数据孤岛困境下联邦学习在护理多中心研究的应用与挑战

刘乘旭[1]，丁琬真[2]，郭慧敏[1]，孙克娟[2]

摘要：数智化转型背景下，护理数据资源的整合与共享已成为提升循证护理证据质量的重要途径。然而，护理数据分散于不同医疗机构和照护场景，数据孤岛问题突出，制约了护理多中心研究的深入开展。联邦学习可在原始数据不出本地的前提下实现多方协同计算与联合分析，为护理数据的安全利用提供新思路。本文围绕护理多中心研究中的数据孤岛困境，阐述联邦学习的适用性、技术原理及主要类型，综述其在临床预测模型构建、慢病管理与延续护理、护理质量评价中的应用，并分析其在数据质量、技术部署和伦理治理中面临的挑战，以期为联邦学习在护理多中心研究中的应用提供参考。

关键词：联邦学习；　多中心研究；　数据孤岛；　护理数据；　多模态数据；　隐私保护；　循证护理；　综述文献

中图分类号：R47；TP18　**DOI**：10.3870/j.issn.1001-4152.2026.19.124

Applications and challenges of federated learning in multicenter nursing research amid the data silo dilemma

Liu Chengxu, Ding Wanzhen, Guo Huimin, Sun Kejuan. School of Graduate, Hebei Medical University, Shijiazhuang 050031, China

Abstract: Against the backdrop of digital and intelligent transformation, the integration and sharing of nursing data resources have become crucial pathways to improving the quality of evidence-based nursing. However, nursing data are often fragmented across various medical institutions and care settings. This exacerbates the prominent issue of data silos, restricting the in-depth advancement of multicenter nursing research. Federated learning enables multi-party collaborative computation and joint analysis without requiring raw data to leave local sites, offering a novel approach to the secure utilization of nursing data. Focusing on the data silo dilemma in multicenter nursing research, this paper discusses the applicability, technical principles, and primary models of federated learning. It reviews its applications in the development of clinical prediction models, chronic disease management, transitional care, and predictive nursing quality evaluation. Furthermore, the paper analyzes the current challenges faced in data quality, technical deployment, and ethical governance, aiming to provide a comprehensive reference for the future application of federated learning in multicenter nursing research.

Keywords: federated learning; multicenter research; data silos; nursing data; multimodal data; privacy protection; evidence-based nursing; review

数智化转型背景下，将临床护理信息转化为可利用的数据资源，并推动跨机构协同研究，是提升循证护理证据质量的重要途径。《“健康中国 2030”规划纲要》[1]明确了健康信息化建设的战略方向，《“十四五”全民健康信息化规划》[2]进一步提出建立健康医疗大数据资源体系，将医疗健康列为重点领域，鼓励在合规前提下开展多源数据协作。《全国护理事业发展规划（2021－2025 年）》[3]则对“互联网＋护理服务”作出专项部署，要求信息技术与护理服务各环节深度融合。在此背景下，如何将临床实践中的护理信息转化为可挖掘的数据资产，并在安全合规前提下整合多源数据以深化护理多中心研究，成为护理学科发展的关键。当前，护理多中心研究的深入推进仍存在障碍。一方面，此类研究发展需大规模、多模态数据支撑，而当前护理数据来源分散，整合与利用仍受限制，难以满足研究需求；另一方面，全球数据治理日趋严格，医疗数据作为敏感信息受到特别保护。欧盟《通用数据保护条例》[4]将健康数据列为特殊类别，我国《个人信息保护法》[5]要求处理医疗健康数据需取得单独同意，这些合规要求为医疗数据的跨机构流通形成了法律约束。联邦学习（Federated Learning，FL）由谷歌于 2016 年首次提出[6]，其分布式架构为破解数据主权与隐私保护困境提供了技术路径。本文立足于护理数据数智化转型背景，探讨联邦学习如何促进护理多中心数据安全共享与价值转化，化解隐私保护与协同研究之间的矛盾，并分析其在护理场景中的应用模式，为护理学科的数字化转型提供参考。

1　护理多中心研究的数据孤岛困境

1.1　护理多中心研究的必要性　护理学高度依赖实证研究，传统单中心研究易受样本量和人群代表性限制，影响结果的稳定性与推广价值。中心静脉导管相关血流感染、重症成人非计划性拔管及医院患者跌倒等低发生率护理事件更需通过多中心协作扩大样本来源[7-9]。以跌倒预防研究为例，美国 STRIDE 试验为验证多因素干预策略可将严重跌倒伤害风险降低 20%，需纳入 5 322 名社区高龄老人，涉及 10 个医疗

作者单位：1. 河北医科大学研究生学院（河北 石家庄，050031）；2. 河北医科大学第一医院智慧医院建设部
通信作者：孙克娟，58101336@hebmu.edu.cn
刘乘旭：男，硕士在读，学生，25034100745@stu.hebmu.edu.cn
科研项目：河北省医学科学研究课题计划项目（20210092）
收稿：2026－05－12；修回：2026－07－15

系统、86 所基层医疗机构[10]，远超单一机构承载能力。同时，单中心样本存在机构特异性偏倚，如德国一项临床验证研究显示，基于某心脏中心构建的急性肾损伤预测模型部署至另一所医院时，受试者工作特征曲线下面积（Area Under the Receiver Operating Characteristic Curve，AUROC）从 0.956 降至 0.751[11]；2024 年一项涵盖 13 个临床数据集的研究显示，机器学习医疗模型从开发机构部署至外部机构时，平均 AUROC 下降 20%。此性能衰减源于模型学习到特定机构的设备特性与标注习惯[12]，印证了单中心模型难以泛化的困境，人群代表性不足直接威胁外部效度，狭隘人群基础上的干预推广可能导致预测失效或资源错配。多中心协作已成为提升护理研究证据等级、解决单中心局限性的重要路径，而联邦学习等计算技术的成熟，为跨机构数据治理与协同分析提供了可行方案，推动护理研究向基于多中心异构数据的循证实践演进。

1.2 数据孤岛的形成机制 数据孤岛是指数据因来源、格式、存储位置及权属主体差异而被行业、部门、地域割裂，形成碎片化、异构化且难以流通的孤立状态[13]。护理多中心研究中的数据孤岛由法规、伦理、技术与利益等因素共同造成。法规层面，护理数据多涉及《个人信息保护法》规定的敏感个人信息，其跨机构处理需满足必要性、告知同意和安全保护等要求[5]，医疗机构因合规风险倾向于将数据留存在本地。伦理层面，各机构伦理委员会的审查标准不一，传统知情同意模式难以覆盖数据跨机构使用、二次利用等复杂场景[14]，伦理合规成为数据流动的隐形门槛。技术层面，护理信息系统的数据结构、术语和接口缺乏统一规范，部分机构内部的医院信息系统（Hospital Information System，HIS）、电子病历系统（Electronic Medical Record，EMR）、实验室信息系统（Laboratory Information System，LIS）与护理模块之间存在数据孤岛[15]，进一步增加了跨机构互联互通的成本。利益层面，医疗机构将医疗数据视为重要资产，但现有机制尚未明确数据贡献与成果收益之间的对应关系[16]，导致其参与数据共享的内在动力不足。因此，需探索兼顾数据利用与隐私保护的跨机构协作路径。

1.3 传统解决方案的局限 针对护理多中心研究的数据共享困境，学术界已尝试数据脱敏、数据沙箱及中心化管理等传统解决方案，但这些路径在护理场景中均存在局限，难以满足数据在保护隐私前提下发挥分析价值的要求。数据脱敏通过删除或泛化直接标识符降低重识别风险，但过度删除或泛化护理记录中的行为表现、环境因素和护患互动等情境信息，可能造成信息损失，削弱数据的临床分析价值[17]。数据沙箱可在受控环境中支持远程分析，但建设、运维和权限管理成本较高[18]，限制了在护理多中心研究中的规模化推广。中心化管理通过建立区域或国家级数据中心汇聚多机构数据[19]，有利于数据的统一管理和标准化处理，但仍面临数据权属、隐私安全和责任分担等问题。可见，在护理数据的高度情境性与隐私合规要求的双重约束下，传统解决方案难以在效用、成本与安全之间实现有效平衡。

2 联邦学习在护理多中心研究的适用性及技术原理

2.1 联邦学习在护理多中心研究的适用性 联邦学习是一种无需汇集原始数据即可实现多方协同的分布式机器学习范式[20]。针对护理多中心研究中的数据孤岛困境，联邦学习的技术架构与跨机构数据协作需求较为契合。在法律合规层面，联邦学习采用数据本地训练和模型参数聚合的运行机制，可减少敏感护理数据的跨机构流转，降低隐私泄露与合规风险[21]。在学科特性层面，联邦学习的分布式架构与护理数据来源于医院、社区、家庭等多场景且类型多样的分布特征相适配。一方面，各中心可保留本地数据，通过模型协同减少集中汇集和过度脱敏造成的情境信息损失；同时，跨机构协作有助于扩大有效样本量，满足跌倒、感染等低发生率事件的研究需求，并提高模型的泛化能力。在技术实施层面，当前我国医疗机构护理信息系统多为分散建设，数据标准不一、接口互不联通[22]。联邦学习可在兼容既有异构系统的基础上开展跨机构协同建模，减少集中式数据整合的实施成本。因此，联邦学习在合规性、学科适配性和技术可行性方面具有优势，有助于解决护理多中心研究中的数据共享难题。

2.2 联邦学习的技术原理与分类

2.2.1 联邦学习的技术原理 联邦学习核心原理是将模型训练从集中式数据聚合转向分布式协同计算，在不暴露原始数据的前提下实现多源知识融合与模型优化[20]。联邦学习通常包括本地训练、隐私保护处理、安全聚合和本地更新 4 个基本环节，其工作流程见图 1。在这一过程中，各参与方接收服务器下发的初始或上一轮全局模型参数，并基于本机构数据完成本地训练，进行模型参数更新。本地训练产生的模型参数或中间结果可采用差分隐私（Differential Privacy，DP）、同态加密（Homomorphic Encryption，HE）等技术进行隐私增强处理。在此基础上，中央服务器或安全聚合节点采用联邦平均算法（Federated Averaging，FedAvg）等方法对各方模型更新进行聚合，生成全局模型。聚合完成后，全局模型下发至各参与机构，用于下一轮本地训练，经多轮迭代逐步收敛。

2.2.2 联邦学习的类型 依据数据分布特征，联邦学习可分为横向联邦学习（Horizontal Federated

Learning，HFL）、纵向联邦学习（Vertical Federated Learning，VFL）、联邦迁移学习（Federated Transfer Learning，FTL）3 种类型。不同联邦学习类型及其特点，见图 2。三者的适用场景与技术路径不同，应根据护理数据分布特征和临床需求选择。①横向联邦学习。适用于各机构数据特征重叠度高、样本重叠度低的场景[23]。如医院基于相同护理评估指标联合训练风险预测模型。其技术核心是在统一特征空间下，通过联邦平均算法聚合模型参数[23]。各医院先在本地独立训练模型，在不上传患者原始数据的前提下，将经隐私保护处理后的模型参数或训练结果提交至中央服务器，经安全聚合机制生成融合多中心信息的全局模型，再下发回各医院使用。部署时需关注不同医院患者群体差异过大的问题，如三甲医院与基层医院在重症患者比例、年龄构成及合并症等方面的差异可能影响模型适用性。这会影响模型在基层医院的适用性。因此，可以将情况相近的医院分组训练，或允许各医院在通用模型上做小幅调整。②纵向联邦学习。适用于各机构患者群体重叠度高、数据特征重叠度低的跨阶段照护场景[24]。例如，医院可能掌握慢病患者的院内生命体征数据，而社区康复机构则掌握同一批患者的居家活动能力评估数据。通过纵向联邦学习，不同机构可在不直接共享原始数据的情况下，联合利用这些互补信息开展分析。其技术实现主要分为两步，首先，各参与方通过隐私集合求交（Private Set Intersection，PSI）技术，在不泄露各自患者名单的前提下安全识别共同患者；随后，各方将本机构数据保留在本地，仅交换经过加密处理的模型计算结果，各方协同完成模型训练[24]。部署时需建立跨机构的患者匹配授权与伦理审查机制，确保数据使用符合法规和患者知情同意要求。由于纵向联邦学习需在多轮训练中反复交换加密计算结果，通信成本较大且对网络同步性要求较高[24]，适合在区域医联体或慢病全程管理项目中分阶段实施。③联邦迁移学习。适用于不同机构之间患者群体与数据特征均存在较大差异的跨领域、跨层级场景[25]。例如，将一般健康监测数据中学习到的步态特征迁移应用于帕金森病早期筛查，或将三甲医院 ICU 中形成的预警模型迁移至阳性样本较少的基层医院普通病房。其技术实现可采用对抗域适应、原型对齐、知识蒸馏或参数迁移等方法。对抗域适应可减弱机构间因采集设备、记录规范和患者构成差异造成的数据分布偏移，提高模型的跨域泛化能力[26]；原型对齐和知识蒸馏可提取不同机构模型中可复用的预测规律，使目标机构能在不共享原始数据的情况下借鉴其他建模经验[27-28]；参数迁移则通过利用源机构已训练模型中的有效参数，辅助目标机构在本地数据上完成模型适配[29]。部署时可分为预训练和微调两阶段，首先在数据丰富的多家医院训练基础模型，随后将模型下发至基层医院，并结合基层医院已有明确结局的本地数据进行微调，以提升模型对目标场景数据分布的适应性。

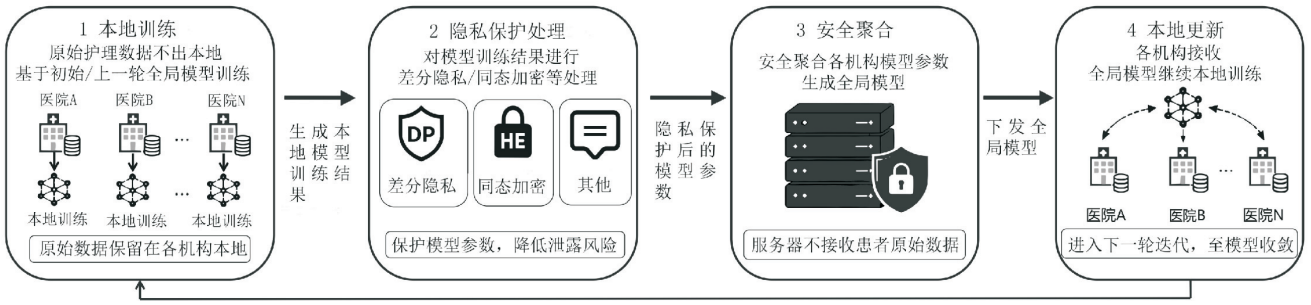


图 1　联邦学习工作流程

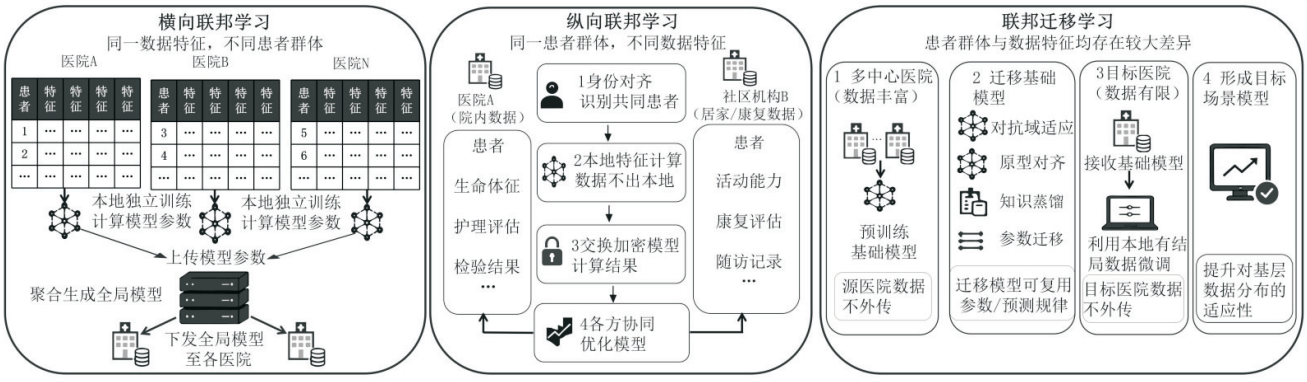


图 2　联邦学习类型

3 联邦学习在护理领域的应用

3.1 临床预测模型构建 临床预测模型是循证护理的核心工具，联邦学习通过整合多中心异构数据，为构建高性能风险预警模型提供了新路径。在住院患者跌倒风险预测中，Nanevski 等[30]采用横向联邦学习，由德国 2 所医院各自在本地训练预测模型，仅上传模型参数进行安全聚合，最终模型在 2 所医院的 AUROC 分别达到 0.926 和 0.735，预测准确率高于传统跌倒风险评估工具。在机械通气撤机预测中，Sheikhalishahi 等[31]采用联邦学习整合 3 个 ICU 数据库超过 3.3 万例患者的数据，各中心在本地训练预测模型后仅共享模型参数，经聚合后模型 AUROC 达到 77%，验证了跨机构预测患者撤机结局的可行性。在用药安全管理中，Pais 等[32]构建带差分隐私的联邦学习系统，多个 ICU 在本地用处方数据训练预测模型，对模型参数加噪后上传聚合，模型识别错误处方的准确率可达 98%，可辅助护士实时预警给药错误。可见，联邦学习通过数据本地训练、参数加密聚合的模式，在保护隐私的同时提升了临床预测模型的性能与泛化能力。

3.2 慢病管理与延续护理 慢病护理依赖连续性数据支持，但医院、社区和家庭场景中的数据相互分散，限制了全周期风险评估。联邦学习可依托客户端、边缘节点、网络聚合层和云端构成的分层架构，在避免向中心端集中传输原始数据的前提下，对可穿戴设备采集的数据开展协同建模，为慢病连续监测与风险评估提供技术支持[21]。以面向可穿戴设备的心房颤动预测系统为例，Alreshidi 等[33]开发了基于联邦学习的心房颤动预测模型，该模型利用本地终端采集的心电信号进行训练，原始数据始终留存于设备端，仅上传模型参数参与全局更新，从而在保护患者隐私的同时实现多节点协同分析。研究显示，经样本平衡与特征提取后，联邦学习模型对心房颤动的识别率可达 97.32%，优于未采用联邦机制的传统机器学习方法[33]。这一结果提示，联邦学习可为可穿戴设备驱动的慢病风险监测和延续护理提供技术支持。然而，慢病护理联邦学习面临一个重要挑战，患者的智能穿戴设备本身就是参与模型训练的底层节点。当患者中断参与或脱落时，此节点便会失效，导致模型无法及时收到该设备端的训练更新，从而影响模型的训练速度和预测准确性。因此，未来慢病护理联邦学习应建立患者长期参与支持机制，减少节点脱落对模型训练的影响，并优化终端参与、模型更新与通信管理策略，以保障数据来源和训练过程的稳定性。

3.3 护理质量评价 护理质量评价是保障患者安全的重要机制，但传统评价面临数据难以共享、无法横向比较的难题。联邦学习支持多所医院在患者数据不离开本地的前提下，分别完成质控指标统计，并将加密结果上传至质控中心进行汇总、标准化比较和趋势分析，以支持跨机构质量对标。以结直肠癌诊疗质量指标为例，Choudhury 等[34]利用荷兰 2 所医院结直肠癌患者的电子健康记录，计算直肠癌患者治疗等待时间达标率和术后并发症发生率，各医院在本地完成数据处理与指标分析，患者原始数据始终留存在院内，仅将计算结果返回中央平台进行汇总和可视化比较。研究结果显示，该模式可在不汇集患者原始数据的前提下完成跨中心质量指标计算，两节点联邦执行过程耗时约 26 s，具有一定的计算效率和隐私保护价值。在预测性评价方面，联邦学习还可推动护理质量管理由事后统计向风险预警延伸。前述联邦学习跌倒风险预测研究显示，多机构可在不共享原始数据的前提下联合构建风险预测模型[30]。若将此类模型嵌入护理质量管理，可用于识别不同机构中的跌倒高风险患者，辅助开展风险分层干预和质量改进，推动护理质量评价由结果统计向风险前移转变。目前联邦学习在护理质量评价中的直接实证应用仍较少，需在更多护理场景中验证。

4 联邦学习在护理领域应用的挑战

4.1 数据层面的挑战 联邦学习在护理领域的应用面临数据层面的挑战。首先是数据质量差异，不同医院在信息化基础设施、数据采集设备及地域信息化发展水平上存在差异。在我国区域发展不均衡背景下尤为突出。沿海发达地区医院在信息化建设方面投入较大，部分医院已逐步实现自动预警数据的采集；而西部及东北地区的基础设施、技术水平相对薄弱。Ye 等[35]基于中国 31 个省份 2010－2022 年的面板数据，采用熵权－逼近理想解排序法（entropy weight-TOPSIS），从信息基础设施、信息服务消费和信息产业 3 个维度测算各地区信息化发展水平。结果显示，信息化发展指数的取值范围为 0.013～0.877，表明不同省份的信息化发展水平存在明显差异。这种区域差异可能进一步影响医院的数据采集能力和数据质量，使在数据质量较高医院训练的模型应用于数据采集不完整、记录质量不一的机构时，预测性能有所下降。其次是护理术语标准化不足，如压力性损伤分期、疼痛评估等核心内容在不同地域医院采用的标准版本不一（如美国压力性损伤咨询小组的压力性损伤分期标准[36]与国内标准有差异），导致不同地域医院间的数据难以直接对比。这会导致联邦学习时，各医院训练的模型对同一护理问题的处理不同，例如 A 医院将“Ⅱ期压力性损伤”标记为 1，B 医院标记为 2，C 医院可能没有标准化记录，中央服务器在聚合这些模型参数时，无法判断真正一致的风险特征，导致模型对不同严重程度的压力性损伤识别混乱，预测准确性下降。此外，若要整合伤口照片和护理文字记录，这两种数据的处理复杂程度不同，对网络传输和隐私

保护的要求存在差异[21,37]。上述数据质量差异、术语标准不一及数据类型整合难题，对护理联邦学习的开展提出了挑战。

4.2　技术部署的挑战　联邦学习从算法原型到临床部署的转化面临护理场景的特殊约束。首先，护理单元信息基础设施薄弱，部分医院病区护士站为老旧终端设备，ICU 床旁设备以生命支持为核心任务，普通病房缺乏专用计算节点，算力与网络条件有限，需设计适配弱网环境和轻量化计算的联邦方案，但现有研究对此关注不足。其次，模型训练难以嵌入临床工作流程，护理工作高强度、高中断性，护士无法预留固定时段参与训练，轮班制度使同步协调困难。最后，临床对反应速度要求高与联邦学习自身的通信延迟存在矛盾。如脓毒症预警需要在数秒内给出判断，但联邦学习的模型更新依赖多中心梯度传输与聚合，网络传输会耗费时间。对此，可采用异步联邦学习、分层联邦学习及缓存优化等策略加以缓解。异步联邦学习可减少多节点同步等待，提高模型训练效率[38]；分层联邦学习通过设置轻量化代理，缩短训练时间[39]；缓存优化可通过服务器端知识复用与轻量化知识传输，降低联邦训练的通信开销[40]。现有技术虽可缓解算力和通信问题，但其在真实护理场景中的适用性仍需验证。

4.3　伦理与治理挑战　联邦学习在破解护理多中心研究数据孤岛困境的同时，也面临伦理与治理层面的挑战。首先是公平性问题，不同层级医疗机构的计算资源与数据质量存在差异，可能造成机构间模型性能不均衡，影响资源受限机构的公平参与和模型应用效果[41]，需在设计中纳入个性化联邦学习和性能校正。其次是数据主权与知情同意问题。联邦学习要求数据持续参与、模型多轮更新，数据用途可能随迭代发生变化，传统一次性知情同意难以覆盖全过程，知情同意的范围和实施程序仍需进一步明确[42-43]。第三是责任归属不明晰，临床决策系统发生错误时，算法开发者、数据贡献机构与临床护士之间的责任边界尚不清晰，且模型训练与决策过程难以追溯。因此，应完善过程记录与审计机制[43]，为责任认定提供依据。

5　小结

联邦学习为护理多中心研究在隐私保护与数据协同之间取得平衡提供了新路径。其通过数据本地留存和模型协同训练，促进不同机构及照护场景中护理数据的知识融合，可为临床预测模型构建、慢病管理与延续护理、护理质量评价等提供技术支持，有助于提升研究结果的稳健性和外部适用性。当前，联邦学习在护理领域的应用仍面临数据质量差异、护理术语标准不统一、多模态数据融合困难、信息基础设施薄弱、模型跨机构适用性不足及责任归属不清等问题。未来应进一步完善护理数据标准体系，发展适配护理场景的轻量化、个性化联邦学习方法，并建立动态知情同意、过程审计和责任分担机制，推动其在护理多中心研究中的规范应用。

参考文献：

[1] 中共中央，国务院. “健康中国 2030”规划纲要[EB/OL]. (2016-10-25)[2026-05-05]. https://www.ndrc.gov.cn/fggz/fzzlgh/gjjzxgh/201705/t20170517_1196770.html.

[2] 国家卫生健康委员会，国家中医药管理局，国家疾病预防控制局. “十四五”全民健康信息化规划[EB/OL]. (2022-11-09)[2026-05-05]. https://www.ndcpa.gov.cn/jbkzzx/c100030/common/content/content_1658745812574605312.html.

[3] 国家卫生健康委. 全国护理事业发展规划(2021－2025年)[J]. 中华人民共和国国务院公报，2022(23)：57-63.

[4] Jagoda E，Dalibor F. Data subject rights according to the general data protection regulation[J]. Policija i sigurnost，2025，34(1)：78-87.

[5] 全国人民代表大会常务委员会. 中华人民共和国个人信息保护法[EB/OL]. (2021-08-20)[2026-05-05]. https://www.npc.gov.cn/npc/c2/c30834/202108/t20210820_313088.html.

[6] Konečný J，McMahan H B，Yu F X，et al. Federated learning：strategies for improving communication efficiency[C]//Proceedings of the International Conference on Learning Representations. Toulon：ICLR，2018.

[7] Rai D K，Kumar P，Gupta P，et al. Surveillance of central line associated bloodstream infection (CLABSI)：comparison of current (CDC/NHSN) and modified criteria：a prospective study[J]. J Anaesthesiol Clin Pharmacol，2022，39：349-354.

[8] Li P，Sun Z，Xu J. Unplanned extubation among critically ill adults：a systematic review and meta-analysis[J]. Intensive Crit Care Nurs，2022，70：103219.

[9] Heinzmann J，Rossen M L，Efthimiou O，et al. Risk factors for falls among hospitalized medical patients：a systematic review and meta-analysis[J]. Arch Phys Med Rehabil，2025，106(2)：292-299.

[10] Bhasin S，Gill T M，Reuben D B，et al. Strategies to Reduce Injuries and Develop Confidence in Elders (STRIDE)：a cluster-randomized pragmatic trial of a multifactorial fall injury prevention strategy：design and methods[J]. J Gerontol A Biol Sci Med Sci，2018，73(8)：1053-1061.

[11] Sun H，Depraetere K，Meesseman L，et al. Machine learning-based prediction models for different clinical risks in different hospitals：evaluation of live performance[J]. J Med Internet Res，2022，24(6)：e34295.

[12] Ong Ly C，Unnikrishnan B，Tadic T，et al. Shortcut learning in medical AI hinders generalization：method for estimating AI model generalization without external data[J]. NPJ Digit Med，2024，7(1)：124.

[13] 汪青松，张才华. 健康中国战略下医疗数据孤岛的平衡治理机制研究[J]. 社会科学研究，2025(4)：92-100.

[14] Smit J R，van der Graaf R，Mostert M，et al. Overcoming ethical and legal obstacles to data linkage in health

research:stakeholder perspectives[J]. Int J Popul Data Sci,2023,8(1):2151.
[15] Alderden J, Cummins M. Standardized nursing data and the oncology nurse[J]. Clin J Oncol Nurs,2016,20(3):336-338.
[16] Juhn E, Galvez E. Incentivizing data sharing among health plans, hospitals, and providers to improve quality[J]. Am J Manag Care,2022,28(12):e426-e427.
[17] Meystre S M, Ferrández Ó, Friedlin F J, et al. Text de-identification for privacy protection: a study of its impact on clinical text information content[J]. J Biomed Inform, 2014,50:142-150.
[18] Khokhar R H, Chen R, Fung B C M, et al. Quantifying the costs and benefits of privacy-preserving health data publishing[J]. J Biomed Inform,2014,50:107-121.
[19] Tarabichi Y, Frees A, Honeywell S, et al. The cosmos collaborative:a vendor-facilitated electronic health record data aggregation platform[J]. ACI Open, 2021,5(1):e36-e46.
[20] Li T, Sahu A K, Talwalkar A, et al. Federated learning: challenges, methods, and future directions[J]. IEEE Signal Process Mag,2020,37(3):50-60.
[21] Khan H, Kavati R, Pulkaram S S, et al. End-to-end privacy-aware federated learning for wearable health devices via encrypted aggregation in programmable networks [J]. Sensors,2025,25(22):7023.
[22] Huang M, Wang J, Nicholas S, et al. Development, status quo, and challenges to China′s health informatization during COVID-19:evaluation and recommendations[J]. J Med Internet Res,2021,23(6):e27345.
[23] Taha Z K, Yaw C T, Koh S P, et al. A survey of federated learning from data perspective in the healthcare domain: challenges, methods, and future directions[J]. IEEE Access,2023,11:45711-45735.
[24] Liu Y, Kang Y, Zou T, et al. Vertical federated learning: concepts, advances, and challenges [J]. IEEE Trans Knowl Data Eng,2024,36(7):3615-3634.
[25] Prayitno, Shyu C R, Putra K T, et al. A systematic review of federated learning in the healthcare area: from the perspective of data properties and applications[J]. Appl Sci,2021,11(23):11191.
[26] Kang Y, Liu Y, Wu Y, et al. Privacy-preserving federated adversarial domain adaptation over feature groups for interpretability[J]. IEEE Trans Big Data,2021,10:879-890.
[27] Li A, Song J, Zheng Z, et al. From local bias to global consensus:group-wise prototype federated learning under heterogeneous and cross-domain settings[J]. Inf Sci, 2026,741:123284.
[28] Shao J, Wu F, Zhang J. Selective knowledge sharing for privacy-preserving federated distillation without a good teacher[J]. Nat Commun, 2024,15(1):349.
[29] Pan S J, Yang Q. A survey on transfer learning[J]. IEEE Trans Knowl Data Eng,2010,22:1345-1359.
[30] Nanevski I, Jäger S, Schulte-Althoff M, et al. The potential of AI in nursing care: multicenter evaluation in fall risk assessment[J]. J Med Internet Res, 2025, 27: e71034.
[31] Sheikhalishahi S, Schwinn J, Morhart M, et al. Federated learning for predictive analytics in weaning from mechanical ventilation[J]. Stud Health Technol Inform, 2025,327:613-614.
[32] Pais V, Rao S, Muniyal B, et al. Federated learning using flower framework for enhanced medication safety in intensive care units[J]. Int J Data Sci Anal,2025,20(8):7039-7053.
[33] Alreshidi F S, Alsaffar M, Chengoden R, et al. Fed-CL: an atrial fibrillation prediction system using ECG signals employing federated learning mechanism[J]. Sci Rep, 2024,14(1):21038.
[34] Choudhury A, Janssen E R C, Bongers B C, et al. Colorectal cancer health and care quality indicators in a federated setting using the Personal Health Train[J]. BMC Med Inform Decis Mak,2024,24(1):121.
[35] Ye A, Deng Y, Li X, et al. The impact of informatization development on healthcare services in China[J]. Sci Rep,2024,14(1):31041.
[36] Edsberg L E, Black J M, Goldberg M, et al. Revised National Pressure Ulcer Advisory Panel Pressure Injury Staging System: revised pressure injury staging system [J]. J Wound Ostomy Continence Nurs, 2016, 43(6): 585-597.
[37] 肖爽,赵庆华,邹依然,等.多模态数据融合的护理信息系统架构及应用分析[J].护理学杂志,2020,35(19):88-90.
[38] Ben Othman S, Kennedy D M. Dynamic Weighted K-Asynchronous Federated Learning for privacy-preserving intrusion detection in wireless body area networks[J]. Cogn Comput,2026,18(1):66.
[39] Islam U, Ullah H, Khan N, et al. Adaptive federated learning framework for privacy-preserving consumer-centric IoMT: a novel secure data collaboration model [J]. IEEE Trans Consum Electron, 2025, 71(4): 10134-10151.
[40] Wu Z, Sun S, Wang Y, et al. FedCache: a knowledge cache-driven federated learning architecture for personalized edge intelligence[J]. IEEE Trans Mob Comput, 2024,23(10):9368-9382.
[41] Zhang F, Zhai D, Bai G, et al. Towards fairness-aware and privacy-preserving enhanced collaborative learning for healthcare[J]. Nat Commun,2025,16(1):2852.
[42] 王绍源,杨东航,任宇东.大语言模型在护理领域的应用场景与伦理探讨[J].护理学杂志,2025,40(5):108-113.
[43] Mohammed S, Malhotra N. Ethical and regulatory challenges in machine learning-based healthcare systems: a review of implementation barriers and future directions [J]. BenchCouncil Trans Benchmarks Stand Eval,2025,5(1):100215.

(本文编辑　宋春燕)