	35.836
	CI	12.144	47.656
	CNN-LSTM	**8.276**	**28.622**

在协方差匹配场景，本文方法 RMSE 为 3.137 m，较 BLUE 方法 (3.250 m) 降低 3.5%，接近最优线性无偏估计下界，说明在协方差精确已知时数据驱动方法仍能逼近最优估计器。在协方差失配场景，BLUE 退化至 10.572 m，CI 退化至 12. 144 m，而本文方法仅降至 8.276 m，RMSE 相比 BLUE 降低 21.7%，最大误差降低 20. 1%，表明 CNN-LSTM 通过数据驱动方式隐式学习传感器可靠性，对协方差估计误差具有显著鲁棒性。图 6 和图 7 分别给出了两种场景的融合轨迹与位置误差对比曲线。

计算复杂度对比。表 9 给出了各方法在仅使用 CPU（模拟无人机载板计算条件）下的单样本推理延迟实测值。关联方法中，RF（本文方法）单样本延迟为 10.1μs，低于 SVM 的 30.3μs，1000 对候选航迹的批量处理在 10ms 以内完成。融合方法中，CNN-LSTM（本文方法）在批量 N=100 时单样本延迟为 0.129ms，约为 BLUE（0.311 ms）的 42%；随批量规模扩大，批处理优势将进一步凸显。CI 因每步均需数值优化，单样本延迟高达 3.40 ms，实时处理代价最高。上述结果表明本文方法在计算效率上具备一定优势，可支持各无人机节点独立并行执行，与低空分布式感知场景对轻量化板载计算的需求相符。

表 9　各方法 CPU 单样本推理延迟

任务	方法	单样本延迟
航迹关联	阈值法	0.015 μs
	LR	0.084 μs
	SVM	30.3 μs
	RF（本文方法）	**10.1 μs**
航迹融合	BLUE	0.311 ms
	CI	3.40 ms
	TCN-p	0.025 ms
	TCN-w	0.026 ms
	CNN-LSTM（本文方法）	**0.129 ms**

与神经网络方法对比。表 10 在协方差失配场景中与基于 TCN 的方法进行对比。为保证对比公平性，三种神经网络方法（TCN-p、TCN-w、CNN-LSTM）均使用完全相同的 11 维输入特征、相同训练集与超参数搜索策略，仅网络主干结构不同。

值得注意的是，TCN-p（直接回归融合位置的无约束端到端方法）RMSE 高达 16.203 m，甚至超过单传感器（传感器 1: 13.824 m），证明无约束的端到端方法在协方差失配场景下存在严重整体性位置偏移问题。TCN-w 通过仅预测融合权重将 RMSE 降至 9.214 m，但因缺乏位置修正头，仍无

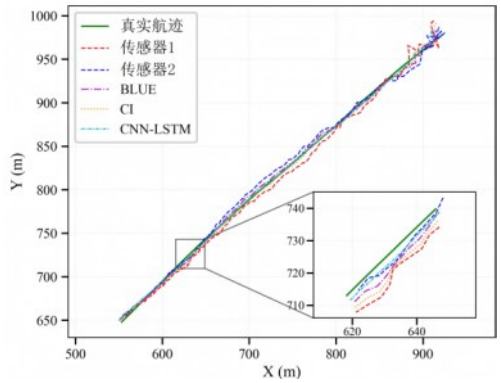

(a)　融合轨迹对比

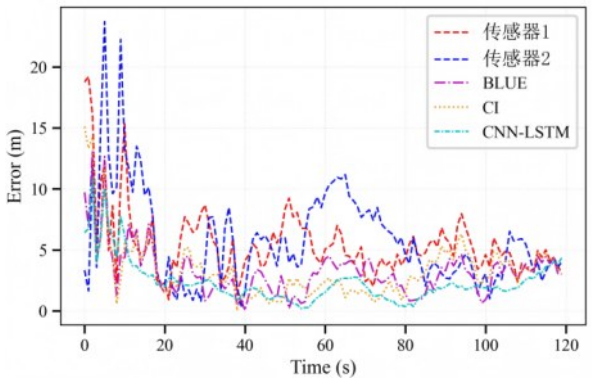

(b)　位置误差曲线

图 6　协方差匹配场景下的航迹融合结果对比

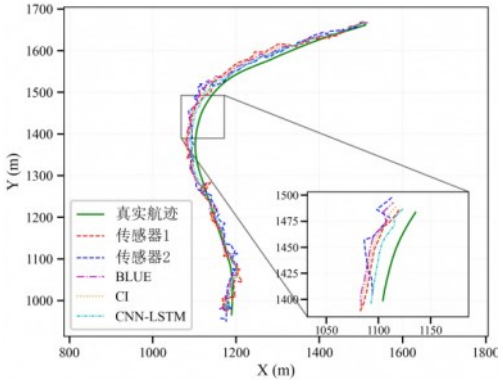

(a)　融合轨迹对比

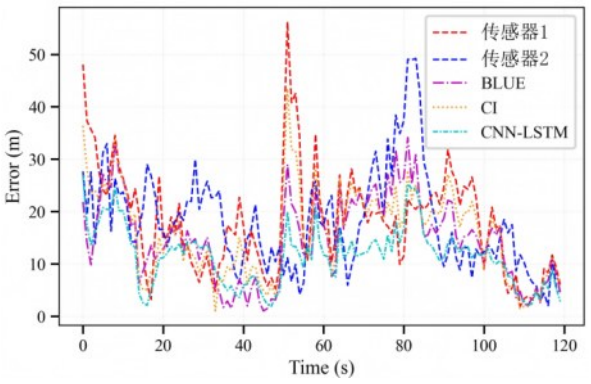

(b)　位置误差曲线

图 7　协方差失配场景下的航迹融合结果对比

法补偿 CV 滤波器对非线性运动（CT 和 CA 机动段）产生的系统偏差，导致其比本文方法（8.343 m）高出 10.4%。本文双头预测结构的核心优势在于：权重头负责自适应传感器置信度调节，而位置修正头(b_x,b_y)通过学习模型失配残差对估计结果进行显式补偿，二者协同使整体偏移得以有效抑制。图8 给出了神经网络方法的位置误差随时间变化曲线对比。

融合权重与修正量分析。通过统计 CNN-LSTM 在 100 次随机抽样仿真中输出的自适应权重，发现在协方差失配场景下，模型自动向测量精度更高的传感器 2 分配更大权重（平均$\alpha_2 \approx 0.63$），并在目标发生 CT 机动的时间段（约第 70 – 80 步）赋予更大的位置修正量 $\|[b_x,b_y]\|$（均值约 2.3 m），有效补偿了 CV 滤波器对非线性运动的模型失配偏差。这表明双头结构在无须显式协方差信息的情况下，依然可以学习到传感器可靠性与运动模型偏差的动态变化规律。

表 10　失配场景下各神经网络融合方法性能对比

方法	RMSE(m)	MaxError(m)
传感器 1	13.824	52.842
传感器 2	15.074	54.995
TCN-p（直接回归位置）	16.203	52.379
TCN-w（预测权重加权）	9.214	32.752
CNN-LSTM（本文）	**8.343**	**28.927**

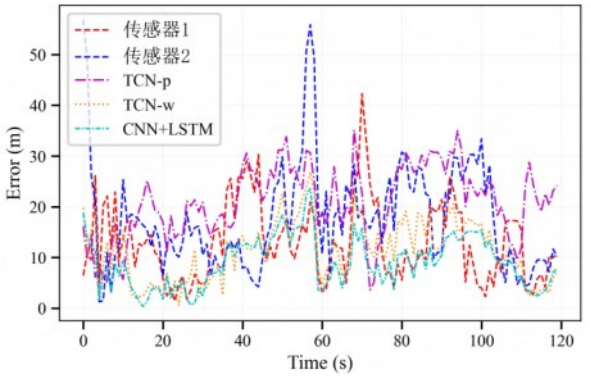

图 8　失配场景下不同神经网络融合方法的位置误差随时间变化对比

4 结 论

本文面向低空海洋物联网场景，研究了低空无人机载异构传感器平台所产生的多源局部航迹的关联与融合问题。首先，提出了以时间重合度为调节变量，动态平衡特征贡献度的航迹关联策略，用于对抗无人机动态场景中的航迹关联性能下降问题；其次，提出了基于 CNN-LSTM 双头输出的航迹融合方法，无需依赖精确协方差信息即可实现稳定的多源航迹整合。实验结果表明，在 MTAD 数据集上，本文关联方法整体正确率达 96.68%，高时间重合度场景下达 99.08%；在协方差失配场景下，融合方法 RMSE 相比 BLUE 方法降低 21.7%，最大误差降低 20. 1%。本文方法为低空无人机组网条件下异构传感器数据的航迹级融合提供了可行方案，后续工作将进一步研究多架无人机协同覆盖下的动态组网与全局航迹管理问题。



王倩，女，浙江工业大学副教授、硕士生导师，主要研究方向包括通信与感知、物联网、智能网络与计算等。近年来长期从事无线通信与感知、智能信号处理、资源调度及相关关键技术研究，主持国家自然科学青年基金、浙江省自然科学基金探索一般项目等科研项目，在国内外学术期刊和会议发表多篇论文。



姜微，女，1991，湖南永州人，浙江工业大学网络空间安全研究院，讲师，博士，主要研究方向为移动通信网络、边缘计算、资源分配。

朱辉杰，男，1987，浙江海宁人，工学博士，



中国电子科技集团公司第三十六研究所、电磁安间安全全国重点实验室，正高级工程师，集团高级专家，主要研究方向包括电磁频谱感知、无线信号处理、软件无线电等。

参考文献：

[1] 张景全. 我国海洋强国建设面临的机遇与挑战 [J]. 人民论坛, 2023(20): 26 – 29.

[2] Fan X, Gu Y, Qin Y, et al. Research on ship target tracking with multi-sensor data fusion[J]. Regional Studies in Ma- rine Science, 2025, 86: 104186.

[3] 何友, 刘瑜, 李耀文, 等. 多源信息融合发展及展望 [J]. 航空学报, 2025, 46(6): 29 – 54.

[4] Golubović D, Erić M, Belić A, et al. High-resolution sea surface target detection using bi-frequency HFSWR[J]. Re- mote Sensing, 2024, 16(18): 3476.

[5] Huang IL, Lee M C, Chang L, et al. Development and appli- cation of an advanced AIS-based ship trajectory extraction framework [J]. Journal of Marine Science and Engineering, 2024, 12(9): 1672.

[6] Khaleghi B, Khamis A, Karray F O, et al. Multisensor data fusion: A review of the state-of-the-art[J]. Information Fu- sion, 2013, 14 (1): 28 – 44.

[7] Zhang P, Li T, Wang G, et al. Multi-source information fu- sion based on rough set theory: A review[J]. Information Fusion, 2021, 68: 85 – 117.

[8] Kanyuch A, Singer R. Correlation of multiple-site track data[J]. IEEE Transactions on Aerospace and Electronic Systems, 1970, 6 (2): 180 – 187.

[9] Bar-Shalom Y. On the track-to-track correlation prob- lem[J]. IEEE Transactions on Automatic Control, 1981, 26(2): 571 – 572.

[10] 曾雅俊, 王俊, 魏少明, 等. 分布式多传感器多目标跟踪方法综述 [J]. 雷达学报, 2023, 12(1): 197 – 213.

[11] Xu P, Cui Y, Xiong W. MH-T2TA: A multiple-hypothesis algo- rithm for multi-sensor track-to-track association with an intelli- gent track score[J]. Frontiers of Information Tech- nology & Elec- tronic Engineering, 2025, 26: 2231 – 2253.

[12] 董凯, 关欣, 王海鹏, 等. 基于序贯修正灰关联度的全局最优航迹关联算法 [J]. 电子与信息学报, 2014, 36(8): 1939 – 1945.

[13] 王号, 沈海平. 基于 Hausdorff 距离的多目标多传感器数据关联 [C]//第一届空中交通管理系统技术学术年会论文集. 2018: 137

– 144.
[14] 崔亚奇, 何友, 唐田田, 等. 一种深度学习航迹关联方法[J]. 电子学报, 2022, 50(3): 759 – 763.
[15] Xiong W, Xu P, Cui Y. HTG-TA: Heterogeneous track graph for asynchronous track-to-track association[J]. IEEE Transactions on Aerospace and Electronic Systems, 2024, 60(5): 7232 – 7250.
[16] Zhang J, Liu Z, Gan Y, et al. Track-to-track association from diverse source ship trajectory based on an improved graph neural network[J]. Applied Ocean Research, 2025, 159: 104598.
[17] Yang Y, Yang F, Sun L, et al. Multi-target association algo- rithm of AIS-radar tracks using graph matching-based deep neural network[J]. Ocean Engineering, 2022, 266: 112208.
[18] Zhou X, Han D. Intelligent track association method based on deep and composite features[C]//2024 China Automa- tion Congress. 2024: 2938 – 2943.
[19] Jin B, Tang Y, Zhang Z, et al. Radar and AIS track associa- tion integrated track and scene features through deep learn- ing[J]. IEEE Sensors Journal, 2023, 23(7): 8001 – 8009.
[20] Xu J, Suo Y, Jiang Y, et al. A fast algorithm for matching AIS trajectories with radar point data in complex environ- ments[J]. Remote Sensing, 2024, 16(23): 4360.
[21] Nurfalah A, Supangkat S H, Mulyana E. Effective & near real-time track-to-track association for large sensor data in maritime tactical data system[J]. ICT Express, 2024, 10(2): 312 – 319.
[22] 张晖, 曾显普, 高亮. 基于改进盖尔-沙普利算法的AIS 与双频地波雷达断裂航迹关联 [J]. 电子与信息学报, 2023, 45(3): 1015 – 1022.
[23] Gao Y, Yang J, Peng C, et al. A track-to-track association algorithm under inconsistent biases[C]//IGARSS 2025 – 2025 IEEE International Geoscience and Remote Sensing Sym- posium. 2025: 8860 – 8864.
[24] Wang M, Zhang W, Liu Z, et al. Track-to-track association based on target position estimate and type of historical infor- mation[C]// 2025 IEEE 9th Advanced Information Technol- ogy, Electronic and Automation Control Conference. 2025: 487 – 492.
[25] Wu Z, Tang P, Xie N, et al. A multi-feature counting- based method with adaptive weighting for radar – AIS track- to-track association[C]//2026 IEEE 8th Eurasian Confer- ence on Information and Computing Sciences. 2026. doi: 10. 1109/ECIS69634.2026.11604454.
[26] 李寅龙, 张天舒. 多传感器航迹关联算法综述 [J]. 舰船电子工程, 2021, 41(8): 44 – 50.
[27] Guo Y, Liu R Q, Qu J, et al. Asynchronous trajectory matching-based multimodal maritime data fusion for vessel traffic surveillance in inland waterways[J]. IEEE Transac- tions on Intelligent Transportation Systems, 2023, 24(11): 12779 – 12792.
[28] Li X, Dunkin F, Dezert J. Multi-source information fu- sion: Progress and future[J]. Chinese Journal of Aeronau- tics, 2024, 37 (7): 24 – 58.
[29] 张曝喜, 田旺, 朱少川, 等. 多源异构航班航迹数据流实时融合方法研究 [J]. 物联网学报, 2020, 4(3): 111 – 121.
[30] Sun S, Lyu H, Dong C. AIS aided marine radar target track- ing in a detection occluded environment[J]. Ocean Engi- neering, 2023, 288: 116133.
[31] Julier S J, Uhlmann J K. A non-divergent estima- tion algorithm in the presence of unknown correla- tions[C]//Proceedings of the American Control Conference, 1997: 2369 – 2373.
[32] 徐嘉辉, 刘宇, 车佳, 等. 基于 CNN 的多目标航迹融合算法 [J]. 现代雷达, 2019, 41(9): 45 – 48.
[33] Wu Y, Chu X, Deng L, et al. A new multi-sensor fusion ap- proach for integrated ship motion perception in inland wa- terways[J]. Measurement, 2022, 200: 111630.
[34] 崔亚奇, 徐平亮, 龚诚, 等. 基于全球 AIS 的多源航迹关联数据集 [J]. 电子与信息学报, 2023, 45(2): 746 – 756.
[35] Singer R A. Estimating optimal tracking filter performance for manned maneuvering targets[J]. IEEE Transactions on Aerospace and Electronic Systems, 1970, 6(4): 473 – 483

[作者简介]



左逸凡，男， 2001，江苏南通人，浙江工业大学硕士研究生，主要研究方向为多模态数据融合、多无人机轨迹规划。



张寅，女，浙江省杭州市，硕士研究生，浙江联通部门副总经理，研究方向为承载网、无线网。