

基于多传感器数据 GM-PHD 滤波算法的 列车 LED 信号灯周期控制

肖彬[†]

(国能朔黄铁路发展有限责任公司, 河北 沧州 062350)

摘 要:随着城市轨道交通的快速发展, 列车 LED 信号灯周期控制的精确性和安全性问题日益凸显。针对传统单一传感器数据控制方法的局限性, 提出一种基于多传感器数据 GM-PHD 滤波算法的列车 LED 信号灯周期控制方法。该方法首先基于噪声加权机制, 将多传感器数据进行融合, 以获得列车状态的准确感知; 其次利用 GM-PHD 滤波算法实现列车运行状态的实时更新和预测, 以达到目标的精准跟踪; 最后将准确的列车运行状态传递给灯控系统, 以动态调整 LED 信号灯周期。实验结果表明, 该方法能显著提高列车运行的精确性和安全性, 为城市轨道交通系统的优化提供了有效支持。

关键词:多传感器数据; GM-PHD 滤波算法; 列车 LED 信号灯; 周期控制; 状态估计; 交通安全; 运行效率

中图分类号: TP391.4

文献标识码: A

Train LED Signal Light Cycle Control Based on Multi Sensor Data GM-PHD Filtering

XIAO Bin[†]

(Guoneng Shuohuang Railway Development Co., Ltd., Cangzhou, Hebei 062350, China)

Abstract: With the rapid development of urban rail transit, the precision and safety problem of train LED signal light cycle control are increasingly prominent. A train LED signal light cycle control method based on multi-sensor data GM-PHD filtering algorithm is proposed to address the limitations of traditional single sensor data control methods. This method is first based on a noise weighting mechanism, which fuses multi-sensor data to obtain accurate perception of train status. Secondly, the GM-PHD filtering algorithm is used to achieve real-time updates and predictions of train operation status to achieve accurate tracking of targets. Finally, the accurate train operation status is transmitted to the lighting control system to dynamically adjust the LED signal light cycle. The experimental results show that this method can significantly improve the accuracy and safety of train operation, providing effective support for the optimization of urban rail transit systems.

Key words: multi sensor data; GM-PHD filtering algorithm; train LED signal lights; cycle control; state estimation; Traffic safety; operating efficiency

随着城市轨道交通系统的持续进步与智能化技术的不断提升, 人们日益关注列车运行的安全保障和效率优化问题^[1-2]。LED 信号灯作为列车运行过程中的关键指示设备, 其周期控制的准确性和

实时性对于确保列车安全运行、优化交通车流具有重要意义^[3]。然而, 传统的信号灯周期控制方法主要依赖于单一的传感器数据, 其在复杂多变的运行环境中往往难以准确反映列车的实际运行状态, 导

致信号灯周期的控制不够精准和灵活。

为了应对这一挑战,学者们针对这些问题展开了广泛的研究。他们探索了多传感器数据融合技术在列车运行状态感知中的应用,以期通过集成多个传感器的观测数据,实现对列车运行状态的全面、准确感知。同时,高斯混合概率假设密度(GM-PHD)滤波算法因其卓越的多目标跟踪性能,受到众多研究者的关注。GM-PHD 滤波算法能够实现对多个目标的同时跟踪和状态估计,具有较高的鲁棒性和精确性,因此在列车运行状态估计和信号灯周期控制中具有潜在的应用价值。文献[4]针对小目标在雷达识别中因回波弱而导致精确度低的问题,提出了一种基于信号幅值辅助的 GM-PHD 算法。该算法通过构建小目标的幅度似然函数来提高目标与干扰波的辨别度,进而提升多目标的识别与状态估计。虽然该算法在多目标状态估计与势估计方面有所改进,但在处理密集或高度重叠的目标时,由于目标与杂波之间的区分度降低,仍可能出现误检或漏检的情况。此外,该算法对幅度信息的准确性有着较高的要求,若幅度信息测量存在误差或不稳定,可能会导致滤波性能下降,进而影响到目标与杂波的准确识别。文献[5]中针对跟踪空间邻近目标的识别度不高、漏检的问题,提出了一种改进算法。该算法通过对每个目标进行高斯项权值的按比例分配来提升邻近目标的跟踪精度,同时利用目标轨迹的连续性特征修正短暂消失的目标,以减少漏检问题。虽然进一步提升了跟踪的准确度和连续性,但是它仍存在一定的局限性。例如,算法对目标航迹连续性的假设在某些复杂场景下可能不成立,特别是当目标进行大幅度机动或遭遇非预期干扰时。此外,当处理高密度的目标群时,该算法的计算复杂度若大幅提升,会对其实时性能造成不利影响,进而影响其实际应用效果。文献[6]针对强干扰条件下跟踪非线性目标跟踪能力弱的问题,提出了基于灰狼改进算法和渐消因子改进的融合算法。该算法通过实时监控和调节环境噪声参数,通过改进渐消因子来调整增益矩阵,进而提升跟踪精度。虽然该算法一定程度上改善了非线性目标跟踪能力弱的问题,但是由于目标的快速运动或突然变化可能导致过程噪声和量测噪声的特性发生显著变化,改进灰狼算法可能难以实时、准确地调节这些噪声参数,从而影响算法的跟踪性能。此外,对于复杂场景中多目标之间的交互和遮挡问题,该算法可能无法有效区分和跟踪各个目标,导致跟踪丢失或混淆。文献[7]中针对传统

多目标跟踪方法中数据关联步骤的复杂性和局限性,特别是虚警率高的问题,提出了一种基于容积卡尔曼滤波器(CKF)的 GM-PHD 算法,采用面向轨道的方法,并通过容积卡尔曼滤波器(CKF)有效处理由多普勒效应引起的非线性问题。为更精确地描述目标状态的不确定性,采用立方积分法来精确计算高斯混合中每个分量的均值与协方差,这一处理方式有效地避免了烦琐的数据关联步骤,从而提升了算法的效率与准确性。但其自身更新步骤中涉及高斯混合的近似和数值计算,如立方积分法,这可能导致计算量较大,尤其是在目标数量多或跟踪场景复杂时,实时性可能受到影响。同时当目标间距较近或发生交叉轨迹时,算法可能难以准确区分和跟踪各个目标,导致目标身份交换或丢失。

然而,尽管多传感器数据融合技术和 GM-PHD 滤波算法在理论层面取得了一定的进展,但在实际应用中仍面临着诸多挑战。例如,如何有效地处理多传感器数据中的噪声和不确定性,以提高目标状态估计的精确度;如何优化 GM-PHD 算法的性能,以应对复杂多变的运行环境;如何将多传感器数据融合技术与 GM-PHD 滤波算法相结合,以实现更加精准、实时的列车 LED 信号灯周期控制等。

因此,基于多传感器数据 GM-PHD 滤波算法,提出了一种精准且灵活的列车 LED 信号灯周期控制策略。通过深入探索多传感器数据的处理与应用方法,力求提升列车运行状态预估的精准性。同时,优化 GM-PHD 滤波算法,使其更能适应复杂多变的运行环境。最终,通过一系列实验验证这一方法的有效性,为城市轨道交通系统的优化提供坚实支撑。

1 多传感器数据融合与列车状态感知

在列车 LED 信号灯周期控制中,准确感知列车运行状态是前提和基础。传统的单一传感器数据往往受到环境噪声、设备精度等因素的影响,难以全面反映列车的实际状态。出于实时性的考虑,本文算法采用集中式多传感器数据融合技术,通过集成来自不同传感器的观测数据,实现对列车运行状态的全面、准确感知。

1.1 多传感器量测模型构建

本文构建了一个由雷达和红外系统组成的混合传感器目标跟踪系统。雷达以其高精度的测距

和测速能力,为系统提供了稳定可靠的目标位置信息;而红外系统则凭借其对热辐射的敏感特性,有效弥补了雷达在某些复杂环境下的探测局限性。这两个传感器协同工作,通过数据融合算法,实现了对目标状态的精确估计和持续跟踪。

多传感器融合目标跟踪算法能显著提升状态估计精度,但复杂度较高,运行耗时较长^[8-9]。为兼顾实时性,我们采用集中式量测融合的方法处理量测数据,旨在高效融合信息同时确保实时性能。为了确保数据的有效融合与协同处理,假定雷达与红外系统已进行同地部署,并且完成了坐标校准、时空对齐与同步处理,其线性离散系统方程表示为^[10]:

$$x_k = D_k x_{k-1} + v_{k-1} \quad (1)$$

混合传感器系统的量测模型方程为:

$$z_k^{(i)} = G_k^{(i)} x_{k-1} + w_k^{(i)}, i = 1, 2 \quad (2)$$

式中,当 $i = 1$ 时为雷达量测,其数学模型可表示为 $z_k^{(1)} = [r_k, \alpha_k^{(1)}, \beta_k^{(1)}]^T + w_k^{(1)}$, 当 $i = 2$ 时为红外传感器量测,其数学模型可表示为 $z_k^{(2)} = [\alpha_k^{(2)}, \beta_k^{(2)}]^T + w_k^{(2)}$, 其中 $w_k^{(i)}$ 表示符合高斯分布的量测噪声,其均值为零,协方差阵为 E_k ; $\alpha_k^{(i)}$ 、 $\beta_k^{(i)}$ 依据 i 值的不同,动态地表示相应类型的斜长距离、方位角和高低角。

$$\begin{cases} E_k^1 = \text{diag}[\sigma_r^2, \sigma_{\alpha}^{2(1)}, \sigma_{\beta}^{2(1)}] \\ E_k^2 = \text{diag}[\sigma_{\alpha}^{2(2)}, \sigma_{\beta}^{2(2)}] \end{cases} \quad (3)$$

式中,参数 $\sigma_{\alpha}^{2(1)}$ 、 $\sigma_{\beta}^{2(1)}$ 表示雷达方位角和高低角的噪声方差,参数 $\sigma_{\alpha}^{2(2)}$ 、 $\sigma_{\beta}^{2(2)}$ 代表红外传感器对应的方位角和高低角噪声方差,而参数 σ_r^2 则特指雷达的距离量测噪声方差。

在目标跟踪的场景中,预设雷达数量为 P , 红外传感器数量为 Q , 共同构建成多传感器系统。该系统首先分别获取各自的观测数据,其次再进入到融合中心进行数据的综合处理,以实现更为精确的目标状态预估

在 k 时刻有 $P + Q$ 组量测数据,即 $Z_{k,1}, \dots, Z_{k,P}, Z_{k,P+1}, \dots, Z_{k,P+Q}$, 其中雷达的量测 $Z_{k,j}^L$ 表示为:

$$Z_{k,j}^L = [r_{k,j}^L, \alpha_{k,j}^L, \beta_{k,j}^L]^T, j = 1, \dots, P \quad (4)$$

式中, $\alpha_{k,j}^L, \beta_{k,j}^L$ 和 $r_{k,j}^L$ 分别为雷达在方位角、高低角及距离方面的观测数据。

红外传感器量测表示为:

$$Z_{k,l}^H = [\alpha_{k,l}^H, \beta_{k,l}^H]^T, l = P + 1, \dots, P + Q \quad (5)$$

式中, $\alpha_{k,l}^H, \beta_{k,l}^H$ 为红外方位角、高低角量测。

雷达观测值 $Z_{k,j}^L$ 对应的高斯噪声协方差阵 $\Theta_{k,j}^L$ 的数学表达式为^[11]:

$$\Theta_{k,j}^L = \text{diag}[C_{k,j}^{L,r}, C_{k,j}^{L,\alpha}, C_{k,j}^{L,\beta}], j = 1, \dots, P \quad (6)$$

红外观测值 $Z_{k,l}^H$ 对应的高斯噪声协方差阵

$\Theta_{k,l}^H$ 的数学表达式为:

$$\begin{aligned} \Theta_{k,l}^H &= \text{diag}[C_{k,l}^{H,\alpha}, C_{k,l}^{H,\beta}], \\ l &= P + 1, \dots, P + Q \end{aligned} \quad (7)$$

式中, $C_{k,j}^{L,\beta}$ 代表雷达的高低角量测噪声方差,而 $C_{k,l}^{H,\beta}$ 则代表红外传感器的高低角量测噪声方差; $C_{k,j}^{L,\alpha}, C_{k,l}^{H,\alpha}$ 分别表示雷达和红外的方位角; $C_{k,j}^{L,r}$ 表示雷达的距离。

1.2 基于噪声加权机制的数据融合

通过对多传感器量测数据进行精心设计与整合,构建出的高效融合系统,旨在克服因雷达方位角量测不准确而可能导致的目标信息遗漏问题。通过实施最优加权融合策略,显著提升了融合后的量测精度,确保所获得的量测性能优于单一传感器,从而实现了更为精准和可靠的目标跟踪。

依据 1.1 理论,在 t 时刻,可采用加权融合的方法对所有量测数据进行综合处理,即:

$$\begin{cases} \hat{\alpha} = \sum_j^P \omega_{k,j}^{L,\alpha} \alpha_{k,j}^L + \sum_{l=P+1}^{P+Q} \omega_{k,l}^{H,\alpha} \alpha_{k,l}^H \\ \hat{\beta} = \sum_j^P \omega_{k,j}^{L,\beta} \beta_{k,j}^L + \sum_{l=P+1}^{P+Q} \omega_{k,l}^{H,\beta} \beta_{k,l}^H \\ \hat{r} = \sum_j^P \omega_{k,j}^{L,r} r_{k,j}^L \end{cases} \quad (8)$$

式中,

$$\begin{aligned} \omega_{k,j}^{L,\alpha} &= 1 / \left[C_{k,j}^{L,\alpha} \left(\sum_{j=1}^P 1 / C_{k,j}^{L,\alpha} + \sum_{l=P+1}^{P+Q} 1 / C_{k,l}^{H,\alpha} \right) \right], \\ \omega_{k,l}^{H,\alpha} &= 1 / \left[C_{k,l}^{H,\alpha} \left(\sum_{j=1}^P 1 / C_{k,j}^{L,\alpha} + \sum_{l=P+1}^{P+Q} 1 / C_{k,l}^{H,\alpha} \right) \right], \\ \omega_{k,j}^{L,\beta} &= 1 / \left[C_{k,j}^{L,\beta} \left(\sum_{j=1}^P 1 / C_{k,j}^{L,\beta} + \sum_{l=P+1}^{P+Q} 1 / C_{k,l}^{H,\beta} \right) \right], \\ \omega_{k,l}^{H,\beta} &= 1 / \left[C_{k,l}^{H,\beta} \left(\sum_{j=1}^P 1 / C_{k,j}^{L,\beta} + \sum_{l=P+1}^{P+Q} 1 / C_{k,l}^{H,\beta} \right) \right], \\ \omega_{k,j}^{L,r} &= 1 / \left(C_{k,j}^{L,r} \sum_{j=1}^P 1 / C_{k,j}^{L,r} \right). \end{aligned}$$

针对 k 时刻的量测噪声数据,采用加权融合的方式进行综合处理,具体为^[12]:

$$\hat{\Theta}_k = \text{diag}[\hat{C}_k^r, \hat{C}_k^\alpha, \hat{C}_k^\beta] \quad (9)$$

$$\begin{cases} \hat{C}_k^\alpha = \left(\sum_{j=1}^P 1 / C_{k,j}^{L,\alpha} + \sum_{l=P+1}^{P+Q} 1 / C_{k,l}^{H,\alpha} \right) - 1 \\ \hat{C}_k^\beta = \left(\sum_{j=1}^P 1 / C_{k,j}^{L,\beta} + \sum_{l=P+1}^{P+Q} 1 / C_{k,l}^{H,\beta} \right) - 1 \\ \hat{C}_k^r = \left(\sum_{j=1}^P 1 / C_{k,j}^{L,r} \right) - 1 \end{cases} \quad (10)$$

由于红外传感器无法直接测定目标距离,为克服传统补零扩维存在的非正定问题,本文将雷达距离观测值转化为红外传感器的距离观测值,从而成功扩展红外传感器的观测维度。

扩维后的红外混合量测:

$$\hat{Z}_{k,l}^H = [\hat{r}_k, \hat{\alpha}_{k,l}^H, \hat{\beta}_{k,l}^H]^T, l = P+1, \dots, P+Q \quad (11)$$

在 k 时刻,雷达的距离量测数据经过加权融合得出 $\hat{r}_k$ 。基于此,红外混合量测的噪声协方差阵确定为:

$$\hat{\Theta}_{k,lk,l} = \text{diag}[\hat{C}_k^r, \hat{C}_k^{H,\alpha}, \hat{C}_k^{H,\beta}] \quad (12)$$

通过赋予不同权重,我们得到了来自多个传感器的量测数据的整合数据,即多传感器量测集 $\hat{Z}_k = [\hat{r}_k, \hat{\alpha}_k, \hat{\beta}_k]^T$,集合中包括列车运行的相关数据信息,如位置、速度、姿态等。

2 GM-PHD 滤波算法在列车状态估计中的应用

在获得了多传感器数据融合的列车状态信息后,需要对这些信息进行进一步的处理和分析,以得到更加精确的状态估计。为此,本文引入了 GM-PHD 算法^[13]。

假定 $k-1$ 时刻的 PHD 分布如下:

$$v_{k-1}(x) = \sum_{i=1}^{O_{k-1}} \omega_{k-1}^{(i)} N(x; m_{k-1}^{(i)}, \mathbf{P}_{k-1}^{(i)}) \quad (13)$$

式中,依据高斯混合概率假设密度过滤波函数理论可知, $\mathbf{P}_{k-1}^{(i)}$ 代表高斯项协方差矩阵, $\omega_{k-1}^{(i)}$ 表示高斯项权重, $m_{k-1}^{(i)}$ 表示高斯项中心值。

2.1 GM-PHD 状态值预测和更新

GM-PHD 强度是通过高斯混合模型(GMM)来表示的,其中每个高斯分量代表一个可能的目标状态及其不确定性。强度的值由高斯分量的权重、均值和协方差等参数共同决定,这些参数在算法的递推过程中不断更新和调整,其强度值的数学模型可表示为:

$$D_{k|k-1}(x) = D_{a,k|k-1}(x) + D_{\beta,k|k-1}(x) + D_{\gamma,k|k-1}(x) \quad (14)$$

式中, $D_{a,k|k-1}(x)$ 表示已存在目标, $D_{\beta,k|k-1}(x)$ 表示衍生目标, $D_{\gamma,k|k-1}(x)$ 表示新生目标。

预测步骤:根据前一时刻的目标状态分布,预测当前时刻的目标可能位置及状态分布:

$$D_{k|k-1}(x) = \sum_{i=1}^{O_{k-1}} \omega_{k|k-1}^{(i)} N(x; m_{k|k-1}^{(i)}, \mathbf{P}_{k|k-1}^{(i)}) \quad (15)$$

更新步骤:结合当前时刻的观测数据,对预测得到的目标状态分布进行修正,以得到更精确的目标状态估计:

$$D_k(x) = (1 - P_D(x)) D_{k|k-1}(x) + \sum_{i=1}^{O_{k|k-1}} \omega_k^{(i)}(\hat{Z}_k) N(x; m_k^{(i)}(\hat{Z}_k), \mathbf{P}_k^{(i)}(\hat{Z}_k)) \quad (16)$$

2.2 GM-PHD 目标个数估计

GM-PHD 算法会计算各高斯分量的权重,这些权重体现了相应目标状态存在的概率。设定合适的阈值后,高于此阈值的高斯分量即被视为真实目标,进而可估计场景中的目标数量。按照 PHD 的定义,目标数量的估计是通过对其在状态空间中的积分计算得到的。据此,可以推导出预测步骤中目标数量的估算结果为^[14]:

$$\hat{N}_{k|k-1} = \int_{S_k} v_{k|k-1}(x) dx = \sum_{i=1}^{k-1} \omega_{k|k-1}^{(i)} \quad (17)$$

更新步骤的目标个数的估计值可表示为:

$$\hat{N}_k = \int_{S_k} v_k(x) dx = (1 - P_D) \hat{N}_{k|k-1} + \sum_{z \in \hat{Z}_k} \sum_{i=1}^k \omega_{k|k-1}^{(i)} \quad (18)$$

2.3 GM-PHD 目标状态提取

GM-PHD 作为一种集合值估计方法,主要功能在于根据目标的数量来估计目标状态。这一过程中,通过筛选混合权重 $E > 0.5$ 的高斯项,并提取其均值,来实现对目标状态的精确估计。在列车状态估计的应用中,将列车视作动态目标,并采用 GM-PHD 滤波算法进行实时跟踪与预测。通过持续更新滤波器的参数和状态估计,获取更为精确和可靠的列车运行状态信息。

3 基于状态估计的 LED 信号灯周期控制策略

LED 信号灯周期控制策略见图 1。

集中式多传感器融合结构通过整合来自不同传感器的数据,为列车控制系统提供全面而准确的环境感知信息。这种结构尤其适用于 LED 信号灯周期控制,因为它能够综合考虑多种因素,如列车位置、速度、信号状态以及周围环境等,从而作出更精准的控制决策^[15]。

首先,作为系统的中枢,融合中心负责汇集多个传感器提供的初始数据,包括列车状态、周围环境以及信号灯状态等信息。这些数据随后通过 PHD 滤波器进行处理,以进行列车状态的预测和更新。

在 PHD 预测阶段,融合中心结合历史数据和环境模型,预测列车未来的运行状态以及信号灯可能的状态变化。随着新传感器数据的不断接收,PHD 更新阶段会对之前的预测进行实时调整,以提高估计的准确性。

随后,融合中心从 PHD 滤波器的输出中提取列车和信号灯的状态值,进行目标状态估计。基于这些状态值,融合中心能够估计列车到达下一个信号灯所需的时间,并预测信号灯可能的周期变化。

最后,根据目标状态估计的结果,融合中心生成相应的控制指令,这些指令被传送给灯控系统,会动态调整 LED 信号灯的周期,以确保列车能够安全、高效地通过信号灯。

整个流程通过集中式多传感器融合结构的应用,实现对列车运行状态和信号灯状态的精准感知和控制。




图 1 LED 信号灯周期控制策略

4 基于增广 OSPA 指标的算法性能评估

在评估滤波器的性能时,一个核心指标是滤波器的估计值与实际位置之间的偏差或误差。由于在本研究中并不涉及航迹的关联问题,因此估计值呈现出无序的状态。为了更准确地衡量这种无序状态下的性能,本文选用了行业内普遍认可的 OSPA 指标作为评估标准。这一指标能够有效地反映滤波器估计值与实际位置之间的整体差异,提供了一个客观、全面的性能评估手段。

使用 $d^{(c)}(x,y) \triangleq \min (c,d(x,y))$ 表示, $x,y \in W,W \subset \mathbb{R}^{N_x}$ 之间的距离,以提前定义的切割参数 $c>0$ 切割。同时使用 Π_k 表示在 $\{1,2,\cdots,k\}$ 上各种排列的集合, k 为任意正整数。对于任意两个 W 上的有限集 $X=\{x_1,\cdots,x_n\}$ 与 $Y=\{y_1,\cdots,y_m\}$,其中 m,n 为任意非负整数且 $m \geq n$,定义^[16]:

$$\bar{d}_p^{(c)}(x,y) = \left\{ \frac{1}{n} \left[\min_{\pi \in \Pi_n} \sum_{i=1}^m d^{(c)}(x_i,y_{\pi(i)})^p + c^p(n-m) \right] \right\}^{1/p} \tag{19}$$

传统的 OSPA 在复杂动态环境或高维大规模数据等方面存在不足,为了解决这一问题,本文提出了其增广算法 GOSPA。该算法能够有效单独评估由遗漏识别和错误观测所引入的误差。基于二维点集进行评估,其数学表达式可以表述为:

$$d_p^{(c,2)}(x,y) \triangleq \left\{ \min_{\gamma \in \Phi^{(|X|,|Y|)}} \left[\sum_{i,j \in \gamma} d(x_i,y_j)^p + \frac{c^p}{2} (|X|+|Y|-2|\gamma|) \right] \right\}^{1/p} \tag{20}$$

式中, $\Phi^{(|X|,|Y|)}$ 为涵盖所有潜在二维分配方案的全面集合, c 表示用于筛选与判断的切割阈值。 p 表示定位分量的异常值敏感系数。设置参数 $\alpha=2$, $[d_p^{(c,2)}(.,.)]^2$ 可以被分解为三种形式: $c_l^2(.,.)=\sum_{(i,j) \in \gamma} d(x_i,y_j)^p$ 表示方位误差, $c_m^2(.,.)=c^p(|X|-|\gamma|)/2$ 表示漏检误差, $c_f^2(.,.)=c^p(|Y|-|\gamma|)/2$ 表示虚假检测误差。

5 实验分析

5.1 环境及参数设定

为验证本文算法对列车 LED 信号灯周期控制的精确性和安全性,实验环境设定在二维运动目标跟踪平面内 $[-1000,1000]\text{m} \times [-1000,1000]\text{m} \times [0,2000]\text{m}$ 的检测区域,假定在检测区域内,我们追踪到三个目标,它们均以匀速运动。这些目标

的具体参数设定如表 1 所示。

表 1 目标参数设定

目标	目标属性	存活时间/s	机动情况	初始运行状态
1	初始	1~70	匀速	[300,350,35000,-300,13000,-80]
2	新生	41~80	匀速	[5850,400,26,100,-200,11980,-100]
3	衍生	51~100	匀速	[22000,50,16900,-500,8080,-200]

监控时长设为 100 s,采样周期定为 $T_{\Delta} = 1000$ ms,假设雷达与红外传感器在同一地点部署并协同作业,在实验过程中,雷达的量测噪声协方差矩阵表示为 $\mathbf{R}_k^L = \text{diag}[0.015,0.015,0.000\ 000\ 0001]$,而红外传感器的量测噪声方差矩阵则用 $\mathbf{R}_k^H = \text{diag}[0.000001,0.000003,0.000005]$ 来表示。雷达过程噪声协方差矩阵为 $\mathbf{Q}_k^L = \text{diag}[0.01,0.02,0.01]$,噪声控制矩阵为 $\mathbf{G}^L = [\frac{T_{\Delta}^2}{2},0,0;T_{\Delta},0,0;0,\frac{T_{\Delta}^2}{2},0,0,T_{\Delta}]$,红外过程噪声协方差矩阵为 $\mathbf{Q}_k^H = \text{diag}[11,11,11]$,噪声控制矩阵为 $\mathbf{G}_k^H = [0,0,0;0,0,1;0,0,0;0,1,0;1,0,0;0,0,0]$,雷达初始状态协方差为 $\mathbf{P}^L = \text{diag}[110,1,110,1,110,1]$,红外初始状态协方差为 $\mathbf{P}^H = \text{diag}[0.000001,0.000\ 0003,0.000\ 0005;0.000\ 0007,0.000003]$ 。

在 LED 灯目标跟踪场景中,设定检测概率和存活概率均为 0.96,即目标的检测和维持其存在状态的信心水平是 0.96。在处理目标状态数据时,我们设定了状态合并门限 6,这有助于确定何时将多个状态合并为一个目标。同时,量测融合门限 $cor = 3$ 用于决定何时将不同传感器的量测数据融合起来,以提高估计的准确性。为了控制计算复杂性和保持模型的精度,我们设定了最大高斯数 1000,即在高斯混合模型中最多使用 1000 个高斯分量来表示目标状态。对于环境中的杂波干扰,我们假设其数学特性符合均值为 10 的泊松分布。最后,为了全面评估系统的性能,采用 OSPA 距离作为评估指标。

5.2 实验设计

5.2.1 三维场景下目标实际轨迹与预估位置对比

在三维场景下,实际轨迹与预估位置的对比是评估多传感器数据 GM-PHD 滤波算法性能的关键环节。在实际应用中,列车在三维空间中运行,其轨迹不仅涉及横向位移,还包括垂直位移和坡度起伏。实验对比分析了本文方法对三维场景下列

车目标实际轨迹的跟踪和预估位置对比结果,用图 2 描述。




图 2 三维场景下实际轨迹与预估位置对比

分析图 2 可以看出,在对比实际列车运行轨迹与预估位置时,三个目标基于多传感器数据 GM-PHD 滤波算法的预估位置与实际轨迹吻合度较高。无论是在水平方向还是垂直方向,算法都能准确反映列车的位置和姿态变化。可见本文方法在列车状态感知和轨迹跟踪方面的有效性和实时性。

5.2.2 雷达红外融合多目标高低角与方位角对比

方位角和高低角是描述目标在三维空间中位置和姿态的关键参数。对于高速行驶的列车来说,高低角可以提供关于列车姿态的重要信息,方位角则常用于判定方位、指示目标和保持行进方向,这两个指标的结合使用,可以使得本文控制方法采用的 GM-PHD 算法在目标跟踪中更加准确和可靠,本文方法采用的 GM-PHD 算法在列车目标跟踪过程中时,利用单传感器的跟踪高低角与方位角和多单传感器高低角与方位角情况,分别用图 3 和图 4 描述。

如图 3 所示,在 100 s 的时间周期内,单传感器的高低角和方位角变化与列车实际运行轨迹的高低角和方位角变化吻合度较低,呈现出较为明显的偏差。此外,因单传感器只能提供单一方向或维度的数据,导致其在反映整体趋势时显得相对平滑,波动较小,无法完全捕捉列车运行的复杂变化。




图 3 单传感器高低角与方位角对比




图 4 多传感器高低角与方位角对比

如图 4 所示,在 100 s 的时间周期内,多传感器的高低角和方位角变化与列车实际运行轨迹的高低角和方位角变化相比较,一致性较高,无明显的偏差。因多传感器具备多方向或多维度的数据获取能力,曲线的态势波动较为丰富。

对比图 3 和图 4,可以明显看出多传感器在高低角和方位角估计方面相较于单传感器具有显著的优势。可见本文方法通过融合不同方向或维度的多传感器数据,能够提供更准确、更全面的列车位置信息和状态感知。

5.2.3 目标个数预估对比

实验统计本文方法采用单传感器和多传感器进行实验列车 LED 灯目标数估计结果,分别用图 5 和图 6 描述。

如图 5 所示,100 s 内,单传感器 LED 灯目标数估计值一共出现了 9 次虚警或漏警的情况,尤其是在 50~70 s 之间,出现了 2 次漏警情况,并且这 2 次漏警偏差多达 2 个,漏警率达到了实际总数的 66.7%,仅识别出 1 个 LED 灯目标,同时每次漏警或虚警的持续时长平均值也大于 1.5 s。




图 5 单传感器目标数估计




图 6 多传感器目标数估计

如图 6 所示,100 s 内,多传感器 LED 灯目标数估计值仅出现了 6 次虚警或漏警的情况,这 6 次中漏警情况只出现了 1 次,漏警率只有 16.7%,每次漏警和虚警的偏差值都是 1,并且持续时长也较短,明显低于 0.1 s。

对比图 5 和图 6,单传感器与多传感器在目标数估计稳定性上差异显著。单传感器在 LED 灯目标数量增多时,可能由于噪声干扰等外环境的改变,其识别率不够稳定,估计偏差较大。而多传感器则展现出更高的稳定性,能更准确地反映真实 LED 灯目标数,尽管偶尔有瞬时偏差。因此,本文方法在列车 LED 灯目标识别、漏警和虚警方面均优于单传感器,实用性和可靠性更高。

5.2.4 GOSPA 距离对比

GOSPA (Generalized Overlap Score for Probability Hypotheses) 距离是一种用于评估概率假设之间相似度的度量标准。通过综合考虑列车 LED 灯目标的定位、存在性和数量,GOSPA 能够提供更全面和准确的性能评估。实验统计本文方法进行列车 LED 灯目标状态估计的 GOSPA 距离值,结果用图 7 描述。




图 7 GOSPA 距离曲线对比

图 7 所示,从 GOSPA 指标曲线图的趋势来看,单传感器在某些时间段内呈现出较为明显的波动。这表明当列车 LED 信号灯状态发生快速变化或者运行环境存在较大的不确定性时,单传感器数据的稳定性受到影响,导致 GM-PHD 滤波算法对信号灯状态的估计精度出现波动。这种波动可能会影响到周期控制的准确性,增加误判和漏检的风险;而多传感器数据融合后的曲线更加平滑稳定,表明 GM-PHD 滤波算法在处理多传感器数据时具有更好的稳定性和一致性。这有助于减少误判和漏检的情况,提高列车运行的安全性和效率。当前实验表明,本文方法充分利用各传感器之间的互补性和冗余性,提高信号灯状态估计的精度和鲁棒性。

6 结 论

通过对基于多传感器数据 GM-PHD 滤波算法的列车 LED 信号灯周期控制方法的深入研究,本文提出了一种新颖且有效的控制策略。该策略通过噪声加权机制融合多传感器数据,实现了列车状态的精准感知;同时,利用 GM-PHD 滤波算法对列车运行状态进行实时更新和预测,进一步提升了跟踪的精准度。最终,将精确的列车运行状态传递给灯控系统,实现了 LED 信号灯周期的动态调整。然而,本文研究仍处在不断探索和完善的阶段。面对城市轨道交通系统日益复杂化的运行环境,多传感器数据的稳定性和可靠性问题、算法的实时性能优化等仍是我们需要进一步研究和解决的关键问题。展望未来,随着智能化技术的不断发展,列车 LED 信号灯周期控制将有望实现更高的自动化和智能化水平。通过持续的研究和创新,相信我们能够城市轨道交通系统的安全、高效运行贡献更多力量,为乘客提供更加舒适、便捷的出行体验。

参考文献

[1] 韩锟,彭晶莹. 基于改进 YOLOX 与多级数据关联的行人多

目标跟踪算法研究[J]. 铁道科学与工程学报,2024,21(1): 94—105.

[2] 薛昱,冯西安. 机动目标跟踪的多传感器分层加权融合算法[J]. 探测与控制学报,2020,42(1):12—16.

[3] 刘金文,任卫红,田建东. 融合人群密度的自适应深度多目标跟踪算法[J]. 模式识别与人工智能,2021,34(5):385—397.

[4] 聂泽东,汪圣利. 幅度信息辅助的 GM-PHD-UKF 弱小多目标跟踪算法[J]. 电光与控制,2020,27(12):41—44.

[5] 龚阳,崔琛. 基于 GM-PHD 滤波的空间邻近多目标跟踪算法[J]. 系统工程与电子技术,2022,44(1):76—85.

[6] 齐美彬,伍坤江,赵谦,等. SRCKF-GM-PHD 多目标跟踪算法的优化[J]. 现代雷达,2023,45(4):31—39.

[7] ANIRBAN R, DEBJANI M. Multi-target trackers using cubature Kalman filter for doppler radar tracking in clutter[J]. IET Signal Processing,2016,10(8):888—901.

[8] 郭业才,曹佳露,韩莹莹,等. 基于光谱匹配降维和特征融合的高光谱目标跟踪[J]. 光学学报,2023,43(20):152—161.

[9] 李祖检,占荣辉,庄钊文. 基于形态匹配聚类的近邻扩展目标跟踪算法[J]. 信号处理,2023,39(2):298—309.

[10] YANG J, NI P, MIAO J, et al. Improving visual multi-object tracking algorithm via integrating GM-PHD and correlation filter[J]. IET Image Processing, 2022,16(5):1349—1358.

[11] LUO Q, GAO Z, XIE C. Improved GM-PHD filter based on threshold separation clusterer for space-based starry-sky background weak point target tracking[J]. Digital Signal Processing,2020, 103(1).

[12] HAN S T, QIAN H M, PENG D L, et al. An unbalanced weighted sequential fusing multi-sensor GM-PHD algorithm[J]. Nature Reviews Cancer,2019,19(2).

[13] WANG L P, ZHAN R H, LIU S Q, et al. Joint tracking and classification of multiple extended targets via the phd filter and star-convex rhm[J]. Digital Signal Processing, 2021, 111(1).

[14] WU W H, LIU W J, JIANG J, et al. GM-PHD filter-based multi-target tracking in the presence of doppler blind zone[J]. Digital Signal Processing,2016,52: 1—12.

[15] 贾亮,于昊充,王贵宇. 多特征的尺度自适应核相关滤波目标跟踪算法[J]. 计算机仿真,2023,40(7):184—189.

[16] 刘晋成,唐伦,陈前斌. 基于数据特征的多传感器融合实时目标检测[J]. 计算机应用研究,2023,40(11):3456—3461.