

压力过程对抑郁状态的动态预测： 基于多层决策树^{*}

罗晓慧 胡月琴 刘红云

(北京师范大学心理学部; 应用实验心理北京市重点实验室;
心理学国家级实验教学示范中心〔北京师范大学〕, 北京 100875)

摘要 近年来, 抑郁预测的重要性日渐凸显。以往研究主要在个体间水平考察抑郁的风险因素, 本研究聚焦个体内水平, 结合压力这一关键因素以及日常压力过程模型, 构建压力过程对抑郁状态的动态预测模型。收集 356 名大学生 7 天(每天 5 次)的生态瞬时评估数据, 采用多层决策树的机器学习算法, 发现: (1)含忧虑消极情绪、压力源和反刍的模型能准确预测个体后续(3 小时后)有无抑郁状态; (2)不含情绪的预测模型中, 整合当前和预期压力应对、反刍、身体不适感和主观压力感受也能实现对抑郁状态的有效预测; (3)压力过程的多个成分会累积作用于个体, 共同预测后续的抑郁状态; (4)压力过程的累积均值和偏离值动态指标对抑郁状态预测有重要贡献。研究从动态视角开发抑郁状态的实时预警工具, 揭示多种压力过程因素协同预测的复杂组合和影响路径, 深化压力过程对抑郁状态复杂预测模式的理解。

关键词 压力过程, 抑郁, 多层决策树, 生态瞬时评估

分类号 B849: R395

1 引言

近年来, 抑郁已成为越来越普遍的心理健康问题。世界卫生组织(World Health Organization, WHO; 2023)的调查显示, 全球约有 5% 的成年人(约 2.8 亿人)患抑郁。根据《2023 年度中国精神心理健康》蓝皮书, 中国成年人的抑郁检出率为 10.6%。可见, 在现代社会的生活压力下, 抑郁问题日渐凸显且亟待解决。许多研究者指出, 预防是抑郁的有效应对策略之一(董健宇 等, 2020; 张伟霞 等, 2023)。这需要对潜在抑郁患者的抑郁状态进行准确预测, 并及时采取预防措施。

大量研究表明压力是抑郁的重要预测因素(Hammen, 2005, 2015; Vrshek-Schallhorn et al., 2020)。研究大多在个体间层面(inter-individual level), 关注压力对抑郁影响过程的调节因素, 以

识别抑郁的高风险个体(Hammen, 2005, 2015)。随着数据收集技术与统计分析方法的发展, 越来越多的研究采用日记法(daily diary)或生态瞬时评估法(ecological momentary assessment)收集密集追踪数据(intensive longitudinal data), 考察个体内层面(intra-individual level)的日常压力事件与个体抑郁状态的动态关联(Connolly & Alloy, 2017; Fuller-Tyszkiewicz et al., 2017; Luo et al., 2025)。

抑郁状态是指个体在日常生活中某一时刻所表现出的抑郁症状。密集追踪研究关注个体内抑郁症状随时间的动态波动与变化。以往研究揭示了对抑郁状态有重要预测作用的多种压力过程因素, 但缺乏对各种因素预测路径的整合考察(Almeida, 2024)。更重要的是, 虽然已有研究采用机器学习算法等提高对抑郁的预测准确性(Sau & Bhakta, 2019; De la Barrera et al., 2024), 但这些预测模型主要用

收稿日期: 2025-03-24

* 国家自然科学基金项目(32471145; 32171089; 32300938)。

通信作者: 刘红云, E-mail: hyliu@bnu.edu.cn; 胡月琴, E-mail: yueqinhu@bnu.edu.cn

于识别抑郁的高风险个体，而无法考察个体内抑郁状态的动态过程。考虑到个体内抑郁状态的发生发展和波动变化可以有效指导回答临床实践中“何时干预”和“对谁干预”的关键问题，有必要收集密集追踪数据并采用合适的机器学习算法，构建压力过程对抑郁状态的动态预测模型。

1.1 压力过程与抑郁状态的关系

从压力的动态视角，Almeida (2024)提出了日常压力过程模型(Daily Stress Process Model)，对日常压力相关的多种成分进行系统梳理。参考该过程模型(Almeida, 2024)，结合压力过程与抑郁状态在密集追踪情境波动特点与动态关联的实证证据，可归纳多种与抑郁状态存在动态关联的日常压力过程成分(见图 1)。其中，压力过程的第一阶段是压力源暴露(stressor exposure)，与个体抑郁状态的动态变化紧密相关。以往研究发现各个领域(如家庭、学校和同伴; Kiang & Buchanan, 2014)和各种类型的压力源(如人际压力源; Flook, 2011)对个体当天的抑郁状态都有显著的正向预测作用，即压力源与抑郁状态存在同期关联(Goldring & Bolger, 2021; Nezlek & Gable, 2001)。还有研究发现当个体遇到压力事件后，下一时段(几小时后)的抑郁状态水平更高，即压力源对抑郁状态还有滞后预测作用(Kang et al., 2023; Luo et al., 2025)。

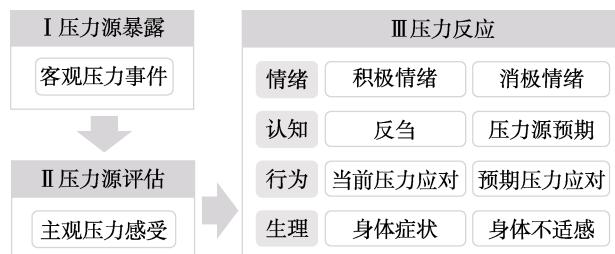


图 1 与抑郁状态存在动态关联的日常压力过程

压力过程的第二阶段是压力源评估(stressor appraisal)，指个体对压力源所带来的主观压力感受的评估，对预测个体抑郁状态有重要作用(Fuller-Tyszkiewicz et al., 2017; O'Hara et al., 2014)。评估主观压力感受有助于区分经历相等数量客观压力事件但主观感受程度不同的个体(Baker et al., 2020)。在客观压力事件的基础上，个体的主观压力感受对抑郁状态的预测有独特的贡献(Zawadzki et al., 2022)。

压力过程的第三阶段是压力反应(stress response)，包括个体对压力源的瞬时性和延续性反

应(Almeida, 2024)，可以分为情绪、认知、行为和生理四个方面。具体而言，在情绪方面，压力的情绪反应是指个体对于压力源在情绪方面的瞬时和延续反应。大量研究表明压力的情绪反应对个体的抑郁状态有重要预测作用。基于个体重复测量的积极和消极情绪的平均水平与个体的抑郁症状紧密相关(Cooke et al., 2022; Merz & Roesch, 2011)，且个体经历日常压力源后更低的积极情绪(Rackoff & Newman, 2020)和更高的消极情绪(Charles et al., 2013; Parrish et al., 2011; Starr et al., 2024)能显著预测个体数月甚至数年后的抑郁症状。在认知方面，抑郁的认知易感性压力模型(cognitive vulnerability-stress model of depression; Abramson et al., 1989; Beck, 2002)认为，个体的认知易感性会与个体经历的压力事件产生交互作用，共同影响其抑郁状态。反刍(rumination)是压力过程中与抑郁状态紧密相关的典型认知易感性因素(Nolen-Hoeksema et al., 2008)，是指个体对自我、感受和不安经历的长时间、反复消极的思考(Watkins, 2008)。近期针对状态性反刍的密集追踪研究发现，当个体遭遇压力事件且对压力经历有较多反刍时，个体会表现出较高的抑郁状态水平(Connolly & Alloy, 2017, 2018)。这表明日常压力事件与个体状态反刍之间也会产生动态交互，共同预测个体的抑郁状态。除了反刍这一回顾性的压力认知反应，另一种前瞻性的压力认知反应是压力源预期。压力源预期(stressor anticipation)是指个体对未来压力事件的预期(Kramer et al., 2022)。大量研究表明，对压力源的预期会产生与经历真实压力源相似的效果，对个体带来生理以及情绪和认知等心理层面的消极影响(Kramer et al., 2022; Neubauer et al., 2018)。在行为方面，研究发现个体自我报告的当前压力应对情况能显著正向预测同时期和后续的悲伤等消极状态(Zawadzki et al., 2022)，以及个体后续的抑郁状态(Fuller-Tyszkiewicz et al., 2017)。此外，还有研究揭示了压力过程中的预期压力应对在预测个体后续健康相关行为时的独特作用(Pannicke et al., 2021)。在生理方面，研究发现个体的抑郁状态与其身体症状存在同时的相互影响(Goldring & Bolger, 2021)。在有抑郁或焦虑症状的群体中，个体的抑郁状态与其身体症状之间还存在滞后的动态交互(Luo et al., 2025)。

此外，压力事件和/或压力反应随时间的累积(accumulation)，或称压力堆积(pileup; Smyth et al.,

2018, 2023), 也值得关注。以往关于压力过程成分的研究指出, 压力过程因素的累积对个体的健康状态有重要预测作用。例如, Almeida 等人(2020)发现, 压力事件和压力的消极情绪反应各自和共同的累积都能有效预测个体后续更低的身体活动水平, 而压力的消极情绪反应本身没有显著的预测作用。这表明, 单个压力过程因素的累积和多个压力过程因素共同的累积, 都可能对抑郁状态的动态预测有重要贡献。然而, 目前仍缺乏在密集追踪情境中探讨压力累积与抑郁状态间关联的研究, 尚不清楚哪些压力过程因素自身的累积或相互之间的叠加能预测更高的抑郁状态风险。因此, 有必要考察压力过程因素的累积对个体抑郁状态的影响, 以深化对于压力过程与抑郁状态间动态关联模式的理解。

虽然已有大量研究探讨了日常压力过程中的客观压力事件、主观压力感受和 4 种压力反应(情绪、认知、行为和生理反应)对抑郁状态的预测作用, 但仍缺乏对日常压力过程与个体抑郁状态的整合研究。因此, 仍不清楚哪些压力过程因素在抑郁状态预测中发挥主要作用, 以及哪些因素(及其累积)对预测效果可能存在独特贡献。考虑到压力过程与抑郁状态的复杂关系, 以及对抑郁状态的识别与预防的重要性, 亟需系统考察压力过程与抑郁状态的动态关联机制, 构建对个体抑郁状态的实时预测与决策模型。

1.2 抑郁状态的动态预测

对抑郁的预测研究大多基于个体对过去一段时间内平均抑郁水平的回顾性测量, 这可能忽视了个体抑郁状态随时间波动变化的过程中有助于预测的关键信息(Aan het Rot et al., 2012; Jimenez et al., 2022)。此外, 关于压力与抑郁关系的研究越来越关注个体在日常生活中经历的压力事件的影响, 并强调考察个体内动态压力过程和抑郁状态变化的重要性(Connolly & Alloy, 2017; Zawadzki et al., 2022)。因此, 近年来有研究开始收集密集追踪数据来更好地捕捉压力过程和抑郁状态的动态变化。

密集追踪数据(intensive longitudinal data)是指个体内重复测量次数较多(如, 大于 10 次或 20 次)的追踪数据。研究者通常采用日记法(一天一次)或生态瞬时评估(一天多次)等方法(Bolger & Laurenceau, 2013; Shiffman et al., 2008)记录个体在日常生活中多种状态的变化过程。与回顾性测量和实验室操纵相比, 这些方法具有高生态效度、低回忆偏差、能实时监测等重要优势(Bolger & Laurenceau, 2013;

Shiffman et al., 2008)。更重要的是, 密集追踪数据中蕴含着关于个体内动态过程的丰富信息, 在抑郁状态的实时预测方面具有重要潜力。

然而, 密集追踪数据的复杂数据结构也对抑郁预测模型的构建提出挑战。密集追踪数据有重复测量(个体内水平)嵌套于个体(个体间水平)的多层次结构。以往收集密集追踪数据的抑郁预测研究仅对预测变量进行密集追踪, 而对结果变量(即个体抑郁情况)进行单次测量, 故预测变量为多层次结构, 而结果变量仍为每个个体一个数据点的单层结构(Asare et al., 2022; De la Barrera et al., 2024; Groen et al., 2019; Horwitz et al., 2023; Shin & Bae, 2023)。因此, 这些研究采用各种方法将每个个体多个数据点的预测变量整合为每个个体一个数据点, 进而在个体间水平采用机器学习算法进行抑郁预测建模。

但考虑到抑郁状态在日常生活中的动态变化(Aan het Rot et al., 2012; Jimenez et al., 2022), 有必要对抑郁状态(结果变量)及其预测变量均进行密集追踪, 以构建抑郁状态的实时预测模型。此时, 抑郁预测模型中的预测变量和结果变量均为多层次数据结构。以往抑郁预测研究采用的机器学习算法未考虑多层次数据中个体内观测不独立的问题, 无法直接用于这类密集追踪数据的建模分析(Hu & Szymczak, 2023)。

对此, 有研究者提出了广义线性混合模型树(generalized linear mixed model (GLMM) tree; Fokkema et al., 2018, 2021)。这种机器学习算法基于广义线性混合效应模型构建决策树, 是一种基于模型的递归分区算法(model-based recursive partitioning algorithm; Zeileis et al., 2008)。一方面, 广义线性混合模型(GLMM)能有效考虑数据的多层次结构, 并允许模型中的截距和斜率在个体间存在差异(即可估计随机截距和随机斜率); 另一方面, 决策树作为经典的机器学习算法, 其重要优势在于树状结构具有较高的可解释性, 且可基于大量预测变量灵活构建预测模型并提供实践决策指导。广义线性混合模型树(GLMM 树)综合了 GLMM 和决策树的多种优势, 将决策树算法拓展运用于多层次的情境。以往研究演示了如何运用 GLMM 树分析横断多层次数据(如, 病人嵌套于不同治疗方案或治疗中心; Fokkema et al., 2018; 2021)或长时追踪数据(间隔数月或数年的重复测量嵌套于个体; Fokkema & Zeileis, 2024), 但尚无研究将此方法应用于密集追踪情境来预测抑郁状态。本研究尝试采用此算法分

析密集追踪数据, 以构建压力过程对抑郁状态的动态预测模型。

1.3 研究目的

本研究旨在采用生态瞬时评估法和多层决策树, 构建大学生日常压力过程对抑郁状态的动态预测模型。以往抑郁预测研究多聚焦于个体间水平的风险因素(Sau & Bhakta, 2019), 但近年来研究开始强调在个体日常生活中识别异常心理健康状态并提供及时干预的重要性(Nahum-Shani et al., 2018)。本研究首先采用生态瞬时评估法收集密集追踪数据, 在个体内水平捕捉个体压力过程和抑郁状态随时间的动态变化。随后, 采用多层决策树分析数据, 在考虑多层嵌套数据结构(即重复测量嵌套于个体), 以及个体一般抑郁水平差异(即估计随机截距)的情况下, 构建动态压力过程对个体抑郁状态的实时预测模型。为了充分考察个体日常压力过程的动态特点及其对抑郁状态的预测效果, 研究在得到每个压力过程因素的实时分数后, 还计算了每个因素的累积均值(即每个个体该因素截止至当前时刻的均值)和偏离值(即每个个体该因素当前时刻的分数相对于此刻累积均值的差值), 作为进一步描述日常压力过程的动态特征指标, 以实现对个体抑郁状态更准确的预测。更重要的是, 为了对个体近期的潜在抑郁状态进行有效地预测与预警, 研究构建了当前时刻的压力过程动态特征对下一时刻(约 3 小时后)的抑郁状态的动态预测模型, 以期为抑郁状态的预防和干预提供实践决策的支持。

2 方法

2.1 研究对象与程序

研究对象为 356 名中国大学生(75.84% 为女性), 平均年龄为 20.66 岁($17\sim25$, $SD = 1.64$), 84.88% 为本科生。研究通过问卷星平台发布被试招募问卷, 并在社交媒体平台进行宣传, 招募有意愿的在校大学生参与研究。招募过程未限制参与者的学校、所在地等, 但要求参与者每天可以较为自由地使用手机(以便接收在线问卷信息并及时填写)。

首先, 每位参与者均签署知情同意书, 并填写一份包括人口统计学信息的调查问卷。在随后的 7 天内, 参与者每天 11 点、14 点、17 点、20 点和 23 点通过智能手机收到带有问卷链接的信息, 并报告他们自上次填写问卷以来的抑郁和压力相关状态。最终, 在参与者收到的所有问卷中($N = 12460$; 356 名参与者 \times 35 份问卷), 完成率为 90.59% (完成

11288 份问卷), 即参与者们表现出较高的遵从率, 这也对应较低的缺失比例(所有变量的缺失率均为 $1 - 90.59\% = 9.41\%$)。每位参与者在完成研究后获得 70 元被试费作为报酬。本研究未进行预注册。本研究获得了伦理委员会的批准。

2.2 测量工具

考虑到以往研究发现生态瞬时评估中较长的问卷会增加参与者的负担并损害数据质量(Eisele et al., 2022), 削弱研究结果的可靠性和有效性, 本研究尽可能选择题量较少的工具测量研究关心的变量。

2.2.1 结果变量

采用两题版患者健康问卷(Patient Health Questionnaire-2, PHQ-2; Löwe et al., 2005)测量个体的抑郁状态。参与者需根据自己的真实感受, 从 0 (“几乎没有”)到 4 (“非常多”)对两项题目描述(“对做事情没有兴趣或乐趣”; “感到沮丧、抑郁或无望”)进行 5 点评分。由于抑郁状态两道题的总分呈现明显的正偏态分布, 且表示有无的二分类变量有助于临床实践的干预决策, 因此根据总分是否为 0 将抑郁状态重新编码为二分类变量。0 表示无抑郁状态, 1 表示有抑郁状态。

2.2.2 预测变量

对于压力过程的第一个阶段(压力源暴露), 测量客观压力事件。采用针对大学生群体编制的日常压力源清单(Baker et al., 2020)评估压力源暴露情况。该清单包括关于各类日常压力事件的 9 个题项(包括“学业任务太多”、“为未来或职业道路做准备”、“准备或参加了考试或小测验”、“平衡学业和其他责任”、“为未来或职业道路做准备”、“工作上遇到问题”、“获得比预期低的分数”、“财务相关问题”、“人际关系问题(如, 与同学、家人、恋人、上级等)”), 研究还询问参与者是否有任何其它未列出的压力事件)。参与者需要用 0 (“否”)或 1 (“是”)表明自上次填写问卷以来是否经历过这些压力源。最终计算所有题项的总分。

对于压力过程的第二个阶段(压力源评估), 测量主观压力感受。对于报告的压力源, 参与者需要考虑这些压力事件对他/她产生的压力有多大, 从 1(“完全没压力”)到 7(“非常有压力”)进行评分。

对于压力过程的第三个阶段(压力反应), 测量参与者在情绪、认知、行为和生理这 4 个方面的压力反应。在情绪方面, 基于简版积极消极情绪量表(the short-form of the Positive and Negative Affect Schedule (PANAS); Thompson, 2007), 参考以往研究

发现的积极和消极情绪的个体内维度结构(Cooke et al., 2022), 并综合考虑题项的维度含义代表性、动态情境适用性、表述易理解性等, 选取适用于本研究的状态情绪题项。具体而言, 分别采用2个情绪词测量积极(“果断的”和“备受鼓舞的”)和消极(“害怕的”和“心神不宁的”)情绪。参与者需要从1(“几乎没有”)到5(“非常多”)对各个情绪词进行评分。由于对积极消极情绪动态测量结构的研究表明, 状态消极情绪在个体内水平包括恐惧(fear)和忧虑(distress)两个子维度(Cooke et al., 2022), 故对积极情绪采用两个题项的平均分, 而对消极情绪则分别采用两题各自的得分描述恐惧和忧虑两个子维度的得分。

在认知方面, 参考以往研究(Blanke et al., 2022)测量状态反刍(“自上次填写问卷以来, 我无法停止对某些事情的思考, 或思考我的感受”), 参与者从1(“完全没有”)到7(“非常多”)进行评分。此外, 参考以往对压力源预期的研究(Kramer et al., 2022), 要求参与者从1(“完全不预期”)到7(“非常预期”), 预期自己多大程度上在接下来的几个小时内会发生一些紧张或不愉快的事情。

在行为方面, 参考以往研究(Pannicke et al., 2021), 采用改编自感知压力量表(the Perceived Stress Scale, PSS; Cohen et al., 1983)的2个题项分别测量个体的当前压力应对和预期压力应对, 参与者从1(“完全没有把握”)到7(“非常有把握”)进行评分。

在生理方面, 参考以往研究中的身体症状清单(Goldring & Bolger, 2021; Larsen & Kasimatis, 1991), 采用9个题项对个体的压力生理反应进行客观评估。研究还询问了参与者是否有任何其它未列出的身体症状。参与者需要用0(“否”)或1(“是”)表明自上次填写问卷以来是否出现各种身体症状(如头痛、腹泻和其它胃肠道症状等), 最终计算所有题项的总分。此外, 参与者还需进行相应的主观评估, 即从0(“没有不适感”)到100(“不适感非常强”)对身体症状造成的不适程度进行评价。

2.2.3 动态指标

对于压力过程的上述11个预测变量, 研究基于每个个体各个压力过程因素的实时分数, 进一步计算了个体各因素的累积均值和偏离值。累积均值是指个体某个压力过程因素从初始时刻($t_0 = 1$)到当前时刻(t)的所有观测分数的平均值, 反映了个体在过去一段时间内该压力过程因素的平均水平, 其值越大表明个体过去一段时间该因素的整体水平较高。偏离值是指个体某个压力过程因素在当前时

刻(t)的实时数值与从初始时刻到此时($t_0 \sim t$)的累积均值的差值, 反映了个体该压力过程因素当前瞬时水平相对过去一段时间平均水平的偏离情况, 其值大于(或小于)0表明个体当前该压力过程因素水平高于(或低于)过去一段时间该因素的整体水平。举例而言, 若个体某压力过程因素在前3个时间点的实时分数分别为2、1、3, 则该压力过程因素第三个时间点的瞬时水平为3, 累积均值为2($= (2 + 1 + 3) / 3$), 偏离值为1($= 3 - 2$)。累积均值和偏离值是基于个体自身以往情况计算得到的压力过程动态指标, 能有效反映不同个体的压力过程变化情况。综合考虑每个压力过程因素的实时分数、累积均值和偏离值可以更充分地体现压力过程的动态特点, 有助于实现对个体抑郁状态更准确的预测。

2.3 数据分析

2.3.1 数据准备

数据准备阶段对数据进行预处理, 并作初步分析。首先运用R 4.2.2(R Core Team, 2021)中的imputeTS程序包(Moritz & Bartz-Beielstein, 2017), 采用卡尔曼滤波法对有时序依赖性的数据进行缺失值插补。随后, 对于压力过程中的11个预测变量(压力源暴露、主观压力评估、积极情绪、消极情绪(恐惧)、消极情绪(忧虑)、反刍、压力源预期、当前压力应对、预期压力应对、身体症状和身体不适感), 分别计算每个个体的各个变量截止至 t 时刻的累积均值, 以及 t 时刻分数相对于此刻累积均值的偏离值, 作为对压力过程动态特征的进一步考察。此外, 为了构建有时间滞后的抑郁状态预测模型(即采用 t 时刻的压力过程变量预测 $t+1$ 时刻的抑郁状态), 生成一阶滞后的抑郁状态分数。最后, 采用psych程序包(Revelle, 2017)对重复测量嵌套于个体的多层次数据进行描述统计分析, 计算群体总均值、个体间标准差、组内相关(intraclass correlation, ICC), 以及个体内水平和个体间水平不同变量间相关。

2.3.2 模型拟合

本研究采用广义线性混合模型树(GLMM树)算法拟合多层次决策树, 构建对抑郁状态的动态预测模型。这种算法的特点是运用每个终端节点内的观测数据对参数的固定效应进行局部估计, 而运用所有观测数据对参数的随机效应进行全局估计(Fokkema et al., 2018)。关于随机效应的选取, 由于本研究不重点关注或预期某个体内变量对抑郁状态预测作用的个体间差异, 故研究仅纳入抑郁状态的随机截距(即, 个体抑郁状态平均水平的个体间

差异), 而不考虑随机斜率。下面以仅含随机截距的 GLMM 树为例介绍此算法的主要流程(同时含随机截距和随机斜率的 GLMM 树算法流程类似, 具体可参见 Fokkema 和 Zeileis (2024) 的研究)。此研究中, 个体 i ($i = 1, 2, \dots, 356$) 抑郁状态的期望(μ_i) 可以表示为:

$$g(\mu_i) = X_i \beta_j + Z_i \theta_i \quad (1)$$

其中, μ_i 为 $T \times 1$ 的向量, 表示个体 i 在各个 t ($t = 1, 2, \dots, 35$; $T = 35$) 时刻抑郁状态的期望, g 表示链接函数; X_i 为个体 i 的固定效应设计矩阵, 含 T 行、 $(p + 1)$ 列(1 用来表示截距, p 表示时变预测变量的数量); β_j 为个体 i 所在的终端节点 j ($j = 1, 2, \dots, J$; J 表示终端节点的数量) 局部估计的固定效应系数, 为 $(1 + p) \times 1$ 的向量, 其第一个元素为随机截距的固定部分, 其余元素为各个预测变量的固定斜率; Z_i 为个体 i 的随机效应设计矩阵, 在随机效应仅为随机截距时, 即为 $T \times 1$ 的向量且元素均为 1; θ_i 是全局估计的个体 i 的随机效应, 即随机截距的随机部分, 假设满足均值为 0, 方差为 σ^2 的正态分布。仅含随机截距的 GLMM 树的估计步骤如下:

(1) 设置 r 的初始值为 0, 并设置 $\hat{\theta}_{i,(r)}$ 为 0;

(2) 设置 $r = r + 1$ 。以 $Z_i \hat{\theta}_{i,(r-1)}$ 为偏移量(offset), 拟合不考虑截距随机效应的广义线性模型树(GLM 树), 得到分区结果 $j_{(r)}$ 。得到分区结果的过程遵循基于模型的递归分区算法的一般步骤, 具体可参见 Zeileis 等人(2008) 和 Fokkema 等人(2018) 的介绍;

(3) 基于上一步得到的分区结果 $j_{(r)}$, 拟合 GLMM ($g(\mu_i) = X_i \beta_{j,(r)} + Z_i \theta_{i,(r)}$), 得到固定效应系数($\hat{\beta}_{j,(r)}$) 和随机截距的随机部分($\hat{\theta}_{i,(r)}$) 的估计值;

(4) 重复第 2 到 3 步, 直至模型收敛。可以通过第 3 步中 GLMM 的对数似然考察模型的收敛情况。当第 2 步中 GLM 树的分区结果 $j_{(r)}$ 与上一次迭代的分区结果 $j_{(r-1)}$ 相同时, 模型通常已收敛。

总的来说, GLMM 树算法在每次迭代中, 先拟合 GLM 树(第 2 步), 再拟合 GLMM 估计参数的固定和随机效应(第 3 步), 如此交替拟合 GLM 树和 GLMM 直至收敛。该算法的具体实现采用 R 中的 *glmertree* 程序包(Fokkema et al., 2018, 2021)。在本研究中, 预测变量包括 11 个压力过程的 3 个动态特征指标(t 时刻预测变量的值、累积均值和偏离值), 共 33 个预测变量; 结果变量为后续($t + 1$ 时刻)的二分类抑郁状态。模型允许每个个体的抑郁状态平均值存在个体间差异(考虑随机截距)。拟合 GLM 树时设置分区变量参数不稳定性检验的显著性水平

为 0.05, 并对多重检验进行 Bonferroni 校正(默认设置; Fokkema et al., 2018)。采用限制性极大似然估计(默认估计方法)得到 GLMM 中的固定和随机效应。关于随机效应的初始值, 研究考察了程序包的默认设置(初始值为 0) 和初始值为传统混合效应模型估计值时的结果, 不同初值设置下结果相对稳定, 最终选择预测效果略优且较常用的默认设置。此外, 研究采用 3×3 网格搜索法调整算法参数得到最优预测模型, 最终设置 GLMM 树的终端节点最小观测数量为 30, 最大数深度为 5。

2.3.3 模型评价

为了评价模型表现, 进行分块和分层的五折交叉验证。由于传统的 k 折交叉验证不适用于观测间有相互依赖性的多层次数据结构(在本研究中, 重复观测嵌套于个体, 个体内的多次观测间相互不独立), 因此采用分块的交叉验证, 使得每个个体的所有观测被分配到同一折中。又由于结果变量的不平衡(如 0 和 1 的占比差异较大)可能会影响交叉验证的结果, 故采用分层的交叉验证, 使得每个折中抑郁状态风险较高和较低水平的个体占比相等或相近(具体操作为不同折之间个体有抑郁状态次数的占比的中位数相等)。整个分块和分层的五折交叉验证重复 5 次以获得更稳定和准确的结果。最终, 采用灵敏度、特异性和 ROC 曲线下面积(AUC)对模型表现进行评价。灵敏度描述了模型能正确识别出有抑郁状态的概率, 特异性描述了模型能正确识别出无抑郁状态的概率。ROC 曲线下面积体现了模型对于有和无抑郁状态的区分能力, 若值为 0.5 表示几乎没有区分能力(即随机水平), 越接近 1 表示区分准确性越高。为了确定能得到最优的模型灵敏度和特异性的结果变量概率判定标准(指判定为有/无抑郁状态的概率标准), 采用 *pROC* 程序包(Robin et al., 2011)并基于“最接近左上角”的原则来确定结果变量的概率临界值。

3 结果

3.1 描述统计分析

压力过程预测变量(原始分数)与抑郁状态(含原始分数和下一时刻的二分类值)的描述统计和相关分析结果见表 1。组内相关系数的结果显示, 这些变量有 50%~70% 的变异在个体间水平。相关分析的结果显示, 除积极情绪外的所有预测变量与结果变量在个体间和个体内水平均存在显著的相关关系($ps < 0.001$)。

表1 压力过程与抑郁状态的描述统计和相关分析

变量	<i>M</i> (<i>SD</i>)	ICC	1	2	3	4	5	6	7	8	9	10	11	12	13
1 压力源暴露	1.26 (1.03)	0.63	—	0.50***	-0.01	0.12***	0.21***	0.16***	0.19***	-0.13***	0.33***	0.23***	0.18***	0.07***	
2 主观压力评估	3.59 (1.25)	0.52	0.67***	—	-0.11***	0.21***	0.29***	0.23***	-0.32***	0.33***	-0.24***	0.25***	0.32***	0.31***	0.08***
3 积极情绪	2.82 (1.00)	0.70	-0.10	-0.29***	—	-0.05***	-0.11***	-0.05***	0.16***	-0.10***	0.12***	-0.10***	-0.15***	-0.17***	-0.06***
4 消极情绪(恐惧)	1.46 (0.69)	0.63	0.39***	0.55***	-0.11***	—	0.43***	0.15***	-0.12***	0.14***	-0.12***	0.13***	0.17***	0.31***	0.09***
5 消极情绪(忧虑)	1.71 (0.75)	0.56	0.42***	0.60***	-0.22***	0.90***	—	0.21***	-0.18***	0.20***	-0.16***	0.18***	0.24***	0.39***	0.10***
6 反刍	3.59 (1.45)	0.69	0.41***	0.66***	-0.16***	0.50***	0.56***	—	-0.14***	0.14***	-0.10***	0.14***	0.16***	0.20***	0.08***
7 压力源预期	4.58 (1.05)	0.53	-0.32***	-0.61***	0.53***	-0.49***	-0.54***	-0.51***	—	-0.20***	0.43***	-0.12***	-0.19***	-0.19***	-0.07***
8 当前压力应对	3.23 (1.18)	0.53	0.40***	0.63***	-0.13***	0.58***	0.61***	0.57***	-0.47***	—	-0.32***	0.14***	0.21***	0.20***	0.06***
9 预期压力应对	4.80 (1.00)	0.51	-0.34***	-0.58***	0.48***	-0.50***	-0.54***	-0.48***	0.94***	-0.50***	—	-0.10***	-0.17***	-0.16***	-0.07***
10 身体症状	0.91 (0.95)	0.61	0.57***	0.51***	-0.24***	0.46***	0.53***	0.38***	-0.34***	0.41***	-0.36***	—	0.55***	0.22***	0.06***
11 身体不适感	19.71 (16.59)	0.58	0.44***	0.60***	-0.25***	0.56***	0.61***	0.45***	-0.39***	0.52***	-0.39***	0.72***	—	0.27***	0.07***
12 抑郁状态(<i>t</i>)	1.70 (0.75)	0.65	0.41***	0.58***	-0.24***	0.87***	0.90***	0.55***	-0.55***	0.61***	-0.56***	0.51***	0.59***	—	0.13***
13 抑郁状态(<i>t</i> +1)	0.54 (0.36)	0.50	0.34***	0.51***	-0.19***	0.62***	0.71***	0.50***	-0.47***	0.57***	-0.47***	0.39***	0.48***	0.81***	—

注: 抑郁状态(*t*)为当前抑郁状态的连续分数值, 抑郁状态(*t*+1)为下一时刻抑郁状态的二分类值(0表示无抑郁状态; 1表示有抑郁状态)。*M*为全局均值, *SD*为个体特定均值的个体间标准差; ICC 为组内相关系数。相关矩阵对角线下方为个体间相关, 对角线上方为个体内相关。*** *p* < 0.001。

3.2 预测模型结果与评价

图 2 呈现了表现最优的抑郁状态预测模型 I。在 5 次五折交叉验证中，该模型的平均灵敏度为 0.80 ($SD = 0.03$)，平均特异性为 0.64 ($SD = 0.05$)，平均 AUC 为 0.80 ($SD = 0.02$)。这表明该模型正确识别有抑郁状态的概率较高，正确识别无抑郁状态的概率可以接受，且能较为准确地区分有无抑郁状态。具体而言，该模型显示有 3 种路径表明个体在下一时段可能出现抑郁状态：(1) 个体的消极情绪(忧虑)累积均值有一些(> 1.85 ; 此解读基于测量量表计分点的实际含义，下同)；(2) 个体的消极情绪(忧虑)累积均值较低(≤ 1.85)，压力源的累积均值较低(≤ 0.75)，且当前消极情绪(忧虑)略高于累积平均水平(偏倚值 > 0.24)；(3) 个体的消极情绪(忧虑)累积均值较低(≤ 1.85)，压力源的累积均值较高(> 0.75 ; 表明累积平均每 3 个小时可能经历约 1 个压力事件)，且有一定程度的反刍(> 2.08)。这一预测模型表明，运用压力过程的 3 个因素(即，消极情绪(忧虑)、压力源和反刍)及其动态特征即可有效预测个体后续的抑郁状态，且各种压力过程动态特征在抑郁状态的动态预测中都发挥着重要作用。

在预测模型 I 中还可观察到，忧虑的消极情绪对后续抑郁状态的预测发挥着关键作用。然而，以往研究发现，有抑郁状态的个体更少地表露他们的

情绪状态(Kahn & Garrison, 2009; Macdonald & Morley, 2001)，且他们在频繁报告情绪状态时会感知到较高水平的负担和侵入性(De Girolamo et al., 2020; Van Genugten et al., 2020)。此外，在监控和预测抑郁状态的实际研究中，频繁测量个体的积极消极情绪可能存在操作上的困难。因此，本研究尝试去除预测变量中的积极和消极情绪，进一步探索不含情绪状态的抑郁状态预测模型。

3.3 补充分析

图 3 呈现了不含情绪预测变量的抑郁状态预测模型。该模型在 5 次五折交叉验证中，平均灵敏度为 0.72 ($SD = 0.03$)，平均特异性为 0.67 ($SD = 0.03$)，平均 AUC 为 0.76 ($SD = 0.03$)。这表明去除积极消极情绪的模型 II 对抑郁状态的预测效果略有下降，但仍能较为准确地区分个体有无抑郁状态的情况。根据模型 II，有 3 种路径表明个体在下一时段可能出现抑郁状态：(1) 个体有中等及以上的当前压力应对的累积均值(> 3.12)，但也有中等及以上的主观压力感受(> 3.02)；(2) 个体有中等及以上的当前压力应对的累积均值(> 3.12)，较低的主观压力感受(≤ 3.02)，但有一定程度的反刍(> 2.97)；(3) 个体当前压力应对的累积均值较低(≤ 3.12)，预期压力应对的累积均值中等或较低(≤ 5.77)，且有一定程度的身体不适感(> 21.20)。

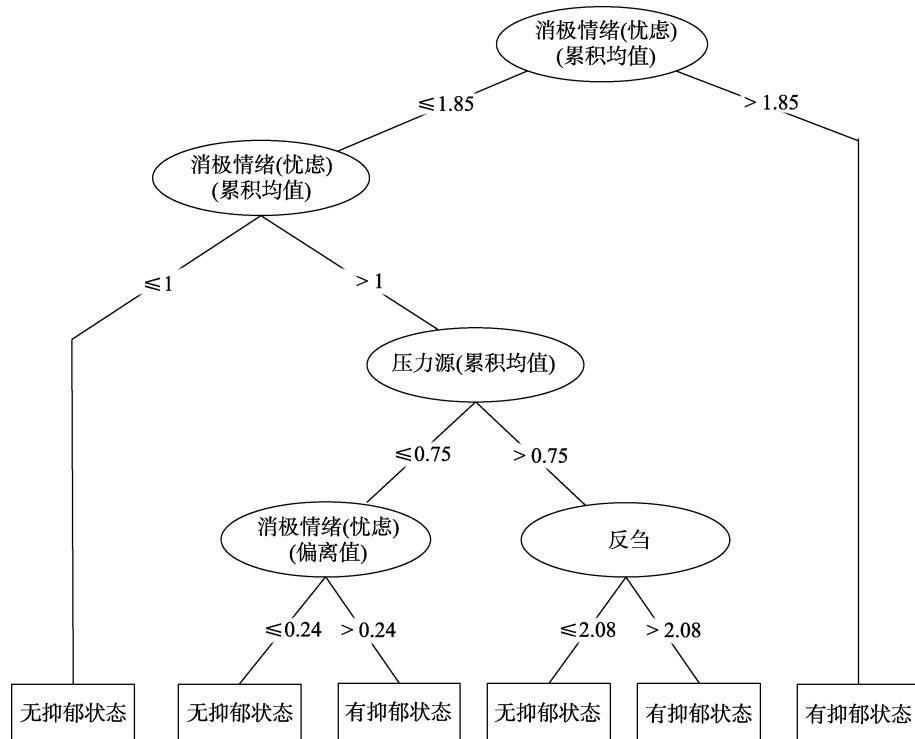
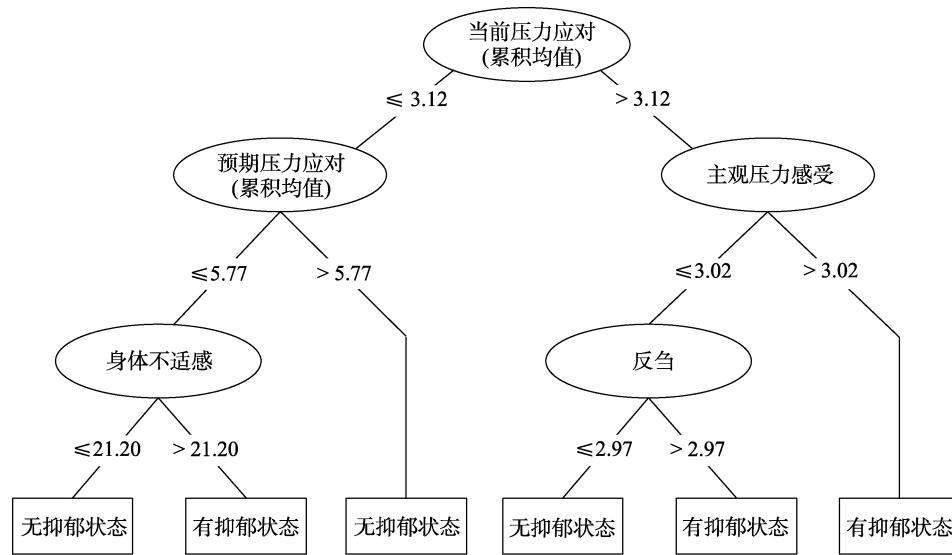


图 2 压力过程(t)对抑郁状态($t + 1$)的动态预测模型 I

注：所有分区变量的参数不稳定性(parameter instability)检验的 p 值均小于 0.001。

图3 压力过程(t)对抑郁状态($t+1$)的动态预测模型Ⅱ

注: 预测变量中不含积极和消极情绪及其动态特征, 所有分区变量的参数不稳定性检验的 p 值均小于 0.001。

4 讨论

本研究首次基于多层决策树(即 GLMM 树), 构建大学生日常压力过程对其抑郁状态的动态预测模型。研究发现含情绪状态的最佳预测模型 I ($AUC = 0.80$) 揭示了对抑郁状态有关键预测作用的压力过程因素: 消极情绪(忧虑; 压力情绪反应)、压力源和反刍(压力认知反应)。不含情绪状态的预测模型 II 也表现出较好的预测效果($AUC = 0.76$), 表明综合当前和预期压力应对(压力行为反应)、反刍(压力认知反应)、身体不适感(压力生理反应)和主观压力感受也可以实现对个体抑郁状态较为准确的预测。此外, 研究结果表明, 除了压力过程的当前水平, 其累积均值和偏离值这些动态特征在抑郁状态的实时预测中也起到重要作用。本研究从压力过程与抑郁状态之间关系的理论基础出发, 采用数据驱动的机器学习算法, 系统探究了压力过程对抑郁状态的复杂预测模式, 为个体在日常生活中抑郁状态的动态预测提供了有效的决策工具, 对抑郁预测相关的理论和实践研究都有重要贡献。

4.1 抑郁状态动态预测的重要发现

研究首先发现, 日常压力过程中的各个成分对个体抑郁状态的预测都有不同程度的贡献。其中, 忧虑这种消极情绪是个体后续抑郁状态最强的风险因素。以往也有大量研究发现消极情绪与抑郁状态存在较强的正向关联(Cooke et al., 2022; Merz & Roesch, 2011; Starr et al., 2024), 这与本研究的结果一致。更重要的是, 本研究基于状态消极情绪的恐

惧-忧虑两维度结构(Cooke et al., 2022), 进一步揭示忧虑这种消极情绪在抑郁状态的动态预测中发挥重要作用, 而恐惧情绪对抑郁状态的预测作用相对较弱。这启示情绪相关的抑郁干预实践应聚焦于个体的忧虑情绪进行设计和实施, 且未来研究应根据更精细的消极情绪结构探究其与个体状态的动态关联。此外, 在抑郁状态的动态预测中, 个体经历的压力源的累积均值和个体当前的反刍水平也发挥着独特作用。当个体有中等水平的忧虑情绪累积均值, 过去一段时间持续经历着日常压力事件(本研究中平均每 3 个小时经历接近 1 个压力事件), 且最近时段有较多的反刍, 则个体很可能在下一阶段表现出抑郁状态。这与持续性认知假说(perseverative cognition hypothesis)的观点相一致, 即个体的反刍会加剧和延长压力源对个体健康的消极影响(Brosschot et al., 2006), 且与抑郁等多种临床症状的发生和维持都有密切的关系(Watkins & Roberts, 2020)。

以忧虑消极情绪为主导的模型对抑郁状态有最佳的预测效果, 但研究发现不含情绪因素的模型也能达到较好的预测效果。具体来说, 可以综合日常压力过程中行为、认知和生理层面的压力反应以及主观压力感受较为准确地预测个体后续的抑郁状态。在不含情绪的抑郁状态预测模型中, 当前压力应对和预期压力应对的累积均值是最初有分类作用的核心节点, 是预测抑郁状态的关键因素。当个体在过去一段时间内的当前和预期压力应对情况都相对较差(即累积均值较低)时, 个体相对较高

的身体不适感(略高于所有个体在所有时刻的平均观测水平)预示着其后续较高的抑郁状态风险水平。以往研究发现个体的抑郁状态与身体症状在不同时间尺度上都存在一定的相互作用和动态关联(Goldring & Bolger, 2021; Long et al., 2018; Luo et al., 2025),本研究进一步发现当个体近期的平均压力应对情况较差时,其生理层面的不适感能有效预测后续的抑郁状态。此外,即使个体过去一段时间的当前压力应对情况较好,若个体主观上感知到较高水平的压力,或压力感知较低但反刍水平较高,个体后续仍有较高的抑郁状态风险。这表明,压力过程的不同成分可能会通过复杂的组合关系对个体后续的抑郁状态产生影响。

事实上,本研究的抑郁状态预测模型表明,日常压力过程的多个成分会累积作用于个体,共同预测其后续的抑郁状态风险。以往有研究发现,压力过程成分的累积对个体健康状态(如,身体活动水平;Almeida et al., 2020)的动态预测有独特贡献。本研究也发现了类似的现象,即个体的忧虑(压力消极情绪反应)和经历的压力事件能叠加预测其后续更高的抑郁状态风险。此外,本研究还揭示了其它压力过程预测个体后续抑郁状态的多种复杂组合和作用路径(如压力应对不良与身体不适感对抑郁状态的共同预测),促进了对压力过程和抑郁状态间复杂关系和影响机制更系统和深入的认识,推动压力过程累积风险相关理论的构建与发展。

此外,压力过程的累积均值和偏离值这些动态特征在抑郁状态预测中的作用也值得关注。在抑郁状态的动态预测模型中,个体的忧虑情绪、压力源,以及当前和预期压力应对的累积均值在预测路径的初始阶段起到了关键作用,忧虑情绪在当前时刻相对于个体累积平均水平的偏离值也能进一步辅助预测个体下一时间段的抑郁状态。这表明,在树状结构的抑郁状态预测模型中,预测的初始阶段主要依据某些压力过程因素在过去一段时间内的整体平均水平。而在预测路径的末端,模型则大多基于各种压力过程因素在临近时刻的瞬时水平或相对平均水平的偏离值,进行更精细的辅助判断。可见,压力过程的瞬时水平、累积均值和偏离值可以在预测个体抑郁状态风险时相互补充完善。这也启示未来研究可结合预测因素的多种动态特征,以实现更准确有效的动态预测(Czyz et al., 2023)。

4.2 研究的理论与实践贡献

本研究在理论和实践方面均具有重要贡献。在

理论方面,本研究从动态的视角丰富拓展了以往关于压力与抑郁之间关系的研究,深化了压力过程对抑郁状态复杂预测机制的理解。首先,本研究通过整合分析多种日常压力过程因素及其动态特征,系统揭示了对抑郁状态预测有关键作用的压力过程因素,以及不同因素的复杂组合对抑郁状态风险的协同预测作用,促进对于压力过程的累积风险理论(Smyth et al., 2018, 2023)的认识与发展。其次,本研究通过生态瞬时评估,在微观时间尺度上(数小时)捕捉个体日常生活中压力过程与抑郁状态的动态波动,并考察压力过程对下一时间段抑郁状态的短时滞后预测作用。由于压力与抑郁在不同时间尺度(从微观的天内水平到宏观的跨年水平)均有独特意义,且个体的宏观发展变化结果(如,患抑郁症)是相应微观动态波动过程(如,日常压力对抑郁状态的短时影响)的长期作用结果(Hammen, 2015; Jeronimus, 2019; Wichers, 2014),本研究对压力与抑郁间短时作用模式的深入考察有助于在多重时间尺度上进一步理解压力与抑郁间关系和抑郁的动态变化过程。此外,本研究基于压力过程提出累积均值和偏离值这些动态指标,在个体中心的视角下为个体抑郁状态的动态预测提供了新的指标构建与理论构建思路。对于压力与抑郁间关系的已有研究主要关注压力相关的抑郁风险因素(即,变量中心的视角)。本研究基于个体内动态压力过程,针对每个个体的压力过程提出累积均值和偏离值的动态指标。这些基于个体自身以往情况(如,偏离值反映个体当下水平相对于自身以往平均水平的波动)计算的压力过程动态指标能有效反映不同个体的压力变化情况。本研究发现的不同动态指标对抑郁状态预测的独特贡献,有助于拓展压力过程对抑郁状态预测的指标构建思路,进而在个体中心的视角下发展构建基于个体内压力累积水平或波动过程的压力与抑郁关系理论。

在实践方面,本研究结合多层决策树和生态瞬时评估,构建了兼具可解释性和预测效果的抑郁状态实时预警模型,为个体潜在抑郁状态的实时监测与识别提供了有效的决策工具。虽然以往也有研究采用生态瞬时评估记录个体日常生活中抑郁相关状态(Asare et al., 2022; De la Barrera et al., 2024; Groen et al., 2019; Horwitz et al., 2023; Shin & Bae, 2023),但这些研究基于密集追踪数据得到的预测指标仅用于预测单次测量的抑郁症状,最终仍局限在个体间水平考察对抑郁症状有预测作用的个体

特征。本研究在此基础上进一步考察个体水平, 探究多种压力过程及其动态指标对个体后续抑郁状态的实时预测, 可有效回答临床干预实践中“何时需要干预”和“谁需要干预”的关键问题。此外, 本研究探讨了自然生活情境下压力对抑郁的短时滞后预测作用, 可以为快速发展的数字化干预(Moshe et al., 2021)和及时适应性干预(Nahum-Shani et al., 2018)提供实证支持。近年来, 数字化干预和及时适应性干预得到了越来越多的发展与应用。这些干预依托于信息技术和移动设备的快速发展, 重视对个体自然生活情境下脆弱性状态(states of vulnerability)的实时动态监测, 常常在一天内进行多次状态评估与干预反馈(如, 每天进行3次评估; Ben-Zeev et al., 2014)。但此类干预方案在开发时常常缺乏较好的实证和理论支持(Riley, 2015)。本研究基于个体日常生活压力过程构建的抑郁状态动态预测模型, 揭示了对个体后续抑郁状态有重要预测作用的关键压力因素和协同作用模式, 可为基于压力的数字化和及时适应性的抑郁干预方案提供实证支持, 指导设计更合理和有针对性的干预方案。

4.3 局限与展望

本研究仍存在一些局限。其一, 本研究中压力过程和抑郁状态的测量均采用自我报告法, 可能会受到共同方法偏差的影响。未来研究可考虑采用可穿戴设备等对个体的压力和抑郁状态相关生理指标进行更客观的测量(Asare et al., 2022)。其二, 本研究在线上平台通过自愿参与的方式招募被试, 对被试所在学校和地区等的平衡可能不足, 这会对本研究大学生样本的代表性产生一定影响。因此, 可以在更好地控制地区等因素的大学生样本中, 进一步探究抑郁状态的动态预测模型。其三, 本研究采用卡尔曼滤波插补缺失数据, 虽然考虑了密集追踪数据的时序依赖特点, 但可能无法体现多变量时间序列间的关系。考虑到目前仍缺乏基于多层决策树等机器学习算法对缺失数据处理方法的系统探讨, 而合理处理缺失数据对密集追踪数据分析很重要, 未来研究可以针对这类预测模型和数据特点探究开发合适的缺失数据处理方法和工具。最后, 本研究考虑的日常压力过程及其动态特征指标有限。比如, 吴朝毅和王振(2024)系统梳理了情绪相关的多种动态指标(如, 情绪变异性、情绪惯性等), 并总结了抑郁症临床人群和健康人群在这些动态指标上的群体差异。在个体水平, 这些

指标一段时间内的实时变化分数也有望运用于个体后续抑郁状态的动态预测。未来研究可以更全面地考察日常压力过程及其动态特征指标, 以更综合地探究动态压力过程对个体抑郁状态的预测和决策模型。

参 考 文 献

- Aan het Rot, M., Hogenelst, K., & Schoevers, R. A. (2012). Mood disorders in everyday life: A systematic review of experience sampling and ecological momentary assessment studies. *Clinical Psychology Review*, 32(6), 510–523.
- Abramson, L. Y., Metalsky, G. I., & Alloy, L. B. (1989). Hopelessness depression: A theory-based subtype of depression. *Psychological Review*, 96(2), 358–372.
- Almeida, D. M. (2024). The time is now for integrative multilayered stress research and mitigation. *Frontiers in Science*, 2, 1389481.
- Almeida, D. M., Marcusson-Clavertz, D., Conroy, D. E., Kim, J., Zawadzki, M. J., Sliwinski, M. J., & Smyth, J. M. (2020). Everyday stress components and physical activity: Examining reactivity, recovery and pileup. *Journal of Behavioral Medicine*, 43(1), 108–120.
- Asare, K. O., Moshe, I., Terhorst, Y., Vega, J., Hosio, S., Baumeister, H., ... Ferreira, D. (2022). Mood ratings and digital biomarkers from smartphone and wearable data differentiates and predicts depression status: A longitudinal data analysis. *Pervasive and Mobile Computing*, 83, 101621.
- Baker, M. R., Nguyen-Feng, V. N., Nilakanta, H., & Frazier, P. A. (2020). Childhood maltreatment predicts daily stressor exposure in college students but not perceived stress or stress reactivity. *Journal of Counseling Psychology*, 67(1), 79–89.
- Beck, A. T. (2002). Cognitive models of depression. In R. L. Leahy & E. T. Dowd (Eds.), *Clinical Advances in Cognitive Psychotherapy: Theory and Application* (pp. 29–61). Springer Publishing Company.
- Ben-Zeev, D., Brenner, C. J., Begale, M., Duffecy, J., Mohr, D. C., & Mueser, K. T. (2014). Feasibility, acceptability, and preliminary efficacy of a smartphone intervention for schizophrenia. *Schizophrenia Bulletin*, 40(6), 1244–1253.
- Blanke, E. S., Neubauer, A. B., Houben, M., Erbas, Y., & Brose, A. (2022). Why do my thoughts feel so bad? Getting at the reciprocal effects of rumination and negative affect using dynamic structural equation modeling. *Emotion*, 22(8), 1773–1786.
- Bolger, N., & Laurenceau, J. P. (2013). *Intensive longitudinal methods: An introduction to diary and experience sampling research*. Guilford Press.
- Brosschot, J. F., Gerin, W., & Thayer, J. F. (2006). The perseverative cognition hypothesis: A review of worry, prolonged stress-related physiological activation, and health. *Journal of Psychosomatic Research*, 60(2), 113–124.
- Charles, S. T., Piazza, J. R., Mogle, J., Sliwinski, M. J., & Almeida, D. M. (2013). The wear and tear of daily stressors on mental health. *Psychological Science*, 24(5), 733–741.
- Cohen, S., Kamarck, T., & Mermelstein, R. (1983). A global measure of perceived stress. *Journal of Health and Social Behavior*, 24(4), 385–396.
- Connolly, S. L., & Alloy, L. B. (2017). Rumination interacts with life stress to predict depressive symptoms: An ecological

- momentary assessment study. *Behaviour Research and Therapy*, 97, 86–95.
- Connolly, S. L., & Alloy, L. B. (2018). Negative event recall as a vulnerability for depression: Relationship between momentary stress-reactive rumination and memory for daily life stress. *Clinical Psychological Science*, 6(1), 32–47.
- Cooke, E. M., Schuurman, N. K., & Zheng, Y. (2022). Examining the within-and between-person structure of a short form of the positive and negative affect schedule: A multilevel and dynamic approach. *Psychological Assessment*, 34(12), 1126–1137.
- Czyz, E. K., Koo, H. J., Al-Dajani, N., King, C. A., & Nahum-Shani, I. (2023). Predicting short-term suicidal thoughts in adolescents using machine learning: Developing decision tools to identify daily level risk after hospitalization. *Psychological Medicine*, 53(7), 2982–2991.
- De Girolamo, G., Barattieri di San Pietro, C., Bulgari, V., Dagni, J., Ferrari, C., Hotopf, M., ... Zarbo, C. (2020). The acceptability of real-time health monitoring among community participants with depression: A systematic review and meta-analysis of the literature. *Depression and Anxiety*, 37(9), 885–897.
- De la Barrera, U., Arrigoni, F., Monserrat, C., Montoya-Castilla, I., & Gil-Gómez, J. A. (2024). Using ecological momentary assessment and machine learning techniques to predict depressive symptoms in emerging adults. *Psychiatry Research*, 332, 115710.
- Dong, J., Wei, W., Wu, K., Ni, N., Wang, C., Fu, Y., & Peng, X. (2020). The application of machine learning in depression. *Advances in Psychological Science*, 28(2), 266–274.
- [董健宇, 韦文棋, 吴珂, 妮娜, 王粲霏, 付莹, 彭歆. (2020). 机器学习在抑郁症领域的应用. *心理科学进展*, 28(2), 266–274.]
- Eisele, G., Vachon, H., Lafit, G., Kuppens, P., Houben, M., Myin-Germeys, I., & Viechtbauer, W. (2022). The effects of sampling frequency and questionnaire length on perceived burden, compliance, and careless responding in experience sampling data in a student population. *Assessment*, 29(2), 136–151.
- Flook, L. (2011). Gender differences in adolescents' daily interpersonal events and well-being. *Child Development*, 82(2), 454–461.
- Fokkema, M., Edbrooke-Childs, J., & Wolpert, M. (2021). Generalized linear mixed-model (GLMM) trees: A flexible decision-tree method for multilevel and longitudinal data. *Psychotherapy Research*, 31(3), 329–341.
- Fokkema, M., Smits, N., Zeileis, A., Hothorn, T., & Kelderman, H. (2018). Detecting treatment-subgroup interactions in clustered data with generalized linear mixed-effects model trees. *Behavior Research Methods*, 50(5), 2016–2034.
- Fokkema, M., & Zeileis, A. (2024). Subgroup detection in linear growth curve models with generalized linear mixed model (GLMM) trees. *Behavior Research Methods*, 56, 6759–6780.
- Fuller-Tyszkiewicz, M., Karvounis, T., Pemberton, R., Hartley-Clark, L., & Richardson, B. (2017). Determinants of depressive mood states in everyday life: An experience sampling study. *Motivation and Emotion*, 41, 510–521.
- Goldring, M. R., & Bolger, N. (2021). Physical effects of daily stressors are psychologically mediated, heterogeneous, and bidirectional. *Journal of Personality and Social Psychology*, 121(3), 722–746.
- Groen, R. N., Snippe, E., Bringmann, L. F., Simons, C. J. P., Hartmann, J. A., Bos, E. H., & Wichers, M. (2019). Capturing the risk of persisting depressive symptoms: A dynamic network investigation of patients' daily symptom experiences. *Psychiatry Research*, 271, 640–648.
- Hammen, C. L. (2005). Stress and depression. *Annual Review of Clinical Psychology*, 1, 293–319.
- Hammen, C. L. (2015). Stress and depression: Old questions, new approaches. *Current Opinion in Psychology*, 4, 80–85.
- Horwitz, A. G., Kentopp, S. D., Cleary, J., Ross, K., Wu, Z., Sen, S., & Czyz, E. K. (2023). Using machine learning with intensive longitudinal data to predict depression and suicidal ideation among medical interns over time. *Psychological Medicine*, 53(12), 5778–5785.
- Hu, J., & Szymczak, S. (2023). A review on longitudinal data analysis with random forest. *Briefings in Bioinformatics*, 24(2), bbad002.
- Jeronimus, B. F. (2019). Dynamic system perspectives on anxiety and depression. In Kunnen, E. S., De Ruiter, N. M., Jeronimus, B. F., & Van der Gaag, M. A (Eds.), *Psychosocial development in adolescence: Insights from the dynamic systems approach* (pp. 100–126). Routledge.
- Jimenez, A., McMahon, T. P., Watson, D., & Naragon-Gainey, K. (2022). Dysphoria and well-being in daily life: Development and validation of ecological momentary assessment scales. *Psychological Assessment*, 34(6), 546–557.
- Kahn, J. H., & Garrison, A. M. (2009). Emotional self-disclosure and emotional avoidance: Relations with symptoms of depression and anxiety. *Journal of Counseling Psychology*, 56(4), 573–584.
- Kang, J. E., Graham-Engeland, J. E., Scott, S., Smyth, J. M., & Sliwinski, M. J. (2023). The relationship between loneliness and the experiences of everyday stress and stressor-related emotion. *Stress and Health*, 40(2), e3294.
- Kiang, L., & Buchanan, C. M. (2014). Daily stress and emotional well-being among Asian American adolescents: Same-day, lagged, and chronic associations. *Developmental Psychology*, 50(2), 611–621.
- Kramer, A. C., Neubauer, A. B., Scott, S. B., Schmiedek, F., Sliwinski, M. J., & Smyth, J. M. (2022). Stressor anticipation and subsequent affective well-being: A link potentially explained by perseverative cognitions. *Emotion*, 22(8), 1787–1800.
- Larsen, R. J., & Kasimatis, M. (1991). Day-to-day physical symptoms: Individual differences in the occurrence, duration, and emotional concomitants of minor daily illnesses. *Journal of Personality*, 59(3), 387–423.
- Long, E. E., Young, J. F., & Hankin, B. L. (2018). Temporal dynamics and longitudinal co-occurrence of depression and different anxiety syndromes in youth: Evidence for reciprocal patterns in a 3-year prospective study. *Journal of Affective Disorders*, 234, 20–27.
- Löwe, B., Kroenke, K., & Gräfe, K. (2005). Detecting and monitoring depression with a two-item questionnaire (PHQ-2). *Journal of Psychosomatic Research*, 58(2), 163–171.
- Luo, X., Ma, J., & Hu, Y. (2025). A dynamic bidirectional system of stress processes: Feedback loops between stressors, psychological distress, and physical symptoms. *Health Psychology*, 44(2), 154–165.
- Macdonald, J., & Morley, I. (2001). Shame and non-disclosure: A study of the emotional isolation of people referred for psychotherapy. *British Journal of Medical Psychology*, 74(1), 1–21.
- Merz, E. L., & Roesch, S. C. (2011). Modeling trait and state variation using multilevel factor analysis with PANAS daily diary data. *Journal of Research in Personality*, 45(1),

- 2–9.
- Moritz, S., & Bartz-Beielstein, T. (2017). imputeTS: Time series missing value imputation in R. *The R Journal*, 9(1), 207–218.
- Moshe, I., Terhorst, Y., Philipp, P., Domhardt, M., Cuijpers, P., Cristea, I., ... Sander, L. B. (2021). Digital interventions for the treatment of depression: A meta-analytic review. *Psychological Bulletin*, 147(8), 749–786.
- Nahum-Shani, I., Smith, S. N., Spring, B. J., Collins, L. M., Witkiewitz, K., Tewari, A., & Murphy, S. A. (2018). Just-in-time adaptive interventions (JITAIs) in mobile health: Key components and design principles for ongoing health behavior support. *Annals of Behavioral Medicine*, 52(6), 446–462.
- Neubauer, A. B., Smyth, J. M., & Sliwinski, M. J. (2018). When you see it coming: Stressor anticipation modulates stress effects on negative affect. *Emotion*, 18(3), 342–354.
- Nezlek, J. B., & Gable, S. L. (2001). Depression as a moderator of relationships between positive daily events and day-to-day psychological adjustment. *Personality and Social Psychology Bulletin*, 27(12), 1692–1704.
- Nolen-Hoeksema, S., Wisco, B. E., & Lyubomirsky, S. (2008). Rethinking rumination. *Perspectives on Psychological Science*, 3(5), 400–424.
- O'Hara, R. E., Armeli, S., Boynton, M. H., & Tennen, H. (2014). Emotional stress-reactivity and positive affect among college students: The role of depression history. *Emotion*, 14(1), 193–202.
- Pannicke, B., Kaiser, T., Reichenberger, J., & Blechert, J. (2021). Networks of stress, affect and eating behaviour: Anticipated stress coping predicts goal-congruent eating in young adults. *International Journal of Behavioral Nutrition and Physical Activity*, 18, 1–14.
- Parrish, B. P., Cohen, L. H., & Laurenceau, J. P. (2011). Prospective relationship between negative affective reactivity to daily stress and depressive symptoms. *Journal of Social and Clinical Psychology*, 30(3), 270–296.
- R Core Team. (2021). *R: A language and environment for statistical computing*. Available at: <https://www.r-project.org/index.html>.
- Rackoff, G. N., & Newman, M. G. (2020). Reduced positive affect on days with stress exposure predicts depression, anxiety disorders, and low trait positive affect 7 years later. *Journal of Abnormal Psychology*, 129(8), 799–809.
- Revelle, W. R. (2017). psych: Procedures for personality and psychological research. Software.
- Riley, W. T. (2015). Theoretical models to inform technology-based health behavior interventions. In Riley, W. T (Ed.), *Behavioral healthcare and technology: Using science-based innovations to transform practice* (pp. 13–23). Oxford University Press.
- Robin, X., Turck, N., Hainard, A., Tiberti, N., Lisacek, F., Sanchez, J. C., & Müller, M. (2011). pROC: An open-source package for R and S+ to analyze and compare ROC curves. *BMC Bioinformatics*, 12, 1–8.
- Sau, A., & Bhakta, I. (2019). Screening of anxiety and depression among seafarers using machine learning technology. *Informatics in Medicine Unlocked*, 16, 100228.
- Shiffman, S., Stone, A. A., & Hufford, M. R. (2008). Ecological momentary assessment. *Annual Review of Clinical Psychology*, 4, 1–32.
- Shin, J., & Bae, S. M. (2023). A systematic review of location data for depression prediction. *International Journal of Environmental Research and Public Health*, 20(11), 5984.
- Smyth, J. M., Sliwinski, M. J., Zawadzki, M. J., Scott, S. B., Conroy, D. E., Lanza, S. T., ... Almeida, D. M. (2018). Everyday stress response targets in the science of behavior change. *Behaviour Research and Therapy*, 101, 20–29.
- Smyth, J. M., Zawadzki, M. J., Marcusson-Clavertz, D., Scott, S. B., Johnson, J. A., Kim, J., ... Almeida, D. M. (2023). Computing components of everyday stress responses: Exploring conceptual challenges and new opportunities. *Perspectives on Psychological Science*, 18(1), 110–124.
- Starr, L. R., Santee, A. C., Chang, K. K., & DeLap, G. A. L. (2024). Everyday emotion, naturalistic life stress, and the prospective prediction of adolescent depression. *Anxiety, Stress, and Coping*, 37(4), 487–500.
- Thompson, E. R. (2007). Development and validation of an internationally reliable short-form of the positive and negative affect schedule (PANAS). *Journal of Cross-cultural Psychology*, 38(2), 227–242.
- Van Genugten, C. R., Schuurmans, J., Lamers, F., Riese, H., Penninx, B. W., Schoevers, R. A., ... Smit, J. H. (2020). Experienced burden of and adherence to smartphone-based ecological momentary assessment in persons with affective disorders. *Journal of Clinical Medicine*, 9(2), 322–335.
- Vrshek-Schallhorn, S., Ditcheva, M., & Corneau, G. (2020). Stress in depression. In Harkness, K. L., & Hayden, E. P (Eds.), *The Oxford handbook of stress and mental health* (pp. 97–126). Oxford University Press.
- Watkins, E. R. (2008). Constructive and unconstructive repetitive thought. *Psychological Bulletin*, 134(2), 163–206.
- Watkins, E. R., & Roberts, H. (2020). Reflecting on rumination: Consequences, causes, mechanisms and treatment of rumination. *Behaviour Research and Therapy*, 127, 103573.
- Wichers, M. (2014). The dynamic nature of depression: A new micro-level perspective of mental disorder that meets current challenges. *Psychological Medicine*, 44(7), 1349–1360.
- World Health Organization. (2023). Available online: <https://www.who.int/news-room/fact-sheets/detail/depression>.
- Wu, C., & Wang, Z. (2024). The dynamic features of emotion dysregulation in major depressive disorder: An emotion dynamics perspective. *Advances in Psychological Science*, 32(2), 364–388.
- [吴朝毅, 王振. (2024). 抑郁症情绪失调的动态特征: 情绪动力学的视角. *心理科学进展*, 32(2), 364–388.]
- Zawadzki, M. J., Hussain, M., & Kho, C. (2022). Comparing multidimensional facets of stress with social, emotional, and physical well-being using ecological momentary assessment among a Hispanic sample. *Stress and Health*, 38(2), 375–387.
- Zeileis, A., Hothorn, T., & Hornik, K. (2008). Model-based recursive partitioning. *Journal of Computational and Graphical Statistics*, 17(2), 492–514.
- Zhang, W., Xi, M., Yin, T., Wang, C., & Si, S. (2023). Prediction of depression onset and development based on network analysis. *Advances in Psychological Science*, 31(11), 2129–2141.
- [张伟霞, 席敏, 阴甜甜, 王成, 司书宾. (2023). 基于网络分析的抑郁症产生与演变预测. *心理科学进展*, 31(11), 2129–2141.]

Dynamic prediction of depressive states using stress processes: A multilevel decision tree approach

LUO Xiaohui, HU Yueqin, LIU Hongyun

(Beijing Key Laboratory of Applied Experimental Psychology, National Demonstration Center for Experimental Psychology Education (Beijing Normal University), Faculty of Psychology, Beijing Normal University, Beijing, 100875, China)

Abstract

The importance of predicting depressive risk has become increasingly prominent in recent years. Research has shown dynamic associations between depressive symptoms and multiple components of the daily stress process model (e.g., stressor exposure, stress appraisal, and stress reactivity). However, an integrated analysis of the predictive effect of stress processes on depressive states is still warranted. More importantly, although studies have been conducted to improve the prediction accuracy of depression using machine learning algorithms, these prediction models have primarily focused on inter-individual differences in depressive risk factors while overlooking the intra-individual dynamics of stress processes and depressive states. Given that fluctuations in individuals' depressive states can effectively guide clinical practice in answering the key questions of "when to intervene" and "for whom to intervene", this study aimed to use ecological momentary assessment (EMA) data and adopt a multilevel decision tree approach to construct a dynamic prediction model of depressive states using stress processes.

A sample of 356 Chinese college students completed five momentary assessments per day for seven days. In each assessment, they completed measures of depressive states, stressful life events (stressor exposure), perceived stress (stress appraisal), positive and negative affect (affective reactivity), rumination and stressor anticipation (cognitive reactivity), present and anticipated stress coping (behavioral reactivity), and physical symptoms and discomfort (physical reactivity). A multilevel decision tree approach (i.e., generalized linear mixed model (GLMM) tree) was employed to account for the multilevel structure of the data and the differences in individuals' general levels of depression (i.e., random intercept). In addition to the momentary score of each stress process factor, we also calculated the cumulative mean and deviation of each factor as indicators to further characterize the dynamics of daily stress processes. To effectively predict and warn individuals of potential depressive states in the near future, we constructed a dynamic prediction model of stress processes at the current moment on the depressive states at the subsequent moment (approximately three hours later).

Our analysis revealed several key findings. First, the model including negative affect (distress), stressors, and rumination accurately predicted whether individuals would experience depressive states three hours later, with distress levels (negative affective reactivity to stressors) emerging as the top risk factor. Second, even excluding affective factors, the model effectively predicted depressive states using present and anticipated stress coping, rumination, discomfort, and perceived stress. This has practical advantages when frequent assessment of affective states is not feasible and too intrusive, or when at-risk individuals may not disclosure their actual affective states if asked directly. Third, multiple components of the daily stress processes cumulatively acted on individuals, jointly predicting their subsequent risk of depression. For example, more stressors and higher levels of distress jointly predicted a higher tendency towards depressive states subsequently. Fourth, dynamic indicators such as cumulative means and deviations of stress processes played crucial roles in predicting depressive states. These findings highlight the complexity and multifaceted nature of stress processes in influencing depressive symptoms.

The study makes a substantial theoretical and practical contribution by examining depression prediction from a dynamic perspective. By integrating a variety of daily stress process factors and their dynamic characteristics, this study identified key stress process factors in predicting depressive risk and revealed the

synergistic effects of their various combinations. These findings expand previous research on the relation between stress and depression and deepen our understanding of the complex predictive pathways of stress processes on depressive states. In addition, this study utilized multilevel decision trees and ecological momentary assessment to construct a near-term warning model of depression with both interpretability and predictive accuracy. This provides an effective decision tool for real-time monitoring and identification of potential depressive risk in daily life, guiding the implementation of just-in-time adaptive intervention for depression.

Keywords stress process, depression, multilevel decision tree, ecological momentary assessment