

DOI:10.13288/j.11-2166/r.2025.21.004

思路与方法

机器学习方法在治疗效果异质性分析中的应用及中医药领域适用性探讨

李牧之¹, 王思村¹, 和晓璐¹, 党海霞², 刘骏¹, 王忠¹, 于亚南¹✉

1. 中国中医科学院中医临床基础医学研究所, 北京市东城区东直门内南小街16号, 100700; 2. 中国中医科学院

[摘要] 治疗效果异质性 (HTE) 分析是对临床研究中不同患者群体治疗效果差异性表现的系统探索, 有助于推动个体化治疗策略的实施。机器学习方法对复杂交互作用的识别能力为 HTE 更准确、高效地获得治疗优势人群提供了可行路径。系统梳理了目前临床研究中 HTE 分析常用的机器学习模型, 归纳为惩罚回归模型、因果树模型、贝叶斯模型和元学习模型四种类型; 阐述了不同类别机器学习模型的优缺点及在 HTE 分析中的适用数据类型, 探讨了不同机器学习方法在中医药临床研究中的可能应用场景, 以期在中医药临床研究中应用 HTE 分析提供方法学支持。

[关键词] 治疗效果异质性分析; 机器学习; 惩罚回归模型; 因果树模型; 贝叶斯模型; 元学习模型

“精准医疗计划”及其倡导的“个性化医疗”理念已成为公共卫生领域的核心议题之一^[1]。个性化医疗强调基于患者个体差异制定诊疗策略, 旨在为不同个体提供针对性的疾病预防和治疗方案, 这一理念与中医药“辨证论治”“三因制宜”等原则高度契合。已有研究者将个性化医疗应用于中医消化道肿瘤防治, 通过区分疾病阶段及治疗状态实施差异化干预, 提升了患者满意度^[2]。个性化医疗的治疗策略源于对治疗效果异质性 (heterogeneity of treatment effects, HTE) 的考量, 即同种疗法在不同患者群体、亚组或个体间所产生的疗效存在差异的现象, 此差异可能源于患者的生理特征、病理状态、生活方式等多种因素^[3]。因此, 为实现个性化医疗, 研究者尝试在临床研究中开展 HTE 分析, 通过亚组分析和统计建模等方法, 对治疗效应的异质性进行系统性探索, 从而识别具有不同治疗获益的亚组^[4]。对有效药物, HTE 分析可精准定位响应人群; 对整体无效药物, 亦可能发掘潜在有效亚组^[5], 如附图 1 所示 (请扫描本文二维码获取)。在中医药临床研究中, HTE 分析的应用是中医药

“因人制宜”治疗理念的体现, 有助于实现目标人群的精准定位, 推动中医药临床研究证据向临床诊疗实践的转化。

目前中医药临床研究中的 HTE 分析仍以传统的亚组分析方法为主, 一次只能进行一个变量的分析, 无法充分揭示个体间治疗效果的非随机变异和变量间的相互作用^[6]。因此, 中医药临床研究在 HTE 分析方面仍然缺少科学的方法学指导, 如何科学地评估中医药治疗手段的治疗效果异质性, 并揭示其与辨证论治的关联, 已成为一个亟待解决的关键问题。机器学习 (machine learning, ML) 方法作为人工智能领域的重要组成部分, 为更准确、高效地筛选异质性人群提供了可行路径^[7]。本文通过系统整理 HTE 分析中常用的 ML 模型, 对其优缺点以及适用场景进行阐述, 旨在为中医药临床研究应用 HTE 分析提供方法学参考。

1 HTE 分析模型分类

当前 HTE 分析已在心理学^[8]和教育学^[9]领域得到了广泛的应用, 在不同数据类型中的分析方法也得到了初步的探索^[10-11]。ML 方法采用从示例中学习的形式, 通过将任务示例提供给计算系统, 使用学习算法创建模型^[12]。与传统预编程的建模方案相比, ML 方法采用数据驱动的方式, 能够一定

基金项目: 国家重点研发计划 (2025YFC3507905); 中国中医科学院基本科研业务费优秀青年科技人才 (创新类) 培养专项 (ZZ13-YQ-076); 国家自然科学基金 (82105052, 82474682)

✉ 通讯作者: yyn433@sina.com

程度上减少选择偏倚,使得 ML 模型在处理更大、更复杂的数据时表现出更优越的性能^[13]。目前 HTE 分析常用的 ML 模型可以根据基础模型差异分为惩罚回归模型、基于树结构的因果推断模型、贝叶斯统计模型和元学习模型四种类型,现对这四种 ML 模型进行介绍,为研究者在 HTE 分析时模型选择的思路提供参考。

1.1 惩罚回归模型

在识别 HTE 的传统统计学方法中, Cox 比例风险回归模型凭借其良好的可解释性,被广泛应用于临床生存数据的预测建模,但其线性假设在多协变量的情况下容易导致过拟合^[14]。而套索 (LASSO) 回归、岭 (Ridge) 回归、弹性网 (Elastic Net) 回归等惩罚模型可通过引入正则化惩罚项抑制过拟合,在部分高维数据分析中取代 Cox 模型应用^[15]。LASSO 回归在 Logistic 回归的基础上引入 L1 正则化,对回归系数 β 进行压缩,使绝对值较小的回归系数 β 变为 0,自动筛选变量并完成参数估计^[15]。Ridge 回归采用 L2 正则化,将所有系数均匀压缩,但不缩减为零,故无法进行变量选择^[16]。Elastic Net 回归模型则结合了 L1 正则化和 L2 正则化,通过调整混合参数可以在 LASSO 回归与 Ridge 回归模型之间灵活过渡^[17]。

1.2 基于树结构的因果推断模型

因果树模型作为最基础的基于树结构的因果推断模型,是一种结合传统决策树与因果推断理论框架的非参数模型,通过递归分割数据,自动捕捉变量间的复杂交互和非线性关系^[18]。该模型以数据驱动的方式构建分割规则,将样本划分为治疗效果不同的“叶节点”,节点中样本具有相似的治疗效果,如附图 2 (请扫描本文二维码获取) 所示。为避免过拟合偏倚,模型采用诚实估计策略,将样本分为训练集和估计集,分别用于确定分裂规则与计算组内平均处理效应。在此基础上发展而来的因果森林模型通过集成多棵树并随机选取部分协变量进行节点分裂,进一步提升了估计的精度与稳定性,但同时也牺牲了部分可解释性^[19]。

1.3 贝叶斯统计模型

此类模型在基础模型上引入贝叶斯框架,通过设置先验分布控制模型复杂度,防止过拟合,并借助后验分布提供预测的置信区间,量化不确定性^[20]。贝叶斯加性回归树 (bayesian additive regression trees, BART) 是一种结合了因果森林模型和贝叶斯统计的非参数模型^[21]。其树结构一般限制在 2 到 3 层,通过施加先验信息对树的生长过程进行约束,从而

实现较少的分支和更简洁的结构,产生预测能力有限的单棵决策树,而后通过后验概率加权集成,并借助马尔可夫链蒙特卡罗方法优化参数,最终输出加权平均预测值。贝叶斯因果森林模型 (bayesian causal forests, BCF) 作为贝叶斯加性回归树的扩展形式,不再侧重于一般预测,而是聚焦于处理效果的异质性,根据治疗组与对照组的效应差异进行分类,因此在建模前需明确区分处理状态^[22]。

1.4 元学习框架

元学习框架 (meta-learning framework, MLF) 由通用算法组成,将 HTE 分析问题分解为若干子问题,在处理高维数据时表现出较高的灵活性^[23]。框架基于线性回归等标准统计模型,其预测性能部分取决于所选用的基础学习器类型,常见包括 s 学习者 (s-learner)、t 学习者 (t-learner)、x 学习者 (x-learner)、r 学习者 (r-learner) 等^[24]。s-learner 使用单一模型整合全部样本特征进行预测;t-learner 则分别对治疗组和对照组拟合两个独立模型,以更灵活捕捉效应异质性;x-learner 在 t-learner 基础上引入交叉拟合和残差调整机制;r-learner 通过分解结果变量,将因果效应估计转化成带残差的回归问题。

2 中医药领域的 HTE 分析适用性及模型构建思考

2.1 中医药治疗与 HTE 分析的适配性

一直以来,患者的主观感受和个体差异在中医治疗中占据了重要地位^[25]。《素问·宝命全形论篇》云:“人以天地之气生,四时之法成”,将疾病与健康之本定位于人,以养人、调人为治病第一要义^[26]。在临床实践中,中医学贯彻“辨证论治”的思想,根据患者的体质特征、症状表现、居住环境等多维因素,灵活运用“同病异治”“异病同治”“三因制宜”等治则,制定个体化的诊疗方案,实现临床疗效的最大化和诊疗风险的精准控制^[27]。在以人为本思想的指导下,中医药临床研究广泛应用中医特色量表,以患者个体感受作为重要结局评价指标,充分体现以患者为中心的临床研究设计理念,与个性化医疗的核心思想高度契合^[28]。

在中医药临床研究中引入 HTE 分析,能进一步强化中医药研究中的个体化诊疗优势。通过将中医理论要素嵌入 HTE 模型构建过程,并在结果阐释时与病机、治则理论互验,可在一定程度上避免陷入过度依赖训练数据的特定分布所导致的“数据驱动陷阱”,有助于中医临床医生根据 HTE 分析结果,实现精准匹配患者个体特征 (如体质、兼症、舌脉、合并症、合并用药等) 的差异化治疗。HTE

分析的应用,既能提升中医药研究水平以达到国际循证医学标准,又可保持中医学整体观指导下的“人-病-证”三维度动态分析特色,是中医药临床研究方法学精准化与特色化发展并重的创新性发展方向。

2.2 中医药临床研究 HTE 模型的构建及思考

上述不同类型的 ML 模型为在临床研究中应用 HTE 分析提供了方法学基础,然而 HTE 分析在中医药临床研究中的应用仍然较为有限,相关方法学体系亟待完善。除了需要对数据类型、分布以及缺失数据的存在做出综合考虑,将方法移植于中医药研究场景中还需要纳入更多中医学导向的思考。HTE 分析中不同类型 ML 模型的优势、局限性及中医临床研究应用场景见附表 1(请扫描本文二维码获取)。

2.2.1 惩罚回归模型解析复方高维数据

HTE 分析常用的 ML 模型中,惩罚回归模型与传统基于回归的方法相同,需要预先指定感兴趣的协变量,通过压缩无关变量系数,惩罚回归模型能够在高维数据中有效剔除冗余变量,极大简化模型的结构。鉴于这一惩罚机制,当研究涉及大量潜在交互项,但仅有少数具有实际效用,尤其在关于中药复方成分与基因组学、代谢组学结合的情况下,协变量数量远超样本量,此时惩罚回归模型显得尤为适用,有望成为中药靶点、模块发现的有力选择。三种惩罚回归中, LASSO 回归通过强制满足交互分层条件(交互项仅在主效应存在时被保留),能更准确识别有意义的交互作用,在 HTE 分析中具有较大的因果推断潜力^[29]。Ridge 回归由于其不筛选变量的特点,适用于所有的变量都与结局高度相关,同时需要简化模型以提升模型泛化性能的情况。在 HTE 分析中, Ridge 回归更常见于对基因的数据分析,可为中药复方相关分子机制的探索提供有效的分析框架^[30]。与前两种相比较,综合了两种正则化函数的 Elastic Net 回归模型在处理和包含大量协变量的数据时更具优势^[31]。此外,惩罚回归模型利用协变量之间的交互作用建模,通过正则化函数实现变量选择,在预测疗效的同时能够对影响疗效的协变量进行重要性排序,这对医生在诊断过程中的决策具有重要的辅助作用。惩罚回归模型基于线性假设,适用于连续型终点、二元终点,或可结合泊松回归、有序逻辑回归等模型,应用于时间-事件终点、计数终点等终点类型^[32]。然而由于线性假设的固有局限性,其无法有效捕捉非线性关系,在样本量较小的情况下,还可能会受到 I 型误差膨胀的影响^[33]。如果已知协变量之间存在非线性关系,建议对惩罚回归模型的选择进行进一步的

审慎考量。

2.2.2 基于树结构的因果推断模型可视化决策规则

基于树的因果推断模型适用于非线性关系,无需预设协变量,适用于连续型结局数据、二分类结局数据,也可与其他模型结合应用于时间-事件结局数据、计数型或有序分类结局^[18]。树模型的结构使其能够对决策规则进行直观展示,在构建过程中亦能同步生成亚组疗效数值,是实现亚组疗效可视化的理想工具。如中医证素研究中,在需要对不同中医证素的重要性进行排序时,树模型能生成客观、可视化的决策依据,从而为中医临床辨证提供有益的思路。在涉及中医证候量表的研究中,可将不同证候视为独立的协变量构建树模型,有助于识别辨证分型中的关键证候。在树模型中,因果树模型生成单棵树结构,凭借一目了然的树状图,能够极大方便研究者对模型的解释,因此当医生根据患者的证候表现制定用药方案时,可以优先考虑在树模型中表现出对异质性影响较大的证候或者表现突出的患者^[34]。因果森林模型是目前 HTE 分析中应用最为广泛的模型^[35],能够有效降低单个因果树模型的不确定性,已有成熟的指南对其应用进行指导^[36]。但是由于生成大量因果树,因果森林模型在可解释性方面有所不足,实际应用时需要对其优势与局限性进行权衡。需要注意的是,树模型的应用依赖一定的样本量支持,对于缺失值也表现出较高的敏感性,在分析时应应对数据进行细致的预处理,以保障结果的可靠性和有效性。

2.2.3 贝叶斯统计模型融合人用经验证据

贝叶斯统计模型通过先验设置,平衡模型灵活性与稳健性,有效避免了过拟合问题,主要适用于连续型数据,如果需要应用于二分类结局、计数型结局数据,应通过泊松回归、Cox 比例风险模型等对其进行扩展^[37]。在临床研究中,通过贝叶斯先验整合专家知识,将中医人用经验转化为可量化参数,能够在增强模型推断可靠性的同时实现临床可解释性的提升,对于人用经验丰富的中成药相关临床研究尤为适用。除此之外,贝叶斯方法根据先验对后验数据及时调整,这与适应性设计根据基线特征或早期疗效数据动态调整后续阶段入组患者的富集型策略互补,适用于证候-方剂匹配的中医药临床探索,如旨在识别中成药应用于疾病的药物敏感证型,力图为中医药个体化治疗优化提供方案的临床研究。然而,相较于线性模型,贝叶斯方法具有更高的计算复杂度,其超参数的选择作为模型拟合过程中的一项不确定性,需要研究者在应用中仔细评估^[38]。

2.2.4 元学习框架协同多中心数据分析 建立在前述不同基础模型上的元学习框架能够灵活适应不同临床研究类型,其多模型协同应用的特性增加了计算量的同时使元学习框架尤其适用于多中心的数据整合,在中医药优势病种范围内因病例稀少、数据收集困难而难以研究的疑难疾病或罕见病证研究中,该框架可以将多个中心的小样本数据进行联合分析,在计算资源有保障的条件下可成为临床异质性研究的首选方法。

3 小结

随着研究者对于药物疗效异质性的理解加深,亚组分析已经逐渐成为临床研究中的重要组成部分。尽管如此,当前 HTE 分析大多基于事后分析,尚无法为新药研发提供足够充分的临床证据。若能在临床试验设计阶段前瞻性地整合 HTE 分析与富集策略,将有助于验证异质性的可靠性,并为药物目标人群的筛选提供科学指导,对个体化治疗具有重要的临床价值。ML 方法在高维协变量建模方面优势显著,尤其是中医临床研究中包含了症状、舌脉、体质等复杂的中医证素数据,ML 方法能量化不同证型特征在疗效预测中的权重,将复杂模型转化为可理解的决策规则,有效平衡预测性能与可解释性。本文系统构建了适用于中医药 HTE 分析的 ML 方法框架,可为该领域的研究提供方法学支持。在实际应用中,建议根据试验数据类型及疾病特点科学选择模型,以为试验统计分析增效。

参考文献

- [1] PACANOWSKI M, LIU Q. Precision medicine 2030[J]. Clin Pharmacol Ther, 2020, 107(1): 62-64.
- [2] 虞梦婷. 中医药精准医疗理念在消化道肿瘤防治中的应用价值[J]. 中医药管理杂志, 2023, 31(23): 138-140.
- [3] KENT DM, PAULUS JK, VAN KLAVEREN D, et al. The predictive approaches to treatment effect heterogeneity (PATH) statement[J]. Ann Intern Med, 2020, 172(1): 35-45.
- [4] LIPKOVICH I, DMITRIENKO A, D'AGOSTINO SRBR. Tutorial in biostatistics: data-driven subgroup identification and analysis in clinical trials[J]. Stat Med, 2017, 36(1): 136-196.
- [5] YARNELL CJ, FRALICK M. Heterogeneity of treatment effect: an evolution in subgroup analysis[J]. NEJM Evid, 2024, 3(4): EVIDe2400054.
- [6] 李宇飞, 张文倩, 张颖, 等. 中医药临床试验亚组分析设计和报告建议[J/OL]. 中国中西医结合杂志. (2025-06-17) [2025-08-29]. <https://link.cnki.net/urlid/11.2787.R.20250616.1656.004>.
- [7] INIESTA R, STAHL D, MCGUFFIN P. Machine learning, statistical learning and the future of biological research in psychiatry[J]. Psychol Med, 2016, 46(12): 2455-2465.
- [8] SUSUKIDA R, AMIN-ESMAEILI M, BADILLO-GOICOECHEA E, et al. Application of causal forest model to examine treatment effect heterogeneity in substance use disorder psychosocial treatments[J]. Int J Methods Psychiatr Res, 2025, 34(1): e70011.
- [9] GILBERT JB. Modeling item-level heterogeneous treatment effects: a tutorial with the glmer function from the lme4 package in R[J]. Behav Res Methods, 2024, 56(5): 5055-5067.
- [10] YANG J, MWANGI AW, KANTOR R, et al. Tree-based subgroup discovery using electronic health record data: heterogeneity of treatment effects for DTG-containing therapies[J]. Biostatistics, 2024, 25(2): 323-335.
- [11] BROOKS JM, CHAPMAN CG, CHEN BK, et al. Assessing the properties of patient-specific treatment effect estimates from causal forest algorithms under essential heterogeneity[J]. BMC Med Res Methodol, 2024, 24(1): 66.
- [12] SHILLAN D, STERNE JAC, CHAMPNETS A, et al. Use of machine learning to analyse routinely collected intensive care unit data: a systematic review[J]. Crit Care, 2019, 23(1): 284.
- [13] HU L, JI J, LI F. Estimating heterogeneous survival treatment effect in observational data using machine learning[J]. Stat Med, 2021, 40(21): 4691-4713.
- [14] WILLKE RJ, ZHENG Z, SUBEDI P, et al. From concepts, theory, and evidence of heterogeneity of treatment effects to methodological approaches: a primer[J]. BMC Med Res Methodol, 2012, 12(1): 185.
- [15] TIBSHIRANI R. Regression shrinkage and selection via the Lasso[J]. J R Stat Soc Series B Stat Methodol, 1996, 58(1): 267-288.
- [16] HOERL AE, KENNARD RW. Ridge regression: biased estimation for nonorthogonal problems[J]. Technometrics, 1970, 12(1): 55-67.
- [17] HUI ZOU, TREVOR HASTIE. Regularization and variable selection via the elastic net[J]. J R Statist Soc B, 2005, 67(2): 301-320.
- [18] ATHEY S, IMBENS G. Recursive partitioning for heterogeneous causal effects[J]. Proc Natl Acad Sci U S A, 2016, 113(27): 7353-7360.
- [19] WAGER S, ATHEY S. Estimation and inference of heterogeneous treatment effects using random forests[J]. J Am Stat Assoc, 2018, 113(523): 1228-1242.
- [20] PEARL J. Causality: Models, Reasoning, and Inference[M]. Cambridge: Cambridge University Press, 2009: 14.

- [21]CHIPMAN HA, GEORGE EI, MCCULLOCH RE. BART: Bayesian additive regression trees[J]. ANN APPL STAT, 2010. doi:10.1214/09-AOAS285.
- [22]HAHN PR, MURRAY JS, CARVALHO CM. Bayesian regression tree models for causal inference: regularization, confounding, and heterogeneous effects (with discussion)[J]. Bayesian Anal, 2020, 15(3): 965–1056.
- [23]HOSPEDALES T, ANTONIOU A, MICAELLI P, et al. Meta-learning in neural networks: a survey [J]. IEEE Trans Pattern Anal Mach Intell, 2022, 44(9): 5149–5169.
- [24]SALDITT M, ECKES T, NESTLER S. A tutorial introduction to heterogeneous treatment effect estimation with meta-learners [J]. Adm Policy Ment Health, 2024, 51(5): 650–673.
- [25]李牧之, 王思村, 党海霞, 等. 以患者为中心研究模式与适应性设计在中医药临床研究中的实践[J]. 世界临床药物, 2024, 45(12): 1213–1218.
- [26]祝世讷. 中医学原理探究[M]. 北京: 中国中医药出版社, 2019: 174.
- [27]王天芳. 中医辨证论治学基础[M]. 北京: 中国中医药出版社, 2016: 2.
- [28]许博文, 张潇潇, 李杰, 等. 基于优势人群的肿瘤中医药防治疗效提升策略[J]. 中医杂志, 2022, 63(4): 318–322.
- [29]DU Y, CHEN H, VARADHAN R. Lasso estimation of hierarchical interactions for analyzing heterogeneity of treatment effect[J]. Stat Med, 2021, 40(25): 5417–5433.
- [30]SUN C, ZHANG M, QIAO Q, et al. Integrating intrinsic radiosensitivity and immune status for predicting benefits of radiotherapy in head and neck squamous cell carcinoma [J]. Med Sci Monit, 2021, 27(1): e932126.
- [31]IRMAK ÖN B, HAVLA J, MANSMANN U. Multi-variable prognostic prediction of efficacy and safety outcomes and response to fingolimod in people with relapsing-remitting multiple sclerosis[J]. Mult Scler Relat Disord, 2025, 93(1): 106247.
- [32]ALI H, SHAHZAD M, SARFRAZ S, et al. Application and impact of Lasso regression in gastroenterology: a systematic review[J]. Indian J Gastroenterol, 2023, 42(6): 780–790.
- [33]VENKATASUBRAMANIAM A, MATEEN BA, SHIELDS BM, et al. Comparison of causal forest and regression-based approaches to evaluate treatment effect heterogeneity: an application for type 2 diabetes precision medicine [J]. BMC Med Inform Decis Mak, 2023, 23(1): 110.
- [34]TAGUCHI A, KATO K, FURUSAWA A, et al. Heterogeneous treatment effect of dose-dense paclitaxel plus carboplatin therapy for advanced ovarian cancer [J]. Int J Cancer, 2024, 155(6): 1068–1077.
- [35]SHIBA K, INOUE K. Harnessing causal forests for epidemiologic research: key considerations [J]. Am J Epidemiol, 2024, 193(6): 813–818.
- [36]JAWADEKAR N, KEZIOS K, ODDEN MC, et al. Practical guide to honest causal forests for identifying heterogeneous treatment effects [J]. Am J Epidemiol, 2023, 192(7): 1155–1165.
- [37]CARON A, BAILO G, MANOLOPOULOU I. Shrinkage bayesian causal forests for heterogeneous treatment effects estimation [J]. J Comput Graph Stat, 2022, 31(4), 1202–1214.
- [38]BLETTE BS, GRANHOLM A, LI F, et al. Causal bayesian machine learning to assess treatment effect heterogeneity by dexamethasone dose for patients with COVID-19 and severe hypoxemia [J]. Sci Rep, 2023, 13(1): 6570.

Application of Machine Learning Methods in Heterogeneity Treatment Effects Analysis and Their Applicability in Traditional Chinese Medicine

LI Muzhi¹, WANG Sicun¹, HE Xiaojun¹, DANG Haixia², LIU Jun¹, WANG Zhong¹, YU Yanan¹

1. Institute of Basic Research in Clinical Medicine, China Academy of Chinese Medical Sciences, Beijing, 100700; 2. China Academy of Chinese Medical Sciences

ABSTRACT Heterogeneity treatment effect (HTE) analysis systematically examines variations in treatment responses across different patient populations in clinical research, enabling the advancement of personalized treatment strategies. Machine learning methods, with their ability to identify complex interactions, provide an effective approach for more accurately and efficiently identifying responsive populations in HTE analysis. This article systematically reviewed machine learning models commonly used in HTE analysis within clinical research, categorizing them into four types, i. e. penalized regression models, causal tree models, Bayesian models, and meta-learning models. We also outlined the advantages, disadvantages, and suitable data types for each category within HTE analysis, and explored potential application scenarios for different machine learning methods in clinical research of traditional Chinese medicine (TCM), so as to provide methodological support for implementing HTE analysis in TCM clinical research.

Keywords heterogeneity treatment effects analysis; machine learning; penalized regression models; causal tree models; Bayesian models; meta-learning models

(收稿日期: 2025-04-16; 修回日期: 2025-08-25)

[编辑: 柴倩云]