

基于图结构的传感器优化部署的防褥护理床智能算法的研究

邝昆伦¹, 陈 浩^{1*}, 谭嘉俊¹

(1.广州中医药大学, 广东省广州市, 510006; *通讯作者, chen hao@gzucm.edu.cn)

摘 要: 本研究聚焦智能护理床压力传感器部署优化, 旨在以低密度传感器布局实现与高密度传感器布局相近的传感器覆盖率。提出融合图结构建模与单目标优化算法的方法, 构建以传感器数量和覆盖效能为目标的单目标模型, 设计改进遗传算法并引入区域优先级机制, 引导传感器聚焦高风险区。仿真显示, 该方法在高风险区覆盖率接近传统高密度方案的同时, 显著减少传感器数量, 验证了算法在资源受限场景的有效性, 为智能护理床传感器部署提供新思路。

关键词: 智能护理床; 图结构建模; 压力传感器部署; 褥疮预防; 单目标优化

引言

褥疮是由于骨隆凸部位皮肤长期受到压迫导致压迫部位表皮与深部组织缺血引发的溃疡, 严重时甚至会引发生命危险。近年来, 随着医疗技术与材料技术的发展, 越来越多气垫护理床被投入到褥疮防治的临床应用中, 而气压传感器作为气垫护理床主要的褥疮风险检测手段, 其部署密度与空间布局直接关系到对褥疮风险的感知精度、反应时效与能耗成本。然而, 目前气垫护理床主要以高密度的传感器布局从而实现高精度识别为主, 如 Caggiari S, Jiang L, Filingeri D, Worsley P 等人提出的矩阵卧姿监测系统使用约 348 个传感器组成的实现了约 86% 的准确率 [1] 以及浙江大学李期胜提出的基于分布式阵列的护理床系统通过约 96 个传感器组成的传感器矩阵实现 92% 的识别准确率 [2]。仍缺乏在低密度的传感器布局下实现与高密度布局相近褥疮风险识别精度的识别策略, 因此亟需一种针对性强、部署高效的优化策略, 以在有限资源条件下实现最大感知收益。因此, 本文提出了一种基于图结构的传感器优化部署的护理床智能算法, 在相近覆盖率下大大减少了传感器在护理床的部署数量, 降低了护理床整体的成本, 为护理床的普及提供了基础。

1. 本文方法

针对智能防褥疮护理床的传感器部署问题, 本研究提出了一种基于图结构的优化算法。首先, 对护理床表面几何形状、褥疮高风险区域的空间分布以及传感器感知范围进行数学建模, 并在此基础上明确定义传感器部署的优化目标函数。其次, 针对该优化问题的特征, 以改进的遗传算法 (Genetic Algorithm, GA) 为框架, 创新性地将构建的图结构信息作为部署引导机制融入算法核心。具体而言, 算法设计了图结构引导的初始化策略以生成高质量初始种群, 图结构引导的交叉与变异算子以更有效地探索解空间并提升收敛效率, 融合图信息的适应度函数以精准评估解的优劣。同时, 算法同步处理部署过程中的物理约束 (如传感器数量限制、位置限制、覆盖冗余度要求等), 并在进化过程中实时修正解的可行性, 确保最终部署方案满足实际应用要求。(算法整体流程如图 1 所示)




图1 算法整体流程

1.1. 系统建模与部署优化问题定义

1.1.1. 护理床表面建模

由于护理床的床面通常为一个有限平面区域，尺寸设为 $L_x \times L_y$ 。在离散建模框架中，床面建模为二维欧几里得空间中的闭合区域：

$$\mathcal{B} = \{(x, y) \in \mathbb{R}^2 \mid 0 \leq x \leq L_x, 0 \leq y \leq L_y\} \quad (1)$$

设可部署的传感器总数为 K ，则部署方案可表示为一组坐标点的集合：

$$S = \{(x_1, y_1), (x_2, y_2), \dots, (x_K, y_K)\} \subseteq \mathcal{B} \quad (2)$$

每个坐标点表示一个传感器在床面上的物理位置，精度可根据实际制造与采样分辨率设定。

1.1.2. 褥疮风险空间分布建模

为了实现对高风险区域的优先覆盖，本研究在床面区域内引入离散空间风险函数 $(\mathbf{x}, \mathbf{y})$ ，用于刻画不同位置发生褥疮的概率密度或严重程度，设图结构中共有 N 个关键风险节点 $V = \{v_1, v_2, \dots, v_N\}$ ，每个节点 v_i 对应床面上的位置 (x_i^v, y_i^v) ，风险权重为 α_i 。则风险函数可以构建为高斯混合函数的形式，Roos提出的高斯混合图形模型（GMM-BN）可用于风险值的迭代传播与更新，为本研究中风险空间建模提供了数学基础 [3]：

$$o(x, y) = \sum_{i=1}^N \alpha_i \cdot \exp\left(-\frac{(x-x_i^v)^2 + (y-y_i^v)^2}{2\sigma_v^2}\right) \quad (3)$$

进一步的，为了模拟风险的扩散传播效应设图中任意节点的传播后风险值由其自身风险 and 邻居节点风险共同决定，定义如下传播模型：

$$R_i = r_i + \lambda \sum_{j \in N(i)} i_j \cdot r_j \quad (4)$$

将传播后更新的节点风险重新注入高斯函数中，形成更新后的风险空间函数：

$$(x, y) = \sum_{i=1}^N R_j \cdot \exp\left(-\frac{(x-x_i^v)^2 + (y-y_i^v)^2}{2\sigma_v^2}\right) \quad (5)$$

从下图的对比可以看出，上述建模方式实现了图结构中节点风险对离散床面空间的扩散，融入解剖学结构的先验知识，体现了高风险区域对邻近区域的风险外扩趋势，

符合临床上对“缓冲区”与“次高风险区”的风险认知，Sarhan等人提出的图论指标（如中心性、聚类系数等）可用于评估节点重要性 [4]，为本研究中高风险区域的优先覆盖提供了理论依据，提升部署方案的合理性




图2 临床上褥疮风险分布

图3 图结构建模结果

1.1.3. 传感器感知模型和覆盖表达

由于传感器对于其周围感知区域有限，其覆盖能力可由一个局部感知函数表示，通常采用离散网格覆盖函数建模。设传感器 i 部署在位置 (x_i, y_i) ，其覆盖函数定义为：

$$c_i(x, y) = \begin{cases} 1, & |x - x_i| \leq \sigma \text{ and } |y - y_i| \leq \sigma \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

其中， σ 表示感知半径或衰减程度。设整个床面一共有 K 个传感器，整个系统对某点 (x, y) 的覆盖能力为：

$$C(x, y) = \max \left(\sum_{i=1}^K c_i(x, y) \right) \quad (7)$$

系统目标是在整个床面区域内最大化高风险区域的覆盖求和：

$$\max \sum_{(x,y) \in H} C(x, y) \quad (8)$$

其中 $H = \{(x, y) \mid \omega(x, y) \geq \text{thr}\}$ 表示高风险单元格集合 thr 为高风险阈值，经实验设定为 0.8。

1.2. 部署优化目标函数建模

完成对护理床、褥疮风险与传感器的建模后，本研究进一步从提高高风险区域的覆盖能力，同时也包括减少冗余、降低部署成本等多个方面进行优化函数的构建，从而体现出结构引导下的单目标优化特征。而Civera等人提出了一种基于单目标遗传算法的传感器优化部署策略，考虑了传感器数量、成本与覆盖效能等多个目标，为本研究的单目标优化模型提供了理论支持 [5]。

1.2.1. 冗余程度最小化

为避免资源浪费和干扰表示多传感器重复覆盖带来的性能开销，引入冗余度项（如式9），其中的 $d(x, y)$ 为两个传感器间曼哈顿距离（如式10）：

$$f_{\text{overlap}}(x, y) = \sum_{i=1}^K \sum_{j=i+1}^K (d(x, y) - 1)^2 \quad (9)$$

$$d(x, y) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (10)$$

1.2.2. 传感器数量最小化

鉴于实际部署成本的限制，传感器数量本身也应作为优化对象之一。在保持覆盖性能的前提下，应尽可能减少部署数量。因此，本文将传感器数量纳入式11中。

$$f_{cost}(K) = \lambda_2 \bullet K \quad (11)$$

综上，本文将优化问题建模为以下带权单目标优化形式：

$$\max_{S \subseteq \mathcal{D}_{valid}} f_{cover}(x, y) - \lambda_1 f_{overlap}(x, y) - \lambda_2 \bullet f_{cost}(K) \quad (12)$$

其中：

$\lambda_1 \lambda_2$ 为权重系数，用于调控冗余惩罚与传感器数量对目标函数的影响，经过多次实验 $\lambda_1 \lambda_2$ 大小为50000； $f_{cover}(x, y)$ 与式8相对应

1.3. 优化算法设计与图结构引导机制

为解决空间部署优化问题，设计高效的智能优化算法以搜索最佳传感器位置集合。本研究融合图结构风险模型的同时引入结构性引导机制，设计了图结构引导的部署优化算法

1.3.1. 问题求解特征分析

综上所述，该优化问题具有如下典型特征：

(1) 非凸性强：由于风险函数和覆盖函数均为高斯型，目标函数整体为非凸非线性，即既不满足凸性（存在多个局部极值、曲线凹陷或波浪形），也不满足线性关系（变量间关系无法用直线或超平面表示），导致优化过程复杂且易陷入局部最优。；

(2) 变量维度高：对K个传感器进行二维坐标优化，总维度达2K；

(3) 单目标权衡复杂：需同时考虑覆盖、冗余等因素；

(4) 先验信息可利用：图结构提供关键高风险区域与空间关系，有助于缩小搜索空间与加快收敛。

因此，采用具有强全局搜索能力和先验引导能力的启发式优化算法如遗传算法是较为合适的选择。

1.3.2. 图结构引导的智能优化框架

本研究采用改进型遗传算法（Genetic Algorithm, GA）

作为基础优化框架，并引入图结构信息作为部署引导机制，设计如下融合策略：

(1) 图结构引导的初始化策略

在遗传算法中，种群初始化质量对收敛速度与全局性具有重要影响。本研究在初始种群中引入结构引导策略，类似地，Tripathi等人（2013）提出了一种将遗传编程与遗传算法相结合的混合方法，用于优化传感器节点的部署[6]：

1.结构型个体：从图结构节点中选取若干高风险节点 $V = \{v_1, v_2, \dots, v_N\}$ （按权重排序），在其周围进行扰动采样，生成部分高质量个体；

2.均匀型个体：在床面区域内均匀随机采样，保证搜索空间多样性；

3.混合型策略：初始种群中按比例（60%结构型，40%均匀型）混合构造，提升初始解的引导性与探索性。

(2) 图结构引导的优化策略

由于实际部署环境中传感器数量直接影响系统成本、安装复杂度与维护难度。因此，为了保证追求覆盖率最大化与冗余控制，与部署数量最小化。为此，本文采用两种方式引导传感器数量的优化类似地，Downey等人（2018）提出了一种自适应遗传算法，结合学习基因库，用于优化传感器在混合密度传感器网络中的部署[7]：

1.约束式优化（Constraint-based）

给定性能下限（如覆盖率 $\geq 95\%$ ），逐步削减传感器数量，搜索能满足性能要求的最小K值。

2.联合优化（Penalty-based）

将部署数量项加入整体目标函数作为惩罚项，使用权重控制其影响程度，从而在搜索过程中自然倾向于数量较少、结构合理的解：

(3) 图结构引导的适应度函数设计

在基本覆盖-成本-冗余评价函数基础上，引入图引导项作为奖励机制

$$f_{total}(x, y) = \lambda_2 f_{cover}(K) - \lambda_1 f_{overlap}(x, y) - \lambda_3 f_{graph}(S) \quad (13)$$

其中结构引导项定义为：

$$f_{graph}(x, y) = \sum_{i=1}^K \sum_{j=1}^N \alpha_j \bullet \exp \left(-\frac{(x_i - x_j^v)^2 + (y_i - y_j^v)^2}{2\sigma_y^2} \right) \quad (14)$$

该项鼓励传感器靠近图结构高风险节点部署，提高部署的临床意义与结构合理性。
进一步的，为了适配上述单目标优化建模，本文设计了综合性适应度函数：

$$\text{Fitness} = \alpha \bullet K + \beta \bullet \max(0, T - C) + \gamma \bullet \max(0, O - O_{thr}) + \mu \bullet \max(0, C - \text{Conn}(H)) \quad (15)$$

其中参数 α （传感器数量惩罚权重）平衡部署成本、 β （覆盖率惩罚权重）确保高风险区域覆盖效能、 γ （重叠冗余惩罚权重）控制传感器空间冲突、 μ （连通性惩罚权重）约束覆盖区域拓扑连续性， T （覆盖率目标阈值经实验设为3）设定最低覆盖要求、 C （实际高风险区域覆盖率如式8）衡量部署方案对高风险区域的覆盖效果、 O （传感器重叠冲突对数如式9）量化传感器间的空间冗余程度、 O_{thr} （允许的最大重叠冲突对数，经实验设定为10）界定可接受的传感器重叠程度、 C （ C 表示当前部署方案中形成的连通子图数量如式16）与 $\text{Conn}(H)$ （原始高风险区域的连通分量数，通常设定为1）共同衡量覆盖区域的空间连续性，最终实现联合优化。该设计使得算法在优化解的同时动态探索更小 K 值下的合理部署结构。

（4）图结构辅助的变异机制

为避免陷入局部最优，引入基于图结构的引力变异机制，在进化过程中动态引导个体靠近图节点，对变异后的子代，以一定概率执行“图吸引操作”：向图节点方向轻微偏移（可加噪声）；

若个体距离任一高权图节点过远，可施加小幅“回拉”操作，保持搜索方向性。该机制可与标准GA中的交叉、变异过程协同工作，提升优化稳定性与收敛质量。

为进一步提高部署方案的空间合理性，本文将图结构中“边”的信息引入遗传算法的变异与交叉操作中，从而实现部署的连通性增强，从而利于排布电路和通信网络，使部署形态更接近实际护理干预区域，提升可解释性。

1.边引导的感知区域变异策略

传统GA变异操作随机性强，易造成部署点离散，感知面碎片化。为此，本文提出“边引导变异”机制：对于一个已部署传感器位置 v_i ，优先选取其邻接节点 $N(i)$ 作为变异候选。该策略模拟风险的空间扩散趋势，引导传感器沿图结构边向邻域高风险区域扩展部署。

2.连通性惩罚函数设计

为进一步约束部署结构的空间完整性，引入连通性惩罚项：

$$\text{Penalty}_{conn} = \gamma \bullet (C - 1) \quad (16)$$

其中 C 表示当前部署方案中形成的连通子图数量（通过边定义的连通性）， γ 为调节系数经实验确定为10000。该项可有效惩罚部署结构中出现“孤岛”或分裂的现象。

2. 实验结果

2.1.1. 实验设置

为确保实验的可重复性与现实性，本文构建了一个标准化护理床面模型，模拟实际尺寸和人体接触区域。

床面区域设定：床面离散化为

100×45个网格单元（分辨率 2cm×2cm），传感器部署位置限定为网格节点，覆盖范围为 3×3 网格（6cm×6cm）；

图结构风险节点：依据临床资料设置 8 个高风险区域节点（如骶尾部、肩胛、足跟等），作为图结构中的节点 $V = \{v_1, v_2, \dots, v_8\}$ 。

风险函数参数：图节点注入高斯风险， $\sigma_v = 0.1$ ， α_i 根据临床统计风险程度设定；

为了验证算法在实际部署任务中的适应性，本文基于真实人体结构构建典型体位模型，并可视化部署结果与风险覆盖情况。

2.2. 实验结果

下图展示了“图结构引导算法”在两种体位下的传感器部署结果与风险热力图叠加情况：




图4 本研究布局方案




图5 传统布局方案




图6 褥疮风险热力图




图7 适应度曲线图




图8 传感器数量曲线图




图9 覆盖率曲线图




图10 冲突对曲线图

对比传统方案，从图4和5可知，该算法得出的部署结果使传感器数量从50个下降至30个。由图9可见，在迭代过程中，传感器对褥疮高风险区域的覆盖率始终维持在较高水平，达到93.5%。从图7能够发现，该算法所得部署方案的适应度相比原方案先大幅下滑，后趋于平稳，这表明该方案已极大程度接近最优方案，证明了算法的收敛性，也体现出其优化性。综上，该算法在保证传感器覆盖率的同时，显著减少了传感器数量，进而降低了部署成本。

3. 结论

本文围绕床面压力传感器网络的优化部署问题，提出了一种融合图结构感知与单目标优化的传感器部署方法，并在理论建模、算法设计与实验验证三个层面展开系统研究。具有：相较于传统的均匀部署方法，更好的聚焦性与效能、在保持覆盖性能、加快收敛速度的同时减少“感知孤岛”、降低了部署和应用成本等优点的同时通过将“风险加权覆盖率最大化”、“冗余程度最小化”与“传感器数量最小化”三者联合建模为部署优化目标，形成一个具备结构引导特征的优化问题，为后续算法设计提供理论支撑。连通部署策略可以覆盖“高风险点+次高风险邻域”，符合临床上褥疮防控“缓冲保护”的思想，避免只在骨突点部署，却忽略边缘区，导致“压强迁移”后产生新压疮点，并且该策略更容易形成“区域性趋势判断”，增强了临床应用的解释性和应用价值。

4. 未来展望

在外来的工作中，可引入实际传感器感知模型，提升部署方案的工程可行性。同时进一步探索自适应或增量式优化策略，使部署方案具备动态适应能力。结合强化学习、多目标进化策略或Pareto前沿搜索，挖掘更具泛化能力的高效部署策略。并在真实病床环境中部署传感器系统，对算法方案进行实地测试与优化调整，以推动研究成果向落地应用转化。

参考文献

[1] CAGGIARI S, JIANG L, FILINGERI D, WORSLEY P. Optimization of Spatial and Temporal Configuration of a Pressure Sensing Array to Predict Posture and Mobility in Lying. Sensors (Basel). 2023 Aug 2; 23(15): 6872. doi: 10.3390/s23156872. PMID: 37571655; PMCID:

PMC10422529.

- [2] 李期盛.基于分布式传感阵列的智能护理床系统研究 [D]. 浙江大学, 2017.
- [3] ROOS, J. (2018). Gaussian Mixture Graphical Model Learning and Inference. CRAN gmgm Manual.
- [4] SARHAN, O., ABDEL WAHED, M., & RUSHDI, M. A. (2025). Graph-Theoretic Measures for Interpretable Multicriteria Decision Making in Emergency Department Layout Optimization. arXiv preprint arXiv: 2504.11620.
- [5] CIVERA, M., PECORELLI, M. L., CERAVOLO, R., SURACE, C., & ZANOTTI FRAGONARA, L. (2021). A multi-objective genetic algorithm strategy for robust optimal sensor placement. *Computer-Aided Civil and Infrastructure Engineering*, 36(9), 1185–1202.
- [6] TRIPATHI, A., GUPTA, P., TRIVEDI, A., & KALA, R. (2013). Wireless sensor node placement using hybrid genetic programming and genetic algorithms. *International Journal of Intelligent Information Technologies*, 9(2), 1–20.
- [7] DOWNEY, A., HU, C., & LAFLAMME, S. (2018). Optimal sensor placement within a hybrid dense sensor network using an adaptive genetic algorithm with learning gene pool. *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability*, 232(1), 3–14