

# 密集追踪数据的有调节的中介效应分析\*

方 杰<sup>1</sup> 温忠麟<sup>2</sup> 王惠惠<sup>3</sup> 顾红磊<sup>4</sup>

(<sup>1</sup> 广东财经大学新发展研究院, 广州 510320) (<sup>2</sup> 华南师范大学心理应用研究中心/心理学院, 广州 510631)

(<sup>3</sup> 宁夏大学教育学院, 银川 750021) (<sup>4</sup> 湖南师范大学教育科学学院心理系; 认知与人类行为湖南省重点实验室, 长沙 410081)

**摘 要** 密集追踪数据在心理学、管理学等领域的应用日益增多, 但密集追踪数据的分析方法研究却比较欠缺。如果将密集追踪数据的有调节的中介效应当成有调节的多水平中介效应进行分析, 则忽略了变量之间的历时性关系。本文使用动态结构方程模型建构了被层 2 变量调节的 1-1-1、2-1-1、2-2-1 密集追踪中介模型和被层 1 变量调节的 1-1-1 密集追踪中介模型。用模拟研究考察了被层 2 变量调节的 1-1-1 密集追踪中介模型的参数估计的准确性。接着用示例演示如何进行有调节的密集追踪中介效应分析, 并给出相应的 Mplus 程序。最后, 讨论了基于动态结构方程模型的有调节的密集追踪中介模型的前提假设以及模型的拓展。

**关键词** 密集追踪数据, 有调节的中介效应, 动态结构方程模型

**分类号** B841

## 1 引言

有调节的中介模型(moderated mediation model)意味着自变量  $X$  通过中介变量  $M$  对因变量  $Y$  产生影响, 而中介过程( $X \rightarrow M \rightarrow Y$ )受到调节变量  $Z$  的调节(Baron & Kenny, 1986), 图 1 是模型概念图。根据中介过程的阶段不同, 有调节的中介模型可分为三种亚型: 前半路径( $X \rightarrow M$ )被调节的中介、后半路径( $M \rightarrow Y$ )被调节的中介、前后路径( $X \rightarrow M$  和  $M \rightarrow Y$ )被调节的中介(温忠麟, 叶宝娟, 2014; Edwards &

Lambert, 2007)。最一般的模型是中介过程的前后路径和直接路径( $X \rightarrow Y$ )都被调节(见图 1)。

自从 Baron 和 Kenny (1986)提出有调节的中介的概念后, 有调节的中介效应的分析方法迅速成为方法学研究的热点之一。有调节的中介效应的分析方法已经从连续变量拓展到类别变量(方杰等, 2023; Hayes, 2022), 从显变量拓展到潜变量(方杰, 温忠麟, 2018; Cheung & Lau, 2017), 从单层数据(即截面数据, Edwards & Lambert, 2007; Muller et al., 2005)拓展到多水平数据或纵向数据(纵向数据可看成时间点  $t$  嵌套于个体  $j$  的多水平数据, 见图 1, 方杰, 温忠麟, 2023a; Bauer et al., 2006)。但现有的有调节的纵向中介效应分析方法还存在不足。第一, 缺乏密集追踪数据(intensive longitudinal data)的有调节的中介(以下简称有调节的密集追踪中介)效应分析方法。第二, 现有的有调节的纵向中介效应分析方法忽略变量之间的时间先后关系, 难以进




图 1 前后路径和直接路径被调节的中介模型概念图

收稿日期: 2023-10-06

\* 国家自然科学基金项目(32171091, 72074055)、教育部人文社会科学研究规划基金项目(24YJA190003)、宁夏回族自治区重点研发计划引才专项(2024BEH04094)和广东省普通高校创新团队项目(2020WCXTD014)资助。

通信作者: 温忠麟, E-mail: wenzl@scnu.edu.cn

行因果推断。本文的目的是, 提出考虑变量间先后关系的有调节的密集追踪中介效应分析方法。首先, 述评有调节的纵向中介效应分析的当前困境。然后, 使用动态结构方程模型(dynamic structural equation model, DSEM; Asparouhov et al., 2018)建构被层 2 变量调节的 1-1-1、2-1-1、2-2-1 密集追踪中介模型(三个数字依次代表自变量、中介变量和因变量, 数字 1 表示层 1, 数字 2 表示层 2)和被层 1 变量调节的 1-1-1 密集追踪中介模型。接着, 用一个模拟研究评估有调节的密集追踪中介模型参数估计的准确性。随后, 用一个示例来演示如何利用动态结构方程模型进行有调节的密集追踪中介效应分析。最后, 讨论了有调节的密集追踪中介效应分析方法的拓展。

## 2 有调节的纵向中介效应分析的当前困境

第一, 缺乏有调节的密集追踪中介效应分析方法。近年来, 由于可穿戴设备和智能手机的普及, 具有高生态效度和低回忆偏差优点的密集追踪数据在心理、管理和行为科学中的应用越来越多(Hamaker & Wichers, 2017; Zhou et al., 2021)。研究者常用日记法、经验取样法和生态瞬时评估法收集间隔时间短(常以小时和天为单位)且重复测量次数多(至少 20 次)的密集追踪数据(郑舒方等, 2021; Collins, 2006)。但如何进行密集追踪数据分析, 研究还处于起步阶段。最近有研究者提出了密集追踪数据的中介效应分析方法(Fang et al., 2024; McNeish & McKinnon, 2025)和调节效应分析方法(Speyer et al., 2024), 但如何将中介效应和调节效应整合在同一个模型中, 进行有调节的中介效应分析, 还不清楚。

第二, 难以进行历时性变量关系的因果推断。纵向数据能明确变量之间的时间先后顺序, 这有利于因果推断的, 但现有分析方法将有调节的纵向中介效应当成有调节的多水平中介效应进行分析。具体地, 已有的有调节的纵向中介效应分析方法是纵向数据看成测量时间点( $t$ )嵌套于个体( $j$ )的两层嵌套结构, 借用多水平模型(multilevel model)和多水平结构方程模型(multilevel structural equation model)进行分析。例如, Lischetzke 等(2021)收集了 313 名被试, 每名被试重复测量平均 18.89 次的密集追踪数据, 使用多水平结构方程模型考察了每晚

的平静(calmness in the evening)在每天的压力(daily stress)和每晚的睡眠质量(nightly sleep quality)之间的 1-1-1 中介效应, 以及每天的负性情绪分化(daily negative emotion differentiation)对 1-1-1 中介的前半路径的调节效应。有调节的多水平中介效应的分析工具(即多水平模型和多水平结构方程模型)都只考虑了变量之间的即时性关系( $X_{ij} \rightarrow M_{ij} \rightarrow Y_{ij}$ , 下标都是  $t$ , 见图 1(b)), 没有考虑变量之间的历时性关系(如  $X_{(t-1)j} \rightarrow M_{ij}$ ), 也没有包含同一变量前后测量时间点(如  $X_{(t-1)j} \rightarrow X_{ij}$ )的自回归效应(autoregressive effect), 未能充分挖掘密集追踪数据的信息。可能的解决方案是, 改进多水平模型(融入变量间的时间先后关系), 使用动态结构方程模型进行有调节的中介效应分析。

动态结构方程模型整合了多水平模型、时间序列模型(即引入变量的时间先后关系)和结构方程模型的优势(Asparouhov et al., 2018; McNeish & Hamaker, 2020)。它能在个体内水平(层 1)和个体间水平(层 2)同时建模, 以体现密集追踪数据的多水平(层)结构; 它还能在个体内水平构建变量的历时性关系, 以体现密集追踪数据的动态特性。此外, 动态结构方程模型采用贝叶斯估计法, 相比极大似然估计可以更灵活地估计参数的随机效应(如参数的个体间差异)。

## 3 被层 2 变量调节的密集追踪中介效应分析

### 3.1 被层 2 变量调节的 1-1-1 密集追踪中介效应分析

动态结构方程模型也可以将密集追踪数据看成是测量时间点( $t$ )嵌套于个体( $j$ )的两层嵌套结构(见图 2)。目前, 有调节的纵向中介效应模型(见图 1(b))研究较多的是将自变量、中介变量和因变量都放置在层 1, 而将调节变量放置在层 2(Bauer et al., 2006; Zhang et al., 2018)。例如, Zhang 等(2018)研究了每天的积极情绪( $M_{ij}$ )在每天感受的压力( $X_{ij}$ )和每天的消极情绪( $Y_{ij}$ )之间的 1-1-1 密集追踪中介效应, 并考察了被层 2 变量  $Z_j$  (性别)调节的 1-1-1 密集追踪中介效应。被层 2 变量调节的 1-1-1 密集追踪中介效应分析的数据示例如表 1 所示。自变量  $X_{ij}$ 、中介变量  $M_{ij}$  和因变量  $Y_{ij}$  既随个体变化, 又随时间变化, 是层 1 变量。调节变量  $Z_j$  只随个体变化, 不随时间变化, 是层 2 变量。




图2 基于动态结构方程模型的被层2变量调节的1-1-1密集追踪中介模型图  
(改编自 Fang et al., 2024)

表1 被层2变量调节的1-1-1密集追踪中介效应分析的数据示例( $t=20$ )

| 个体( $j$ ) | 时间( $t$ ) | $Z$      | $X$      | $M$      | $Y$      |
|-----------|-----------|----------|----------|----------|----------|
| 1         | 1         | 1.21     | 0.39     | 1.99     | 0.85     |
| 1         | 2         | 1.21     | -0.43    | 1.97     | 1.69     |
| $\vdots$  | $\vdots$  | $\vdots$ | $\vdots$ | $\vdots$ | $\vdots$ |
| 1         | 20        | 1.21     | -0.89    | 2.10     | -1.68    |
| 2         | 1         | 2.10     | -0.78    | 0.59     | 0.83     |
| 2         | 2         | 2.10     | -1.12    | 2.22     | 1.67     |
| $\vdots$  | $\vdots$  | $\vdots$ | $\vdots$ | $\vdots$ | $\vdots$ |
| 2         | 20        | 2.10     | -1.13    | 2.45     | -0.84    |

注: 数据源自 Wang et al., 2024

使用动态结构方程模型建构的前后路径和直接路径都被层2变量 $Z_j$ 调节的1-1-1密集追踪中介模型(模型1, 图2)可表示为(Fang et al., 2024):

$$\text{层1: } X_{ij}^c = \beta_{Xj} X_{(t-1)j}^c + \varepsilon_{Xij} \quad (1)$$

$$M_{ij}^c = \beta_{Mj} M_{(t-1)j}^c + a_j X_{(t-1)j}^c + \varepsilon_{Mij} \quad (2)$$

$$Y_{ij}^c = \beta_{Yj} Y_{(t-1)j}^c + b_j M_{(t-1)j}^c + c_j' X_{(t-2)j}^c + \varepsilon_{Yij} \quad (3)$$

$$\text{层2: } l_{Xj} = l_X + \mu_{1j} \quad l_{Mj} = l_M + dZ_j + \mu_{2j} \quad l_{Yj} = l_Y + fZ_j + \mu_{3j} \quad (4)$$

$$a_j = a + gZ_j + \mu_{7j} \quad b_j = b + kZ_j + \mu_{8j} \quad c_j' = c' + hZ_j + \mu_{9j} \quad (5)$$

$$\beta_{Xj} = \beta_X + \mu_{4j} \quad \beta_{Mj} = \beta_M + \mu_{5j} \quad \beta_{Yj} = \beta_Y + \mu_{6j} \quad (6)$$

$$\log(\sigma_{Xj}^2) = \omega_X + \mu_{10j} \quad \log(\sigma_{Mj}^2) = \omega_M + \mu_{11j} \quad \log(\sigma_{Yj}^2) = \omega_Y + \mu_{12j} \quad (7)$$

其中,  $X_{ij}^c$ 、 $M_{ij}^c$ 和 $Y_{ij}^c$ 的上标 $c$ 表示变量按个体潜均

值 $l_{Xj}$ 、 $l_{Mj}$ 和 $l_{Yj}$ 进行潜变量中心化(latent variable centering), 即

$$X_{ij}^c = X_{ij} - l_{Xj}, \quad M_{ij}^c = M_{ij} - l_{Mj}, \quad Y_{ij}^c = Y_{ij} - l_{Yj} \quad (8)$$

因此, 显变量 $X_{ij}$ 、 $M_{ij}$ 和 $Y_{ij}$ 被分解为两部分(见图2的左边), 即个体间潜变量( $l_{Xj}$ 、 $l_{Mj}$ 和 $l_{Yj}$ )和个体内潜变量( $X_{ij}^c$ 、 $M_{ij}^c$ 和 $Y_{ij}^c$ )。同理,  $X_{(t-1)j}^c = X_{(t-1)j} - l_{Xj}$ 、 $X_{(t-2)j}^c = X_{(t-2)j} - l_{Xj}$ 、 $M_{(t-1)j}^c = M_{(t-1)j} - l_{Mj}$ 和 $Y_{(t-1)j}^c = Y_{(t-1)j} - l_{Yj}$ 。与显变量中心化相比, 潜变量中心化能有效克服 Nickell 偏差(即显变量中心化使自回归效应产生负偏差的现象, Asparouhov et al., 2018)。 $\beta_{Xj}$ 、 $\beta_{Mj}$ 和 $\beta_{Yj}$ 表示自回归效应, 即每个变量前后时间点的效应(图2右下侧);  $a_j$ 、 $b_j$ 和 $c_j'$ 表示滞后效应(lagged effect), 即控制了上一时刻的结果变量对自身的影响(即自回归效应)后, 预测变量对结果变量的历时性影响(图2右下侧); 动态结构方程模型的“动态”就是指变量之间的历时性影响(即自回归效应和滞后效应)。 $\varepsilon_{Xij}$ 、 $\varepsilon_{Mij}$ 和 $\varepsilon_{Yij}$ 表示层1残差, 且假设层1残差服从正态分布 $\varepsilon_{Xij} \sim N(0, \sigma_{Xj}^2)$ 、 $\varepsilon_{Mij} \sim N(0, \sigma_{Mj}^2)$ 和 $\varepsilon_{Yij} \sim N(0, \sigma_{Yj}^2)$ ,  $\sigma_{Xj}^2$ 、 $\sigma_{Mj}^2$ 和 $\sigma_{Yj}^2$ 表示层1残差的方差。

在层2, 所有层1的参数( $l_{Xj}$ 、 $l_{Mj}$ 、 $l_{Yj}$ 、 $\beta_{Xj}$ 、 $\beta_{Mj}$ 、 $\beta_{Yj}$ 、 $a_j$ 、 $b_j$ 、 $c_j'$ 、 $\sigma_{Xj}^2$ 、 $\sigma_{Mj}^2$ 和 $\sigma_{Yj}^2$ )都可以设为随机效应, 即层1的参数都可以在层2作为因变量(由于残差方差 $\sigma_{Xj}^2$ 、 $\sigma_{Mj}^2$ 和 $\sigma_{Yj}^2$ 都是非负数, 因此将 $\log(\sigma_{Xj}^2)$ 、 $\log(\sigma_{Mj}^2)$ 和 $\log(\sigma_{Yj}^2)$ 作为层2的因变量), 写成均值加残差的形式(见方程(4)~(7))。其中,  $l_X$ 、 $l_M$ 、 $l_Y$ 、 $\beta_X$ 、 $\beta_M$ 、 $\beta_Y$ 、 $a$ 、 $b$ 、 $c'$ 、 $\omega_X$ 、 $\omega_M$ 和 $\omega_Y$ 表示所有个体的均值,  $\mu_{1j} \sim \mu_{12j}$ 表示残差, 代表每个个

体值偏离均值的程度。设置随机效应就是为了考察参数是否会随个体而变化。

另外, 方程(4)和(5)还添加了调节变量  $Z_j$  作为层 2 自变量, 因此,  $Z_j$  的调节效应都是跨层(cross-level)调节效应。此时, 条件中介效应(即调节变量取值为  $Z_j$  时的中介效应, 以下类同)的均值为

$$E(a_j b_j) = (a + gZ_j)(b + kZ_j) + \sigma_{a_j b_j} \quad (9)$$

其中,  $\sigma_{a_j b_j}$  是  $\sigma_{a_j}$  和  $\sigma_{b_j}$  的协方差(在数值上等于  $a_j$  和  $b_j$  的协方差) (Bauer et al., 2006)。设  $E_{high}(a_j b_j)$  和  $E_{low}(a_j b_j)$  是  $Z_j$  为  $Z_{high}$  和  $Z_{low}$  时的条件中介效应, 如果  $E_{high}(a_j b_j) - E_{low}(a_j b_j)$  的区间估计不包含 0, 则表示中介效应受到  $Z_j$  的调节(Edwards & Lambert, 2007)。另外, 条件直接效应(即调节变量取值为  $Z_j$  时的直接效应, 以下类同)的均值为

$$E(c'_j) = c' + hZ_j \quad (10)$$

如果  $h$  的区间估计不包含 0, 就表示直接效应受到  $Z_j$  的调节(Hayes, 2015)。如果直接路径不被调节, 则去掉方程(5)的  $hZ_j$  (删除图 2 中  $Z_j \rightarrow c'_j$  的路径)即可。

如果只调节中介的前半路径和直接路径(模型 2), 则去掉方程(5)的  $kZ_j$  (删除图 2 中  $Z_j \rightarrow b_j$  的路径)即可。此时的条件中介效应的均值为

$$E(a_j b_j) = (a + gZ_j)b + \sigma_{a_j b_j} \quad (11)$$

如果  $gb$  的区间估计不包含 0, 就表示中介效应的前半路径受到  $Z_j$  的调节(Hayes, 2015); 如果只调节中介的后半路径和直接路径(模型 3), 则去掉方程(4)的  $dZ_j$  和方程(5)的  $gZ_j$  (即删除图 2 中  $Z_j \rightarrow l_{Mj}$  和  $Z_j \rightarrow a_j$  的路径)即可。此时的条件中介效应的均值为

$$E(a_j b_j) = a(b + kZ_j) + \sigma_{a_j b_j} \quad (12)$$

如果  $ak$  的区间估计不包含 0, 就表示中介效应的后半路径受到  $Z_j$  的调节(Hayes, 2015)。

### 3.2 被层 2 变量调节的 2-1-1 密集追踪中介效应分析

自变量可以是随时间变化的密集追踪数据, 也可以是不随时间变化的层 2 变量。例如, McKellar 和 Wang (2023)的研究中, 选用的自变量  $X_j$  是学生的学习方式(面对面学习和远程网络学习), 就是一个不随时间变化的层 2 变量。McKellar 和 Wang 使用多水平结构方程模型考察了与老师的每天联系( $M_{ij}$ )在学生的学习方式( $X_j$ )和每天学习投入( $Y_{ij}$ )之间的 2-1-1 密集追踪中介效应。使用动态结构方程模型建构的前后路径和直接路径被层 2 变量  $Z_j$  调节的 2-1-1 中介效应模型(模型 4, 图 3)可表示为:

$$\text{层 1: } M_{ij}^c = \beta_{Mj} M_{(t-1)j}^c + \varepsilon_{Mij} \quad (13)$$

$$Y_{ij}^c = \beta_{Yj} Y_{(t-1)j}^c + b_{Wj} M_{(t-1)j}^c + \varepsilon_{Yij} \quad (14)$$

$$\text{层 2: } l_{Mj} = l_M + aX_j + dZ_j + gX_j Z_j + \mu_{1j} \quad (15)$$

$$l_{Yj} = l_Y + c'X_j + b_B l_{Mj} + fZ_j + hX_j Z_j + kl_{Mj} Z_j + \mu_{2j} \quad (16)$$

$$b_{Wj} = b_W + \mu_{5j} \quad (17)$$

$$\beta_{Mj} = \beta_M + \mu_{3j} \quad \beta_{Yj} = \beta_Y + \mu_{4j} \quad (18)$$

$$\log(\sigma_{Mj}^2) = \omega_M + \mu_{11j} \quad \log(\sigma_{Yj}^2) = \omega_Y + \mu_{12j} \quad (19)$$

相比被层 2 变量调节的 1-1-1 中介效应模型(图 2), 被层 2 变量调节的 2-1-1 模型(图 3)有如下三个变化。第一, 中介效应从层 1 ( $X_{ij} \rightarrow M_{ij} \rightarrow Y_{ij}$ )变到了层 2 ( $X_j \rightarrow l_{Mj} \rightarrow l_{Yj}$ ), 因此层 2 变量调节的 2-1-1 中介效应实际上是层 2 变量调节层 2 中介效应( $X_j \rightarrow l_{Mj} \rightarrow$




图 3 基于动态结构方程模型的被层 2 变量调节的 2-1-1 密集追踪中介模型图

$l_{Yj}$ )。第二, 调节效应从跨层调节效应变成了同层调节效应。Mplus 软件可以直接利用“define”语句生成调节项  $X_jZ_j$ , 从而顺利地进行  $Z_j$  对中介前半路径 ( $X_j \rightarrow l_{Mj}$ ) 和直接路径 ( $X_j \rightarrow l_{Yj}$ ) 的调节效应分析。但 Mplus 软件目前无法直接生成调节项  $l_{Mj}Z_j$  (因为 Mplus 软件目前无法直接生成时间序列变量的调节项, 而  $l_{Mj}$  是时间序列变量  $M_{ij}$  的一部分), 也就无法直接进行  $Z_j$  对中介后半路径 ( $l_{Mj} \rightarrow l_{Yj}$ ) 的调节效应分析。借鉴 Speyer 等(2024)提出的层 1 的同层调节效应分析方法, 进行层 2 的同层调节效应分析。具体地, 先抽取出  $M_{ij}$  的个体潜均值  $l_{Mj}$ , 将之另存为一个新的层 2 观测变量 B\_M (Mplus 程序见网络版附录), 然后利用“define”语句生成调节项  $l_{Mj}Z_j$  ( $l_{Mj}Z_j = B\_M * Z_j$ )。这样就可以进行  $Z_j$  对中介后半路径 ( $l_{Mj} \rightarrow l_{Yj}$ ) 的调节效应分析了。第三, 系数  $a$  和  $b_B$  都在层 2, 不存在  $\sigma_{a,b_j}$  项, 因此条件中介效应变为  $(a + gZ_j)(b_B + kZ_j)$ , 但条件直接效应仍是  $c' + hZ_j$ 。对于中介效应和直接效应是否受到  $Z_j$  调节的判断和 3.1 节相同。如果直接路径不被调节, 则去掉方程(21)的  $hX_jZ_j$  (删除图 4 中  $X_jZ_j \rightarrow l_{Yj}$  的路径)即可。如果只调节中介的前半路径和直接路径(模型 8), 则去掉方程(21)的  $kM_jZ_j$  (删除图 4 中  $M_jZ_j \rightarrow l_{Yj}$  的路径)即可。如果只调节中介的后半路径和直接路径(模型 9), 则去掉方程(24)的  $dZ_j$  和  $gX_jZ_j$  (删除图 4 中  $Z_j \rightarrow M_j$  和  $X_jZ_j \rightarrow M_j$  的路径)即可。

### 3.3 被层 2 变量调节的 2-2-1 密集追踪中介效应分析

在 2-1-1 密集追踪中介模型中, 只有自变量是不随时间变化的层 2 变量。更进一步, 自变量和中介变量都可以是不随时间变化的层 2 变量。例如, Talty 等(2023)考察了师生关系( $M_j$ )在负性教养经历( $X_j$ )和消极情绪( $Y_{ij}$ )之间的 2-2-1 密集追踪中介效应。由于 2-2-1 密集追踪中介效应发生在层 2 (Fang et al., 2024), 因此研究者可以进一步分析被层 2 变量调节的 2-2-1 密集追踪中介效应。使用动态结构方程模型建构的前后路径和直接路径被层 2 变量调节的 2-2-1 中介效应分析(模型 7, 图 4)可表示为:

$$\text{层 1: } Y_{ij}^c = \beta_{Yj} Y_{(t-1)j}^c + \varepsilon_{Yij} \quad (20)$$

$$\text{层 2: } l_{Yj} = l_Y + bM_j + c'X_j + fZ_j + hX_jZ_j + kM_jZ_j + \mu_{2j} \quad (21)$$

$$\beta_{Yj} = \beta_Y + \mu_{6j} \quad (22)$$

$$\log(\sigma_{Yj}^2) = \omega_Y + \mu_{12j} \quad (23)$$

$$M_j = \lambda_M + aX_j + dZ_j + gX_jZ_j + \mu_{16j} \quad (24)$$

其中  $\lambda_M$  表示截距。条件中介效应为  $(a + gZ_j)(b +$

$kZ_j)$ , 直接效应为  $c' + hZ_j$ 。对于中介效应和直接效应是否受到  $Z_j$  调节的判断和 3.1 节相同。如果直接路径不被调节, 则去掉方程(21)的  $hX_jZ_j$  (删除图 4 中  $X_jZ_j \rightarrow l_{Yj}$  的路径)即可。如果只调节中介的前半路径和直接路径(模型 8), 则去掉方程(21)的  $kM_jZ_j$  (删除图 4 中  $M_jZ_j \rightarrow l_{Yj}$  的路径)即可。如果只调节中介的后半路径和直接路径(模型 9), 则去掉方程(24)的  $dZ_j$  和  $gX_jZ_j$  (删除图 4 中  $Z_j \rightarrow M_j$  和  $X_jZ_j \rightarrow M_j$  的路径)即可。




图 4 基于动态结构方程模型的有调节的 2-2-1 密集追踪中介模型图

## 4 被层 1 变量调节的密集追踪中介效应分析

自变量、中介变量和因变量中, 如果至少有一个变量是层 2 变量(如 2-1-1 和 2-2-1), 则中介效应必定发生在层 2 水平(Preacher et al., 2010)。因此, 至少有一个变量是层 2 变量的密集追踪中介效应(如 2-1-1 和 2-2-1)只能被层 2 变量调节(见图 3 和图 4)。但是, 1-1-1 密集追踪中介模型既能被层 2 变量调节(见图 2), 还能被层 1 变量调节。只不过被层 1 变量调节的情况更为复杂, 不仅需要层 1 调节变量  $Z_{ij}$  分解为个体间潜变量( $l_{Zj}$ )和个体内潜变量( $Z_{ij}^c$ ), 更重要的是调节效应是层 1 的同层调节, 层 1 的同层调节效应分析比跨层调节效应和层 2 的同层调节效应分析都更为复杂。具体地, 同层调节效应无法像跨层调节效应那样(如  $Z_j$  调节  $X_{(t-1)j} \rightarrow M_{ij}$  关系), 将层 1 关系( $X_{(t-1)j} \rightarrow M_{ij}$  的关系  $a_j$ )设置为随机斜率, 将随机斜率在层 2 设为因变量, 做随机斜率对层 2 调节变量  $Z_j$  的回归(称为随机系数预测法, 方杰, 温

忠麟, 2018; Preacher et al., 2016)。相比层 2 的同层调节效应(以调节项  $X_{ij}Z_{ij}$  为例), 层 1 的同层调节效应的调节项为  $X_{(t-1)j}Z_{(t-1)j}$  (表示  $Z_{(t-1)j}$  调节  $X_{(t-1)j} \rightarrow M_{ij}$  的关系), 层 1 的同层调节效应分析还需要考虑调节项的时间先后问题, 即调节项一般比因变量要提前至少一个时间点。因此, 为了简化模型和便于理解, 这里我们仅讨论前半路径被层 1 变量  $Z_{ij}$  调节的 1-1-1 密集追踪中介模型。

Lischetzke 等(2021)研究了每晚的平静( $M_{ij}$ )在每天感受的压力( $X_{ij}$ )和每晚的睡眠质量( $Y_{ij}$ )之间的 1-1-1 密集追踪中介效应, 并考察了前半路径(每天感受的压力 $\rightarrow$ 每晚的平静)被层 1 变量  $Z_{ij}$  (每天的负性情绪分化)调节的 1-1-1 密集追踪中介效应。使用动态结构方程模型建构的前半路径被层 1 变量  $Z_{ij}$  调节的 1-1-1 密集追踪中介模型(模型 10)可表示为:

$$\text{层 1: } X_{ij}^c = \beta_{Xj} X_{(t-1)j}^c + \varepsilon_{Xij} \quad (25)$$

$$Z_{ij}^c = \beta_{Zj} Z_{(t-1)j}^c + \varepsilon_{Zij} \quad (26)$$

$$M_{ij}^c = \beta_{Mj} M_{(t-1)j}^c + a_j X_{(t-1)j}^c + d_j Z_{(t-1)j}^c + g_j \text{int}_{(t-1)j}^c + \varepsilon_{Mij} \quad (27)$$

$$Y_{ij}^c = \beta_{Yj} Y_{(t-1)j}^c + b_j M_{(t-1)j}^c + c_j' X_{(t-2)j}^c + \varepsilon_{Yij} \quad (28)$$

$$\text{层 2: } l_{Xj} = l_X + \mu_{1j} \quad l_{Mj} = l_M + \mu_{2j} \quad l_{Yj} = l_Y + \mu_{3j} \\ l_{Zj} = l_Z + \mu_{4j} \quad (29)$$

$$a_j = a + \mu_{7j} \quad b_j = b + \mu_{8j} \quad c_j' = c' + \mu_{9j} \\ d_j = d + \mu_{18j} \quad g_j = g + \mu_{19j} \quad (30)$$

$$\beta_{Xj} = \beta_X + \mu_{4j} \quad \beta_{Mj} = \beta_M + \mu_{5j} \\ \beta_{Yj} = \beta_Y + \mu_{6j} \quad \beta_{Zj} = \beta_Z + \mu_{20j} \quad (31)$$

$$\log(\sigma_{Xj}^2) = \omega_X + \mu_{10j} \quad \log(\sigma_{Mj}^2) = \omega_M + \mu_{11j} \\ \log(\sigma_{Yj}^2) = \omega_Y + \mu_{12j} \quad \log(\sigma_{Zj}^2) = \omega_Z + \mu_{21j} \quad (32)$$

在模型中只有一个调节项( $X_{(t-1)j}^c Z_{(t-1)j}^c$ ), 但 Mplus 软件目前无法直接产生时间序列变量的调节项, 也就无法直接进行调节效应分析。退一步, 即使产生了调节项  $X_{(t-1)j}^c Z_{(t-1)j}^c$ , 仍然存在中心化的问题。也就是说, 即使  $X_{(t-1)j}^c$  和  $Z_{(t-1)j}^c$  都是均值为 0,  $X_{(t-1)j}^c Z_{(t-1)j}^c$  的均值也不为 0,  $X_{(t-1)j}^c Z_{(t-1)j}^c$  还需要进行潜变量中心化, 这进一步增加了分析的困难(Speyer et al., 2024)。

Speyer 等(2024)提出两步法分析层 1 的同层调节效应。第一步, 先抽取  $X_{ij}^c$  和  $Z_{ij}^c$ , 将之另存为两个新的层 1 观测变量  $X\_W$  和  $Z\_W$  (Mplus 程序见网络版附录)。第二步, 利用 Mplus 软件的“define”语句生成一个新变量  $\text{int}_{ij} = X\_W * Z\_W$ 。然后, 利用

动态结构方程模型将  $\text{int}_{ij}$  分解为个体间潜变量  $l_{\text{int}j}$  和个体内潜变量  $\text{int}_{ij}^c$ , 确保  $\text{int}_{ij}^c$  进行了潜变量中心化( $\text{int}_{ij}^c = \text{int}_{ij} - l_{\text{int}j}$ )。接着, 增加自回归方程(33)

$$\text{层 1: } \text{int}_{ij}^c = \beta_{\text{int}} \text{int}_{(t-1)j}^c + \varepsilon_{\text{int}ij} \quad (33)$$

需要说明的是,  $\text{int}_{ij}$  是调节项, 并不是一个有实际意义的变量, 因此  $\text{int}_{ij}$  的自回归效应  $\beta_{\text{int}}$  并不具有实际意义。因此为了简化模型, 方程(33)中的自回归效应  $\beta_{\text{int}}$  设置为固定效应, 使其不随个体变化。Speyer 等(2024)进一步用实例说明, 将  $\beta_{\text{int}}$  固定为 0 会导致 DIC (deviance information criterion, DIC)值增大, 模型拟合变差。最后, 将方程(27)中的调节项  $X_{(t-1)j}^c Z_{(t-1)j}^c$  换为  $\text{int}_{ij}^c$

$$M_{ij}^c = \beta_{Mj} M_{(t-1)j}^c + a_j X_{(t-1)j}^c + d_j Z_{(t-1)j}^c + g_j \text{int}_{(t-1)j}^c + \varepsilon_{Mij} \quad (34)$$

即可进行被调节的中介效应分析了。条件中介效应的均值见方程(11) (需要将  $Z_j$  换为  $Z\_W$ ), 中介效应是否被调节的判断和 3.1 节相同。

## 5 模拟研究

目前, 密集追踪中介研究(Fang et al., 2024; McNeish & McKinnon, 2025)尚未用模拟研究考察密集追踪中介模型中的参数估计的精度, 更复杂的有调节的密集追踪中介模型的参数估计精度就更不清楚了。因此, 本模拟研究的目的是考察有调节的密集追踪中介模型(方程(1)~(7))中的参数是否能被准确估计, 以及参数估计受哪些因素的影响。

### 5.1 模拟设计

对于方程(1)~(7), 参考 Kenny 等(2003)、Wang 和 Preacher (2015)、Zhang 等(2018)的模拟设计, 真值设定如下。对于条件中介效应  $E(a_j b_j)$ , 设  $a_j$ 、 $b_j$  都服从正态分布, 即  $a_j \sim N(a, 0.16)$ ,  $b_j \sim N(b, 0.16)$ 、 $a = b = g = k = 0.2$  和 0,  $a_j$  和  $b_j$  的协方差  $\sigma_{a_j b_j}$  为 0.113 和 0。直接效应  $c_j'$  服从均值为 0.2, 方差为 0.04 的正态分布,  $c_j'$  和  $a_j$  和  $b_j$  都不相关, 调节变量  $Z_j$  不调节直接路径, 即  $h = 0$ 。自回归效应  $\beta_{Xj}$ 、 $\beta_{Mj}$  和  $\beta_{Yj}$  都服从均值为 0.3, 方差为 0.01 的正态分布(Asparouhov et al., 2018; Zhou et al., 2021)。 $d = f = 0.1$ 。层 1 残差的方差  $\log(\sigma_{Xj}^2)$ 、 $\log(\sigma_{Mj}^2)$  和  $\log(\sigma_{Yj}^2)$  都服从均值为 1.4, 方差为 0.39 的正态分布(McNeish & McKinnon, 2025)。调节变量  $Z_j$  和个体潜均值  $l_{Xj}$  都服从均值为 0, 方差为 1 的正态分布;  $l_{Mj}$  服从均值为 8.8, 方差为 4.5 的正态分布;  $l_{Yj}$  服从均值为 35, 方差为 35 的正态分布(McNeish & McKinnon, 2025)。

本模拟研究的因素设计为:

1) 样本容量:  $N = 100, 200$  (被试间因素)。

2) 重复测量的时间点:  $T = 10, 20, 50$  (被试间因素)。目前学界对于密集追踪数据至少需要重复测量多少次还未达成一致。Collins (2006) 建议 20 次, McNeish 和 Hamaker (2020) 建议 10 次, 因此本研究对这两种情况都进行考察。

3) 条件(即调节变量  $Z_j = 1$  时的)中介效应的均值:  $E(a_j b_j) = 0.273$  和 0 (被试间因素)。具体地, 如果  $a = b = g = k = 0.2$ 、 $\sigma_{a_j b_j} = 0.113$ , 则  $E(a_j b_j) = 0.273$ ; 如果  $a = b = g = k = 0$ 、 $\sigma_{a_j b_j} = 0$ , 则  $E(a_j b_j) = 0$ 。

这是一个  $2 \times 3 \times 2$  设计, 共有 12 种处理。对于每种处理, 使用 Mplus 8.3 产生 200 个样本(即重复 200 次, Gistelinck et al., 2021)。需要说明的是, 理想情况下, 一般重复更多次(如 500 次)来确保结果的可靠性。在本研究中, 由于计算时间太长, 我们选择了重复 200 次。为了验证 200 次重复足以满足模拟目的, 我们在  $N = 100$ 、 $T = 10$  和条件中介效应为 0.273 的条件下, 进行了 500 次重复, 发现条件中介效应估计值与 200 次重复相比变化不大。实际上, 已有密集追踪数据的研究为了缩短计算时间, 每种处理只重复了 100 次(Asparouhov et al., 2018; Asparouhov & Muthén, 2020)。

## 5.2 数据分析和评价指标

使用 Mplus 软件进行贝叶斯估计, 共迭代 10000 次(Fang & Wang, 2024; Wang & Preacher, 2015), 采用后 5000 次迭代获得参数的后验分布。使用 Mplus 软件默认的无信息先验分布(Muthén & Muthén, 1998-2017)。具体地, 回归系数( $l_X$ 、 $l_M$ 、 $l_Y$ 、 $\beta_X$ 、 $\beta_M$ 、 $\beta_Y$ 、 $a$ 、 $b$ 、 $c'$ 、 $d$ 、 $f$ 、 $g$ 、 $k$ 、 $\omega_X$ 、 $\omega_M$ 、 $\omega_Y$ )采用均值为 0, 方差为  $10^6$  的正态分布; 残差方差采用逆 Gamma 先验分布( $\sim IG(-1, 0)$ ),  $a_j$  和  $b_j$  的方差协方差矩阵采用逆 Wishart 分布( $\sim IW(0, -3)$ )。链条数设为 2, 为了降低后验分布间的自相关和节约存储空间, 将抽取后验分布的间隔设定为 10 (即  $\text{thin} = 10$ )。感兴趣的参数包括条件(取  $Z_j = 1$ )中介效应  $E(a_j b_j)$ 、条件(取  $Z = 1$  和  $Z = -1$ )中介效应的差异  $\text{diff}$ 、 $a$ 、 $b$ 、 $g$ 、 $k$ 、以及  $a_j$  和  $b_j$  的方差和协方差  $\sigma_{a_j b_j}$ 。

使用相对偏差(relative bias)、均方误差(MSE)、95%可信区间的覆盖率、检验力和第一类错误率 5 个指标评估系数( $a$ 、 $b$ 、 $g$ 、 $k$ 、 $E(a_j b_j)$ 、 $\text{diff}$ )估计的精度, 使用相对偏差和均方误差 2 个指标评估  $a_j$ 、 $b_j$  的方差和协方差估计的精度(Zhang et al., 2018)。

相对偏差和均方误差的定义如下:

$$\text{相对偏差} = \frac{1}{n} \sum_{j=1}^n \frac{\hat{\theta}_j - \theta}{\theta} \quad (35)$$

$$\text{均方误差} = \frac{\sum_{j=1}^n (\hat{\theta}_j - \theta)^2}{n} \quad (36)$$

其中,  $n$  表示重复次数,  $\hat{\theta}_j$  是第  $j$  次重复的参数估计值,  $\theta$  是真值。相对偏差(绝对值)小于 5% 时可以忽略, 相对偏差不超过 10% 时可以接受(Muthén & Muthén, 2002)。当参数真值  $\theta$  为 0 时, 改用偏差

$$= \frac{\sum_{j=1}^n \hat{\theta}_j}{n} - \theta$$

来评估参数估计的精度, 偏差的绝对

值越接近于 0 越好。均方误差越小越好。95%可信区间的覆盖率是指 95%可信区间内包含参数真值的次数与重复次数之比。95%可信区间的覆盖率越接近 0.95 越好, 95%可信区间的覆盖率的合理变化范围是在 0.925~0.975 之间(Bradley, 1978)。检验力是在参数真值不为 0 时, 参数检验结果为显著的次数与重复次数之比。检验力越接近 1 越好。第一类错误率是在参数真值为 0 时, 参数检验结果为显著的次数与重复次数之比。当参数真值为 0 时, 第一类错误率 =  $1 - \text{区间覆盖率}$ 。第一类错误率越接近显著性水平( $\alpha = 0.05$ )越好, 第一类错误率的合理变化范围是在 0.025~0.075 之间(Bradley, 1978)。

## 5.3 结果

表 2 呈现的是相对偏差和均方误差的结果。结果表明, 在所有  $N \times T$  条件下, 均方误差都接近 0。在所有  $N \times T$  条件下, 当  $a = b = g = k = 0$  且  $\sigma_{a_j b_j} = 0$  时, 参数  $a$ 、 $b$ 、 $g$ 、 $k$ 、 $E(a_j b_j)$  和协方差  $\sigma_{a_j b_j}$  的偏差都非常接近 0, 仅当  $N = 100$  且  $T = 10$  时, 残差方差  $\sigma_{a_j}^2$  和  $\sigma_{b_j}^2$  的相对偏差大于 10%。当  $a = b = g = k = 0.2$  且  $\sigma_{a_j b_j} = 0.113$  时, 结果表明: 1) 在所有  $N \times T$  条件下, 参数  $a$ 、 $b$ 、 $g$ 、 $k$ 、 $E(a_j b_j)$  和  $\text{diff}$  的相对偏差都小于 5%, 协方差  $\sigma_{a_j b_j}$  的偏差都小于 10%。但是, 当  $N = 100$  且  $T = 10$  时, 残差方差  $\sigma_{a_j}^2$  和  $\sigma_{b_j}^2$  的相对偏差大于 10%; 当  $N = 200$  且  $T = 10$  时, 残差方差  $\sigma_{b_j}^2$  的相对偏差大于 10%。2) 当重复测量的时间点  $T$  一定时, 随着样本容量  $N$  的增大, 相对偏差在绝大多数情况下都会减少。当  $N$  一定时, 随着  $T$  的增多, 仅发现残差方差  $\sigma_{a_j}^2$  和  $\sigma_{b_j}^2$  的相对偏差会持续减少。

表 3 呈现的是系数估计的 95%可信区间覆盖率、检验力和第一类错误率结果。结果表明, 第一,

表 2 系数、方差和协方差估计的相对偏差(%)和均方误差(×100)

| 参数                | $N \times T$ | 100×10      |     | 100×20 |     | 100×50 |     | 200×10      |     | 200×20 |     | 200×50 |     |
|-------------------|--------------|-------------|-----|--------|-----|--------|-----|-------------|-----|--------|-----|--------|-----|
|                   | 真值           | RB          | MSE | RB     | MSE | RB     | MSE | RB          | MSE | RB     | MSE | RB     | MSE |
| $a$               | 0.2          | 1.2         | 0.3 | 0.5    | 0.2 | 2.7    | 0.2 | 0.9         | 0.2 | 0.4    | 0.1 | 1.7    | 0.1 |
| $b$               | 0.2          | 2.9         | 0.3 | 0.6    | 0.2 | 1.5    | 0.2 | 2.4         | 0.2 | -0.3   | 0.1 | 0.4    | 0.1 |
| $g$               | 0.2          | -0.1        | 0.3 | -0.5   | 0.2 | -0.7   | 0.2 | 0.9         | 0.1 | -0.4   | 0.1 | -0.3   | 0.1 |
| $k$               | 0.2          | 0.3         | 0.3 | -1.7   | 0.2 | 0.4    | 0.2 | 1.4         | 0.2 | -1.2   | 0.1 | -0.3   | 0.1 |
| $E(a_jb_j)$       | 0.273        | 4.1         | 0.4 | 3.1    | 0.3 | 4.3    | 0.3 | 3.5         | 0.2 | 1.7    | 0.2 | 2.2    | 0.1 |
| $diff$            | 0.16         | 0.9         | 0.2 | -1.5   | 0.1 | 0.7    | 0.1 | 2.3         | 0.1 | -1.1   | 0.1 | 0.2    | 0.1 |
| $\sigma_{a_j}^2$  | 0.16         | <b>11.1</b> | 0.2 | 7.6    | 0.1 | 5.0    | 0.1 | 4.4         | 0.1 | 3.3    | 0.1 | 2.5    | 0.0 |
| $\sigma_{b_j}^2$  | 0.16         | <b>16.5</b> | 0.3 | 9.4    | 0.1 | 8.5    | 0.1 | <b>10.9</b> | 0.1 | 4.8    | 0.1 | 4.6    | 0.0 |
| $\sigma_{a_jb_j}$ | 0.113        | 5.0         | 0.1 | 6.4    | 0.1 | 5.8    | 0.1 | 3.3         | 0.1 | 3.8    | 0.0 | 3.2    | 0.0 |
| $a$               | 0.0          | 0.3         | 0.3 | 0.3    | 0.2 | 0.5    | 0.2 | 0.2         | 0.2 | 0.1    | 0.1 | 0.4    | 0.1 |
| $b$               | 0.0          | -0.1        | 0.3 | 0.3    | 0.2 | -0.3   | 0.2 | 0.1         | 0.2 | -0.1   | 0.1 | -0.4   | 0.1 |
| $g$               | 0.0          | 0.1         | 0.3 | -0.1   | 0.2 | -0.1   | 0.2 | 0.3         | 0.1 | 0.0    | 0.1 | 0.1    | 0.1 |
| $k$               | 0.0          | -0.6        | 0.3 | -0.6   | 0.2 | 0.1    | 0.2 | -0.6        | 0.2 | -0.6   | 0.1 | -0.1   | 0.1 |
| $E(a_jb_j)$       | 0.0          | -0.1        | 0.1 | 0.0    | 0.1 | 0.1    | 0.1 | -0.1        | 0.1 | 0.0    | 0.0 | 0.0    | 0.0 |
| $\sigma_{a_j}^2$  | 0.16         | <b>10.9</b> | 0.2 | 7.9    | 0.1 | 4.0    | 0.1 | 5.4         | 0.1 | 3.9    | 0.1 | 2.5    | 0.0 |
| $\sigma_{b_j}^2$  | 0.16         | <b>15.6</b> | 0.3 | 7.9    | 0.1 | 8.2    | 0.1 | 9.7         | 0.1 | 2.6    | 0.1 | 4.4    | 0.0 |
| $\sigma_{a_jb_j}$ | 0.0          | -0.1        | 0.1 | 0.0    | 0.1 | 0.1    | 0.0 | -0.1        | 0.1 | 0.0    | 0.0 | 0.0    | 0.0 |

注：RB 表示相对偏差、加粗表示相对偏差的绝对值大于 10%; MSE 表示均方误差。当真值为 0 时, RB 一列显示的是偏差。

表 3 系数估计的可信区间覆盖率、检验力和第一类错误率

| 系数          | $N \times T$ | 100×10 |       | 100×20 |       | 100×50 |       | 200×10 |       | 200×20 |       | 200×50 |       |
|-------------|--------------|--------|-------|--------|-------|--------|-------|--------|-------|--------|-------|--------|-------|
|             | 真值           | Cov    | Pow   | Cov    | Pow   | Cov    | Pow   | Cov    | Pow   | Cov    | Pow   | Cov    | Pow   |
| $a$         | 0.2          | 0.945  | 0.925 | 0.96   | 0.99  | 0.965  | 0.995 | 0.945  | 1     | 0.94   | 1     | 0.95   | 1     |
| $b$         | 0.2          | 0.975  | 0.950 | 0.95   | 0.99  | 0.955  | 1     | 0.94   | 1     | 0.945  | 1     | 0.95   | 1     |
| $g$         | 0.2          | 0.950  | 0.945 | 0.945  | 0.975 | 0.97   | 1     | 0.965  | 1     | 0.96   | 1     | 0.965  | 1     |
| $k$         | 0.2          | 0.96   | 0.94  | 0.93   | 0.96  | 0.965  | 0.995 | 0.955  | 1     | 0.94   | 1     | 0.95   | 1     |
| $E(a_jb_j)$ | 0.273        | 0.955  | 1     | 0.955  | 1     | 0.97   | 1     | 0.96   | 1     | 0.93   | 1     | 0.95   | 1     |
| $diff$      | 0.16         | 0.935  | 0.945 | 0.945  | 0.985 | 0.97   | 1     | 0.975  | 1     | 0.935  | 1     | 0.955  | 1     |
| 系数          | $N \times T$ | 100×10 |       | 100×20 |       | 100×50 |       | 200×10 |       | 200×20 |       | 200×50 |       |
|             | 真值           | Cov    | Error | Cov    | Error | Cov    | Error | Cov    | Error | Cov    | Error | Cov    | Error |
| $a$         | 0.0          | 0.949  | 0.051 | 0.95   | 0.05  | 0.965  | 0.035 | 0.939  | 0.061 | 0.935  | 0.065 | 0.965  | 0.045 |
| $b$         | 0.0          | 0.96   | 0.04  | 0.94   | 0.06  | 0.975  | 0.025 | 0.949  | 0.051 | 0.96   | 0.04  | 0.955  | 0.035 |
| $g$         | 0.0          | 0.949  | 0.051 | 0.945  | 0.055 | 0.97   | 0.03  | 0.965  | 0.035 | 0.95   | 0.05  | 0.955  | 0.045 |
| $k$         | 0.0          | 0.934  | 0.066 | 0.955  | 0.045 | 0.96   | 0.04  | 0.955  | 0.045 | 0.965  | 0.035 | 0.945  | 0.055 |
| $E(a_jb_j)$ | 0.0          | 0.97   | 0.03  | 0.95   | 0.05  | 0.965  | 0.035 | 0.944  | 0.056 | 0.945  | 0.055 | 0.945  | 0.055 |

注：Cov 表示可信区间覆盖率。Pow 表示检验力。Error 表示第一类错误率。

在所有  $N \times T$  条件下, 系数的 95%可信区间覆盖率都在 0.925~0.975 的合理范围内, 第一类错误率都在 0.025~0.075 的合理范围内。第二, 当  $T$  一定时, 随着样本容量  $N$  的增大, 检验力会增大。当  $N = 100$  时, 随着  $T$  的增大, 检验力会增大。第三, 当  $N \times T$  一定(即 2000)时,  $N$  越大, 检验力越大。

## 6 有调节的密集追踪中介效应分析示例

以前后路径被层 2 变量  $Z_j$  调节的 1-1-1 中介效应分析为例, 演示如何使用 Mplus 8.3 执行动态结构方程模型的有调节的密集追踪中介效应分析。其

余三类模型(被层2变量调节的2-1-1和2-2-1中介效应分析、被层1变量调节的1-1-1中介效应分析)的示例(包括数据、Mplus程序和运行结果)都可在<https://osf.io/e273c/>下载。与实际数据相比,模拟数据更能代表典型的有调节的密集追踪中介模型,相应的Mplus代码更具一般性,更便于读者理解(Fang et al., 2024; McNeish & MacKinnon, 2022)。

### 6.1 数据产生和贝叶斯估计方法

根据方程(1)~(7)模拟产生示例数据(200名被试,每名被试都重复测量100次)。除了 $a = b = 0.6$  (Kenny et al., 2003),  $g = k = 0.4$ ,其余参数设置都和模拟研究的设置相同。示例数据(<https://osf.io/e273c/>下载)的 $Z_j$ 的均值(0)加一个标准差为 $Z_{high} = 0.92$ ,  $Z_j$ 的均值减一个标准差为 $Z_{low} = -0.92$ ,则根据方程(9)计算得到, $Z_{high}$ 时的条件中介效应的真值是1.005,  $Z_{low}$ 时的条件中介效应的真值是0.167,条件中介效应之差的真值是0.838。

本例采用贝叶斯法进行参数估计。参数的先验分布使用Mplus默认的无信息先验分布(详见5.2部分)。用PSR值来检查Markov链的收敛性。2条Markov链各迭代2万次,每条Markov链都抛弃前一万次迭代作为预热期或燃烧期(burn in period),用后一万次迭代作为待估参数的后验分布。用95%最高密度后验可信区间(highest posterior density credible intervals)作为参数的区间估计。因为中介效应往往是非对称分布的,最高密度后验可信区间更适用于不对称分布的情况(方杰,温忠麟,2023b)。如果中介效应的95%最高密度后验可信区间不包含0,就表示中介效应显著。

### 6.2 结果

前后路径被层2变量 $Z_j$ 调节的1-1-1密集追踪

中介效应分析结果见表4(<https://osf.io/e273c/>下载Mplus程序和运行结果)。首先检查Markov链的收敛情况,Markov链迭代300次后,PSR值都始终小于1.05,表明Markov链稳定收敛(方杰,温忠麟,2023b)。其次,除了 $d$ 和 $f$ 都不显著、表4中的其它参数都显著不等于0(可信区间都不包含0)。当 $Z_{high} = 0.92$ 和 $Z_{low} = -0.92$ 时,条件中介效应(1.024和0.172)都显著。实际上,在 $Z_j$ 的取值范围内,条件中介效应都显著(见图5,上下两条双曲线都不包含0)。条件中介效应之差( $1.024 - 0.172 = 0.852$ )也显著,表明中介效应受到 $Z_j$ 的调节。

表4 前后路径被调节的1-1-1密集追踪中介效应分析结果

| 参数                  | 点估计    | 区间估计             |
|---------------------|--------|------------------|
| $a$                 | 0.590  | [0.532, 0.652]   |
| $b$                 | 0.598  | [0.531, 0.660]   |
| $g$                 | 0.410  | [0.346, 0.475]   |
| $k$                 | 0.371  | [0.300, 0.439]   |
| $\sigma_{a_j, b_j}$ | 0.117  | [0.085, 0.151]   |
| IND1                | 1.024  | [0.879, 1.186]   |
| IND2                | 0.172  | [0.126, 0.225]   |
| IND1-IND2           | 0.852  | [0.700, 1.010]   |
| $c'$                | 0.218  | [0.172, 0.266]   |
| $d$                 | 0.161  | [-0.192, 0.529]  |
| $f$                 | -0.186 | [-1.152, 0.739]  |
| $l_x$               | 0.267  | [0.013, 0.515]   |
| $l_M$               | 8.995  | [8.660, 9.324]   |
| $l_Y$               | 35.151 | [34.281, 36.027] |
| $\beta_x$           | 0.291  | [0.269, 0.314]   |
| $\beta_M$           | 0.300  | [0.283, 0.317]   |
| $\beta_Y$           | 0.303  | [0.284, 0.312]   |

注: IND1和IND2是 $Z_{high}$ 和 $Z_{low}$ 时的条件中介效应。




图5 基于动态结构方程模型的条件中介效应

## 7 讨论

密集追踪数据作为新兴的复杂数据类型,需要方法学提供新的分析工具和分析方法与之相适应。例如,由于缺少相应的方法学指导,已有研究者只好将有调节的密集追踪中介效应当成有调节的多水平中介效应进行分析,忽略了纵向数据的时间先后特点。本研究使用动态结构方程模型建构了能考虑变量间先后关系的被层 2 变量调节的 1-1-1、2-1-1、2-2-1 密集追踪中介模型和被层 1 变量调节的 1-1-1 密集追踪中介模型,并通过模拟研究考查了被层 2 变量调节的 1-1-1 密集追踪中介模型的参数估计的准确性。

根据模拟研究的结果,当  $N \geq 100$  且  $T \geq 10$  时,有调节的密集追踪中介模型能得到准确的固定效应( $a$ 、 $b$ )值、协方差  $\sigma_{a,b_j}$  值、调节效应( $g$ 、 $k$ )值、条件中介效应值  $E(a_j b_j)$ , 以及条件中介效应的差异值  $\text{diff}$ 。但是,当  $T=10$  时,残差方差( $\sigma_{a_j}^2$  和  $\sigma_{b_j}^2$ )的相对偏差较大(大于 10%),这是因为方差都是非负数,相对偏差的模拟结果会天然地正偏。残差方差  $\sigma_{a_j}^2$  和  $\sigma_{b_j}^2$  的准确估计需要更大的  $N$  和  $T$ , 当  $T \geq 20$  时,才能得到准确的残差方差  $\sigma_{a_j}^2$  和  $\sigma_{b_j}^2$  值。接着,为了方便研究者使用,本文还提供了被调节的密集追踪中介效应分析示例及相应的 Mplus 程序(见网络版附录)。但本文仍有如下内容需要进一步讨论和拓展。

### 7.1 模型的前提假设

第一,本文涉及的有调节的中介模型假设密集追踪数据具有平稳性(stationarity),即变量的均值、方差以及自相关都不会随着时间发生系统性变化(Hamilton, 1994)。但密集追踪数据往往因为存在时间趋势(trend)时而导致违背平稳性假设,此时需要对原始数据进行去趋势(detrending)处理。对于线性的时间趋势,动态结构方程模型有两种常用的去趋势办法(Fang et al., 2024; McNeish & Hamaker, 2020)。一是在描述变量自身和变量间关系(即中介效应)的同时,将时间作为协变量加入动态结构方程模型构建有调节的密集追踪中介模型以控制时间效应。二是从变量中剥离随时间的发展趋势(即做每个变量对时间的回归)后,再利用残差建构有调节的密集追踪中介模型。此种方法可以用残差动态结构方程模型(residual dynamic structural equation modeling, RDSEM; Asparouhov et al., 2018)实现。Fang 等(2024)阐述了如何用这两种去趋势法进行层

2 调节变量  $Z_j$  调节的 1-1-1 密集追踪中介效应分析。

第二,本文涉及的有调节的中介模型还假设自回归效应( $\beta_{X_j}$ 、 $\beta_{M_j}$ 、 $\beta_{Y_j}$ )和滞后效应( $a_j$ 、 $b_j$  和  $c_j'$ )不随时间的变化而变化(没有下标  $t$ ),这要以重复测量的时间间隔相等为前提条件。因为自回归效应和滞后效应会随重复测量的时间间隔变长而变小(McNeish & Hamaker, 2020)。但是在实际应用中,很可能遇到时间间隔不等的现象。Mplus 软件给出的解决办法是在 VARIABLE 命令下,用 Tinterval 语句(见网络版附录)设置合适的时间间隔(time interval),然后用卡尔曼滤波(Kalman Filter)将时间间隔由不等变为相等(McNeish & Hamaker, 2020)。例如,三个测量时间点为 11 点、14 点和 15 点,这就出现时间间隔不等的现象。我们可以用“Tinterval=time(1)”语句设定时间间隔为 1 小时,则 11 点编码为  $t_0=0$ , 14 点和 15 点编码为  $t_3=3$  和  $t_4=4$ 。此时,12 点( $t_1=1$ )和 13 点( $t_2=2$ )没有变量的观测值,卡尔曼滤波能帮助我们得到这两个时间点的变量的预测值。具体地,卡尔曼滤波会根据 11 点的观测值预测 12 点的观测值;同理,卡尔曼滤波会根据 12 点的预测值预测 13 点的观测值。接着,卡尔曼滤波会根据 13 点的预测值预测 14 点的观测值,由于 14 点有观测值,卡尔曼滤波会放弃 14 点的预测值,直接用 14 点的观测值来预测 15 点的预测值,由于 15 点有观测值,卡尔曼滤波会用 15 点的观测值替换掉 15 点的预测值,最终得到时间间隔相等(均为 1 小时)的 5 个时间点的数据(即 11 点的观测值、12 和 13 点的预测值、14 和 15 点的观测值)。

第三,本文涉及的有调节的中介模型还假设调节变量  $Z_j$  不调节自回归效应(如  $Y_{(t-1)j} \rightarrow Y_{tj}$ ),调节变量对自变量也不产生影响。如果调节变量要调节自回归效应,需要在方程(6)添加  $Z_j$ ; 如果调节变量对自变量有效应,需要在方程(5)的  $l_{Xj} = l_X + \mu_{1j}$  中添加  $Z_j$ 。需要说明的是,建议在有理论基础的前提下,添加调节效应。随意的添加调节效应会让模型更为复杂,可能会导致模型收敛困难或参数难以估计等问题。如果出现估计困难,则建议研究者适当减少调节效应的数目,也可将部分层 2 随机效应改为固定效应(即删除相应的层 2 残差项  $\mu$ )。

### 7.2 模型的拓展

第一,本文的有调节的 1-1-1 中介模型只涉及连续变量,实际上本文的方法和步骤可拓展到二分类别变量的情况。如果自变量是二分类别变量,则将方程(1)改为:

$$\text{层 1: } X_{ij} = l_X + \beta_X X_{(t-1)j} + \varepsilon_{Xij} \quad (37)$$

其中  $l_X$  表示  $X_{(t-1)j} = 0$  时,  $X_{ij} = 1$  的概率;  $l_X + \beta_X$  表示  $X_{(t-1)j} = 1$  时,  $X_{ij} = 1$  的概率;  $l_X$  和  $\beta_X$  都是固定值。  $\varepsilon_{Xij}$  服从均值为 0, 方差为  $\sigma_X^2$  的正态分布。二分类别自变量  $X_{ij}$  不中心化, 原因有两个。一个是因为 Asparouhov 和 Muthén (2019) 的模拟研究表明, 对于二分变量, 显均值中心化比不中心化表现更差。另一个原因是 McNeish 和 MacKinnon (2025) 用一个实际例子, 对二分类别自变量进行潜变量中心化的 1-1-1 密集追踪中介效应分析, 结果发现层 2 随机效应的方差特别大。如果调节变量是二分类别变量 (如性别), 则将调节变量编码为 0 和 1 即可, 仍可使用连续变量的有调节的中介效应分析方法进行分析。更进一步, 已有研究者提出因变量是二分类别变量的动态结构方程模型分析方法 (Asparouhov et al., 2018; McNeish et al., 2024), 即将二分类别因变量转换为连续潜变量, 再利用 Probit 回归进行分析。但如何进行二分类别因变量的有调节的中介效应分析, 还需进一步深入研究。

第二, 本文的有调节的中介效应分析方法都对密集追踪变量 (如  $Y_{ij}$ ) 进行潜变量中心化 (如图 2 左侧), 将其分解为个体内潜变量 (如  $Y_{ij}^c$ ) 和个体间潜变量 (如  $l_{Yj}$ )。如果潜变量中心化遇到估计困难或无法估计的情况, 我们建议将潜变量中心化改为显变量中心化或者不中心化, 用多水平自回归模型 (multilevel autoregressive model) 进行有调节的中介效应分析 (Zhang et al., 2018)。以被层 2 变量调节的 1-1-1 密集追踪中介效应分析为例, 多水平自回归模型和动态结构方程模型共享层 2 方程 (即方程 (4)~(6)), 但层 1 的方程 (1)~(3) 变为

$$\text{层 1: } (X_{ij} - \bar{X}_{\cdot j}) = \beta_{Xj} (X_{(t-1)j} - \bar{X}_{\cdot j}) + \varepsilon_{Xij} \quad (38)$$

$$(M_{ij} - \bar{M}_{\cdot j}) = \beta_{Mj} (M_{(t-1)j} - \bar{M}_{\cdot j}) + a_j (X_{(t-1)j} - \bar{X}_{\cdot j}) + \varepsilon_{Mij} \quad (39)$$

$$(Y_{ij} - \bar{Y}_{\cdot j}) = \beta_{Yj} (Y_{(t-1)j} - \bar{Y}_{\cdot j}) + b_j (M_{(t-1)j} - \bar{M}_{\cdot j}) + c'_j (X_{(t-2)j} - \bar{X}_{\cdot j}) + \varepsilon_{Yij} \quad (40)$$

其中,  $\bar{X}_{\cdot j}$ 、 $\bar{M}_{\cdot j}$  和  $\bar{Y}_{\cdot j}$  是样本个体均值。如果变量 (如  $Y_{ij}$ ) 不进行中心化, 则层 1 方程变为:

$$\text{层 1: } X_{ij} = l_{Xj} + \beta_{Xj} X_{(t-1)j} + \varepsilon_{Xij} \quad (41)$$

$$M_{ij} = l_{Mj} + \beta_{Mj} M_{(t-1)j} + a_j X_{(t-1)j} + \varepsilon_{Mij} \quad (42)$$

$$Y_{ij} = l_{Yj} + \beta_{Yj} Y_{(t-1)j} + b_j M_{(t-1)j} + c'_j X_{(t-2)j} + \varepsilon_{Yij} \quad (43)$$

其中  $l_{Xj}$ 、 $l_{Mj}$  和  $l_{Yj}$  表示方程 (41)~(43) 的截距项, 而不是方程 (1)~(3) 的个体潜均值 (Zhang et al., 2018)。

第三, 本研究涉及的被调节的 1-1-1 密集追踪中介模型实际上是二阶滞后的中介模型, 即自变量  $X_{(t-2)j}$  滞后因变量  $Y_{ij}$  二个时间间隔 (McNeish & MacKinnon, 2025)。如果是自变量  $X_{(t-1)j}$  滞后因变量  $Y_{ij}$  一个时间间隔的 1-1-1 中介效应模型 (即中介效应的前半路径是  $X_{(t-1)j} \rightarrow M_{ij}$ 、后半路径是  $M_{(t-1)j} \rightarrow Y_{ij}$ ), 也称为一阶滞后的中介模型 (Fang et al., 2024)。本文提出的被调节的 1-1-1 密集追踪中介效应分析方法可以推广到一阶滞后的被调节的中介模型。具体地, 将方程 (3) 的  $X_{(t-2)j}$  改为  $X_{(t-1)j}$ 。

第四, 本文仅阐述了前半路径被层 1 变量  $Z_{ij}$  调节的 1-1-1 密集追踪中介模型的分析方法。该方法可推广到后半路径被调节的 1-1-1 密集追踪中介模型分析中。具体地, 如果中介的后半路径被调节, 则先抽取  $M_{ij}^c$  和  $Z_{ij}^c$ , 将之另存为新的层 1 观测变量  $M\_W$  和  $Z\_W$ , 并利用 Mplus 软件的 “define” 语句生成一个新变量  $intmz_{ij} = M\_W * Z\_W$ 。然后, 利用动态结构方程模型将  $intmz_{ij}$  分解为个体间潜变量  $l_{intmzj}$  和个体内潜变量  $intmz_{ij}^c$  ( $intmz_{ij}^c = intmz_{ij} - l_{intmzj}$ )。接着, 增加自回归方程 (44)

$$\text{层 1: } intmz_{ij}^c = \beta_{intmz} intmz_{(t-1)j}^c + \varepsilon_{intmzij} \quad (44)$$

最后, 将方程 (28) 改为

$$Y_{ij}^c = \beta_{Yj} Y_{(t-1)j}^c + b_j M_{(t-1)j}^c + c'_j X_{(t-2)j}^c + f_j Z_{(t-1)j}^c + k_j intmz_{(t-1)j}^c + h_j int_{(t-1)j}^c + \varepsilon_{Yij} \quad (45)$$

层 2 增加方程 (46)

$$\text{层 2: } f_j = f + \mu_{22j} \quad k_j = k + \mu_{23j} \quad h_j = h + \mu_{24j} \quad (46)$$

即可进行后半路径被调节的中介效应分析了。系数  $k$  表示层 1 变量  $Z_{ij}$  调节中介效应的后半路径, 系数  $h$  表示层 1 变量  $Z_{ij}$  调节直接路径。条件中介效应的均值见方程 (9) (需要将  $Z_j$  换为  $Z\_W$ ), 中介效应是否被调节的判断和 3.1 节相同。

最后, 基于动态结构方程模型的被调节的密集追踪中介模型总结如表 5 所示, 研究者可根据调节变量所在的水平 (水平 1 或水平 2)、中介的类型 (1-1-1、2-1-1 和 2-2-1)、被调节的中介路径 (前半路径和直接路径、后半路径和直接路径、三条路径都被调节) 来选择表 5 中对应的模型进行被调节的中介效应分析。更进一步, 如果不考虑直接路径是否被调节, 只考虑调节前、后半路径, 则需要去掉回归系数  $h$  即可; 如果只考虑调节后半路径, 则还需要去掉回归系数  $f$  即可; 如果只调节前半路径, 则还需要去掉回归系数  $f$  和  $h$  才可以。

表 5 被调节的密集追踪中介模型汇总表

| 调节变量     | 中介模型  | 被调节的中介路径                        |                                 |                                                   |
|----------|-------|---------------------------------|---------------------------------|---------------------------------------------------|
|          |       | 前、后路径和直接路径                      | 前半路径和直接路径                       | 后半路径和直接路径                                         |
| $Z_j$    | 1-1-1 | 方程(1)-(7)                       | 去掉方程(5)的 $kZ_j$                 | 去掉方程(4)的 $dZ_j$ 和方程(5)的 $gZ_j$                    |
|          | 2-1-1 | 方程(13)-(19)                     | 去掉方程(16)的 $kl_{Mj}Z_j$          | 去掉方程(15)的 $dZ_j$ 和 $gX_jZ_j$                      |
|          | 2-2-1 | 方程(20)-(24)                     | 去掉方程(21)的 $kM_jZ_j$             | 去掉方程(24)的 $dZ_j$ 和 $gX_jZ_j$                      |
| $Z_{ij}$ | 1-1-1 | 方程(25)-(26)、(29)-(34)和(44)-(46) | 去掉方程(45)的 $k_jintmz_{(t-1)j}^c$ | 去掉方程(34)的 $d_jZ_{(t-1)j}^c$ 和 $g_jint_{(t-1)j}^c$ |

## 参 考 文 献

- Asparouhov, T., Hamaker, E. L., & Muthén, B. (2018). Dynamic structural equation models. *Structural Equation Modeling: A Multidisciplinary Journal*, 25(3), 359–388.
- Asparouhov, T., & Muthén, B. (2019). Latent variable centering of predictors and mediators in multilevel and time-series models. *Structural Equation Modeling: A Multidisciplinary Journal*, 26(1), 119–142.
- Asparouhov, T., & Muthén, B. (2020). Comparison of models for the analysis of intensive longitudinal data. *Structural Equation Modeling: A Multidisciplinary Journal*, 27(2), 275–297.
- Baron, R. M., & Kenny, D. A. (1986). The moderator-mediator variable distinction in social psychological research: Conceptual, strategic, and statistical considerations. *Journal of Personality and Social Psychology*, 51(6), 1173–1182.
- Bauer, D. J., Preacher, K. J., & Gil, K. M. (2006). Conceptualizing and testing random indirect effects and moderated mediation in multilevel models: New procedures and recommendations. *Psychological Methods*, 11(2), 142–163.
- Bradley, J. V. (1978). Robustness? *British Journal of Mathematical and Statistical Psychology*, 31(2), 144–152.
- Cheung, G. W., & Lau, R. S. (2017). Accuracy of parameter estimates and confidence intervals in moderated mediation models: A comparison of regression and latent moderated structural equation. *Organizational Research Methods*, 20(4), 746–769.
- Collins, L. M. (2006). Analysis of longitudinal data: The integration of theoretical model, temporal design, and statistical model. *Annual Review of Psychology*, 57, 505–528.
- Edwards, J. R., & Lambert, L. S. (2007). Methods for integrating moderation and mediation: A general analytic framework using moderated path analysis. *Psychological Methods*, 12(1), 1–22.
- Fang, J., & Wen, Z. L. (2018). Moderated mediation effects based on structural equation modeling. *Journal of Psychological Science*, 41(2), 453–458.
- [方杰, 温忠麟. (2018). 基于结构方程模型的有调节的中介效应. *心理科学*, 41(2), 453–458.]
- Fang, J., & Wen, Z. (2023a). Analysis of multilevel moderated mediation models. *Journal of Psychological Science*, 46(1), 221–229.
- [方杰, 温忠麟. (2023a). 有调节的多层中介效应分析. *心理科学*, 46(1), 221–229.]
- Fang, J., & Wen, Z. (2023b). *Advanced models for analyzing mediation and moderation effects*. Education Science Publishing House.
- [方杰, 温忠麟. (2023b). 中介效应和调节效应模型进阶. 教育科学出版社.]
- Fang, J., Wen, Z., & Hau, K-T. (2024). Mediation analyses of intensive longitudinal data with dynamic structural equation modeling. *Structural Equation Modeling: A Multidisciplinary Journal*, 31(4), 728–741.
- Fang, J., Wen, Z., & He, Z. (2023). Moderated mediation analyses of a frequently-used types of categorical variable. *Chinese Journal of Applied Psychology*, 29(4), 291–299.
- [方杰, 温忠麟, 何子杰. (2023). 常见的类别变量的有调节的中介模型分析. *应用心理学*, 29(4), 291–299.]
- Fang, Y., & Wang, L. (2024). Dynamic structural equation models with missing data: Data requirements on  $N$  and  $T$ . *Structural Equation Modeling: A Multidisciplinary Journal*, 31(5), 891–908.
- Gistelinck, F., Loeys, T., & Flamant, N. (2021). Multilevel autoregressive models when the number of time points is small. *Structural Equation Modeling: A Multidisciplinary Journal*, 28(1), 15–27.
- Hamaker, E. L., & Wichers, M. (2017). No time like the present: Discovering the hidden dynamics in intensive longitudinal data. *Current Directions in Psychological Science*, 26(1), 10–15.
- Hamilton, J. D. (1994). *Time series analysis*. Princeton, NJ: Princeton University Press.
- Hayes, A. F. (2015). An index and test of linear moderated mediation. *Multivariate Behavioral Research*, 50(1), 1–22.
- Hayes, A. F. (2022). *Introduction to mediation, moderation, and conditional process analysis: A regression-based approach* (3rd ed.). New York: Guilford Press.
- Kenny, D. A., Korchmaros, J. D., & Bolger, N. (2003). Lower level mediation in multilevel models. *Psychological Methods*, 8(2), 115–128.
- Lischetzke, T., Schemer, L., Glombiewski, J. A., In-Albon, T., Karbach, J., & Könen, T. (2021). Negative emotion differentiation attenuates the within-person indirect effect of daily stress on nightly sleep quality through calmness. *Frontiers in Psychology*, 12, 684117.
- McKellar, S. E., & Wang, M. (2023). Adolescents' daily sense of school connectedness and academic engagement: Intensive longitudinal mediation study of student differences by remote, hybrid, and in-person learning modality. *Learning and Instruction*, 83, 101659.
- McNeish, D., & Hamaker, E. L. (2020). A primer on two-level dynamic structural equation models for intensive longitudinal data in Mplus. *Psychological Methods*, 25(5), 610–635.
- McNeish, D., & MacKinnon, D. P. (2025). Intensive longitudinal mediation in Mplus. *Psychological Methods*, 30(2), 393–415. <https://dx.doi.org/10.1037/met0000536>
- McNeish, D., Somers, J. A. & Savord, A. (2024). Dynamic structural equation models with binary and ordinal outcomes in Mplus. *Behavior Research Methods*, 56(3), 1506–1532.
- Muller, D., Judd, C. M., & Yzerbyt, V. Y. (2005). When moderation is mediated and mediation is moderated.

- Journal of Personality and Social Psychology*, 89(6), 852–863.
- Muthén, L. K., & Muthén, B. O. (2002). How to use a Monte Carlo study to decide on sample size and determine power. *Structural Equation Modeling: A Multidisciplinary Journal*, 9(4), 599–620.
- Muthén, L. K., & Muthén, B. O. (1998–2017). *Mplus user's guide*. Los Angeles, CA: Muthén and Muthén
- Preacher, K. J., Zhang, Z., & Zyphur, M. J. (2016). Multilevel structural equation models for assessing moderation within and across levels of analysis. *Psychological Methods*, 21(2), 189–205.
- Preacher, K. J., Zyphur, M. J., & Zhang, Z. (2010). A general multilevel SEM framework for assessing multilevel mediation. *Psychological Methods*, 15(3), 209–233.
- Speyer, L. G., Murray, A. L., & Kievit, R. (2024). Investigating moderation effects at the within-person level using intensive longitudinal data: A two-level dynamic structural equation modelling approach in Mplus. *Multivariate Behavioral Research*, 59(3), 620–637.
- Talty, A., Speyer, L. G., Eisner, M. P., Ribeaud, D., Murray, A. L., & Obsuth, I. (2023). The role of student–teacher relationships in the association between negative parenting practices and emotion dynamics – Combining longitudinal and ecological momentary assessment data. *Journal of Research on Adolescence*, 33(4), 1268–1280.
- Wang, L., & Preacher, K. J. (2015). Moderated mediation analysis using Bayesian methods. *Structural Equation Modeling: A Multidisciplinary Journal*, 22(2), 249–263.
- Wang, Q., Yan, G., Hu, Y., Ding, G., & Lai, Y. (2024). Stress and emotion in a locked campus: The moderating effects of resilience and loneliness. *Frontiers in Psychology*, 14, 1168020.
- Wen, Z., & Ye, B. (2014). Different methods for testing moderated mediation models: Competitors or backups? *Acta Psychologica Sinica*, 46(5), 714–726.
- [温忠麟, 叶宝娟. (2014). 有调节的中介模型检验方法: 竞争还是替补? *心理学报*, 46(5), 714–726.]
- Zhang, Q., Wang, L. J., & Bergeman, C. S. (2018). Multilevel autoregressive mediation models: Specification, estimation, and applications. *Psychological Methods*, 23(2), 278–297.
- Zheng, S., Zhang, L., Qiao, X., & Pan, J. (2021). Intensive longitudinal data analysis: Models and application. *Advances in Psychological Science*, 29(11), 1948–1969.
- [郑舒方, 张沥今, 乔欣宇, 潘俊豪. (2021). 密集追踪数据分析: 模型及其应用. *心理科学进展*, 29(11), 1948–1969.]
- Zhou, L., Wang, M., & Zhang, Z. (2021). Intensive longitudinal data analyses with dynamic structural equation modeling. *Organizational Research Methods*, 24(2), 219–250.

## Moderated mediation analyses of intensive longitudinal data

FANG Jie<sup>1</sup>, WEN Zhonglin<sup>2</sup>, WANG Huihui<sup>3</sup>, GU Honglei<sup>4</sup>

(<sup>1</sup> Institute of New Development, Guangdong University of Finance & Economics, Guangzhou 510320, China)

(<sup>2</sup> Center for Studies of Psychological Application & School of Psychology, South China Normal University, Guangzhou 510631, China)

(<sup>3</sup> School of Education, Ningxia University, Yinchuan 750021, China) (<sup>4</sup> Department of Psychology, School of Educational Sciences, Hunan Normal University; Cognition and Human Behavior Key Laboratory of Hunan Province, Changsha 410081, China)

### Abstract

Intensive longitudinal data (ILD) is increasing in fields such as psychology and management, yet research on analytical methods for ILD remains relatively scant. Traditionally, the ILD is statistically modeled as a two-level structure, with Level 1 being the time and Level 2 being individuals. Especially, existing analytical methods treat longitudinal moderated mediation as multilevel moderated mediation, without considering the lagged relationship between variables. A possible solution is to use dynamic structural equation modeling (DSEM) for ILD moderated mediation analysis.

DSEM has recently been used for analyzing intensive longitudinal mediation (ILMed; Fang et al., 2024; McNeish & MacKinnon, 2022) and intensive longitudinal moderation (ILMod; Speyer et al., 2024). However, it remains unclear how DSEM can be employed in analyzing intensive longitudinal moderated mediation (ILMM). The purpose of this paper is to combine ILMed and ILMod based on DSEM and propose a method of moderated mediation analysis that takes into account the temporal order between variables.

For the 1-1-1 ILMed model where all variables are measured at Level 1 (i.e., all variables are ILD), it might be moderated by variables of Level 1 or Level 2. However, for the 2-1-1 ILMed model (i.e., only the independent variable is measured at Level 2) and the 2-2-1 ILMed model (i.e., only the dependent variable is measured at Level 1), they could only be moderated by variables of Level 2. Therefore, there are four basic types of ILMM models: 2-1-1 ILMed moderated by a level 2 moderator, 2-2-1 ILMed moderated by a level 2 moderator, 1-1-1 ILMed moderated by a level 2 moderator, and 1-1-1 ILMed moderated by a level 1 moderator.

This paper describes in detail how to construct the above four ILMM models with DSEM, so that empirical

researchers can understand which kind of ILMM model meets their needs and how to analyze it. Mplus codes for analyzing all these ILMM models are provided.

A simulation study is conducted to examine the estimation accuracy of the 1-1-1 ILMed moderated by a level 2 moderator, with the following factors taken into account: sample size ( $N$ ), number of time points ( $T$ ), indirect effect sizes, and Level-2 variances and covariances. Results show that the estimates for the average mediation effect components ( $a$  and  $b$ ) and the average mediation effect are generally accurate when  $N \geq 100$  and  $T \geq 10$ . However, a sufficiently large  $N$  and  $T$  (e.g.,  $T \geq 20$ ) are required in order to obtain accurate estimation of Level-2 variances.

Lastly, we discuss assumptions and the extensions of ILMM based on DSEM. As usual, the models used in this paper are based on the assumption that the time series is stationary. Otherwise, residual DSEM can be employed to detrend in ILMM analysis.

**Keywords** intensive longitudinal data, moderated mediation effect, dynamic structural equation model

## 附录:

## 1. 前后路径和直接路径都被层 2 变量调节的二阶滞后的 1-1-1 中介效应分析(模型 1) Mplus 程序

DATA: FILE = 111mome.dat; !使用长格式数据

VARIABLE: NAMES = Z Y X M day PERSON;

USEVARIABLES = PERSON X M Y Z day;

BETWEEN=Z;

Lagged = Y(1) M(1) X(2); !创造前一时刻的预测变量  $Y_{(t-1)j}$ 、 $M_{(t-1)j}$  和  $X_{(t-2)j}$

CLUSTER=PERSON; !被试为层 2 的组

TINTERVAL = day(1);

DEFINE: CENTER Z(GRANDMEAN); !Z 按总均值中心化

ANALYSIS: TYPE = TWOLEVEL RANDOM; !随机斜率的两层数据分析

ESTIMATOR = BAYES; !用贝叶斯方法

BITERATIONS= (20000); !迭代至少 20000 次

MODEL: %WITHIN% !层 1 部分

BETA1 | Y ON Y&1; !求自回归效应  $\beta_{Yj}$

BETA2 | X ON X&1; !求自回归效应  $\beta_{Xj}$

BETA3 | M ON M&1; !求自回归效应  $\beta_{Mj}$

GAMA1 | Y ON X&2; !求一阶滞后效应  $c'_j$

GAMA2 | M ON X&1; !求一阶滞后效应  $a_j$

GAMA3 | Y ON M&1; !求一阶滞后效应  $b_j$

LogV1 | Y; !求  $\varepsilon_{Yij}$  的方差的对数

LogV2 | X; !求  $\varepsilon_{Xij}$  的方差的对数

LogV3 | M; !求  $\varepsilon_{Mij}$  的方差的对数

%BETWEEN%

M ON Z(d);

Y ON Z(f);

GAMA2 ON Z(g);

GAMA3 ON Z(k);

GAMA1 ON Z(h);

[Y]; [X]; [M]; !求  $l_Y$ 、 $l_X$ 、 $l_M$

[BETA1]; [BETA2]; [BETA3]; [GAMA1]; !求  $\beta_Y$ 、 $\beta_X$ 、 $\beta_M$ 、 $c'$

[GAMA2](a);

[GAMA3](b);

[LogV1]; [LogV2]; [LogV3]; !求  $\omega_X$ 、 $\omega_M$  和  $\omega_Y$

GAMA2 with GAMA3(cab);

Y X M BETA1-BETA3 GAMA1-GAMA3 LogV1-LogV3 with Y X M BETA1-BETA3 GAMA1-GAMA3

LogV1-LogV3;

Y; X; M; !求  $l_{Yj}$ 、 $l_{Xj}$ 、 $l_{Mj}$  的误差的方差

BETA1; BETA2; BETA3; !求  $\beta_{Yj}$ 、 $\beta_{Xj}$ 、 $\beta_{Mj}$  的误差的方差

GAMA1; GAMA2; GAMA3; !求  $c'_j$ 、 $a_j$ 、 $b_j$  的误差的方差

LogV1; LogV2; LogV3; !求  $\mu_{Xj}$ 、 $\mu_{Mj}$ 、 $\mu_{Yj}$  的方差

model constraint: new(ind1 ind2 ind3);

ind1=(a+g\*0.92)\*(b+k\*0.92)+cab; ! $Z_{high}$  的条件中介效应

```

ind2=(a-g*0.92)*(b-k*0.92)+cab; !Zlow 的条件中介效应
ind3=ind1-ind2;
PLOT(indirect); !画图的纵坐标是 indirect
LOOP(moderator,-1.6,2.1,0.1);
indirect = (a+g*moderator)*(b+k*moderator)+cab;
OUTPUT: tech1; !给出参数的先验分布
tech8; !给出 PSR 值检验 Markov 链是否收敛
cinterval(hpd); !给出最高后验密度的可信区间
PLOT: type=plot2; !画图

```

注：“LOOP(moderator,-1.6,2.1,0.1)”表示画图的横坐标是 moderator(即调节变量  $Z_j$ )，“-1.6, 2.1”表示  $Z_j$  取值的最小值和最大值, 0.1 表示画图时, 每隔 0.1 取一个调节变量值。

1)如果只调节中介的前半路径和直接路径(模型 2), 则去掉“GAMA3 ON Z(k)”, “ind1=(a+g\*0.92)\*(b+k\*0.92)+cab”改为“ind1=(a+g\*0.92)\*b +cab”, “ind2=(a-g\*0.92)\*(b-k\*0.92)+cab”改为“ind1=(a-g\*0.92) \*b+cab”, “indirect = (a+g\*moderator)\*(b+k\*moderator)+cab”改为“indirect = (a+g\*moderator)\*b+cab”即可。

2) 如果只调节中介的后半路径和直接路径(模型 3), 则去掉“M ON Z(d)”和“GAMA2 ON Z(g)”, “ind1=(a+g\*0.92)\*(b+k\*0.92)+cab”改为“ind1=a\*(b+k\*0.92)+cab”, “ind2=(a-g\*0.92)\*(b-k\*0.92)+cab”改为“ind1= a\*(b-k\*0.92) +cab”, “indirect = (a+g\*moderator)\*(b+k\*moderator)+cab”改为“indirect = a\*(b+k\*moderator)+cab”即可。

3)如果不调节直接路径, 则去掉“GAMA1 ON Z(h);”语句, 即是示例的分析程序。

4)如果是被层 2 变量调节的一阶滞后的 1-1-1 中介效应分析, 则将“Lagged = Y(1) M(1) X(2);”中的“X(2)”改为“X(1)”, “GAMA1 | Y ON X&2;”中的“X&2”改为“X&1”即可。

5)层 2 的调节变量  $Z_j$  还可以设置为潜变量。例如潜变量  $Z_j$  有三个指标( $Z_1$ 、 $Z_2$  和  $Z_3$ ), 则在“%BETWEEN%”部分增加“Z by z1-z3;”。同时, “VARIABLE”部分的 Z 替换为  $Z_1$ 、 $Z_2$  和  $Z_3$ ; 删掉“DEFINE”部分的“CENTER Z(GRANDMEAN)”语句。

## 2. 前后路径和直接路径都被层 2 变量调节的 2-1-1 中介效应分析(模型 4)的 Mplus 程序

步骤一: 抽取  $I_{Mj}$  的值, 保存为因子分数

DATA: FILE =211.dat;

VARIABLE: NAMES = Z X Y M day PERSON;

USEVARIABLES = M;

CLUSTER=PERSON;

AUXILIARY = Z X Y day; !变量 Z X Y day 将原封不动地保存在 211mome.dat 文件中

ANALYSIS: TYPE=TWOLEVEL RANDOM;

ESTIMATOR=MLR;

MODEL = NOCOVARIANCES; !MODEL 中没有指明的所有协方差都固定为 0

MODEL:

%WITHIN%

M\_W BY M@1; M@0; !将 M 的组内部分设置为潜变量

%Between%

SAVEDATA: FILE = 211mome.dat;

SAVE = FSCORES; !保存为因子分数

FORMAT = free;

注: 在最终保存的 211mome.dat 文件中保存的变量依次是 M、Z、X、Y、day、M\_W、B\_M(即  $I_{Mj}$ )、B\_M\_SE、PERSON。

步骤二:

```

DATA: FILE = 211mome.dat;
VARIABLE: NAMES = M Z X Y day M_W B_M B_M_SE PERSON;
USEVARIABLES = X M B_M Y Z PERSON day MZ XZ;
BETWEEN=Z X B_M;
Lagged = Y(1) M(1); !创造前一时刻的预测变量  $Y_{(t-1)j}$ 、 $M_{(t-1)j}$ 
CLUSTER=PERSON; !被试为层 2 的组
TINTERVAL = day(1);
DEFINE: CENTER X Z(GRANDMEAN); !X 和 Z 按总均值中心化
MZ= B_M* Z; !定义调节项 MZ
XZ=X*Z; !定义调节项 XZ
ANALYSIS: TYPE = TWOLEVEL RANDOM; !随机斜率的两层数据分析
ESTIMATOR = BAYES; !用贝叶斯方法
BITERATIONS= (20000); !迭代至少 20000 次
MODEL: %WITHIN% !层 1 部分
BETA1 | Y ON Y&1; !求自回归效应  $\beta_{Yj}$ 
BETA3 | M ON M&1; !求自回归效应  $\beta_{Mj}$ 
bw | Y ON M&1;
LogV1 | Y; !求  $\varepsilon_{Yj}$  的方差的对数
LogV3 | M; !求  $\varepsilon_{Mj}$  的方差的对数
%BETWEEN%
M ON X(a)
Z(d)
XZ(g);
Y ON Z(f)
X
B_M(b)
XZ(h)
MZ(k);
[Y]; [M]; !求  $l_Y$ 、 $l_M$ 
[BETA1]; [BETA3]; [bw]; !求  $\beta_Y$ 、 $\beta_M$ 、 $b_W$ 
[LogV1]; [LogV3]; !求  $\omega_Y$  和  $\omega_X$ 
Y; M; !求  $l_{Yj}$ 、 $l_{Mj}$  的误差的方差
BETA1; BETA3; bw; !求  $\beta_{Yj}$ 、 $\beta_{Xj}$ 、 $b_{Wj}$  的误差的方差
LogV1; LogV3; !求  $\mu_{Yj}$ 、 $\mu_{Mj}$  的方差
Y BETA1 BETA3 bw LogV1 LogV3 with Y BETA1 BETA3 bw LogV1 LogV3;
M with BETA1 BETA3 bw LogV1 LogV3;
model constraint: new(ind1 ind2 ind3);
ind1=(a+g*Zhigh)*(b+k*Zhigh); !用实际数据的  $Z_{high}$  值取代公式中的“Zhigh”
ind2=(a+g* Zlow)*(b+k*Zlow); !用实际数据的  $Z_{low}$  值取代公式中的“Zlow”
ind3=ind1-ind2;
PLOT(indirect);
LOOP(moderator,Zmin, Zmax,0.1); !用实际数据的  $Z_{max}$  值和  $Z_{min}$  值取代“Zmax”和“Zmin”
indirect = (a+g*moderator)*(b+k*moderator);
OUTPUT: tech1; tech8; cinterval(hpd);

```

PLOT: type=plot2;

注: 1) 如果不调节直接路径, 则去掉“XZ(h)”即可。层 2 变量  $X_j$ 、 $Z_j$  都可以设置为潜变量, 设置方法同附录 1 的注解(5)。

2) 如果只调节中介的前半路径和直接路径(模型 5), 则去掉“MZ(k)”, “ind1=(a+g\*Zhig)\*(b+ k\*Zhig);” 改为 “ ind1=(a+g\*Zhig)\*b; ”, “ ind2=(a+g\*Zlow)\*(b+k\*Zlow); ” 改 为 “ ind1=(a+g\*Zlow)\*b; ”, “ indirect = (a+g\*moderator)\*(b+k\*moderator)+cab” 改为 “indirect = (a+g\*moderator)\*b” 即可。

3) 如果只调节中介的后半路径和直接路径(模型 6), 则去掉“Z(d)”和“XZ(g)”, “ind1=(a+g\*Zhig)\*(b+k\*Zhig);” 改 为 “ ind1=a\*(b+k\*Zhig); ”, “ ind2=(a+g\*Zlow)\*(b+k\*Zlow) ” 改 为 “ ind2=a\*(b+k\*Zlow) ”, “ indirect = (a+g\*moderator)\*(b+k\*moderator)” 改为 “indirect =a\*(b+k\*moderator)” 即可。

### 3. 前后路径和直接路径都被层 2 变量调节的 2-2-1 中介效应分析(模型 7)的 Mplus 程序

DATA: FILE =221mome.dat;

VARIABLE: NAMES = M Z X Y day PERSON;

USEVARIABLES = M Z X Y PERSON day MZ XZ;

BETWEEN=M Z X;

Lagged = Y(1); !创造前一时刻的预测变量  $Y_{(t-1)j}$

CLUSTER=PERSON; !被试为层 2 的组

TINTERVAL = day(1);

DEFINE: CENTER M X Z(GRANDMEAN); !M、X 和 Z 按总均值中心化

MZ= M\*Z; !定义调节项 MZ

XZ=X\*Z; !定义调节项 XZ

ANALYSIS: TYPE = TWOLEVEL RANDOM; !随机斜率的两层数据分析

ESTIMATOR = BAYES; !用贝叶斯方法

BITERATIONS= (20000); !迭代至少 20000 次

MODEL: %WITHIN% !层 1 部分

BETA1 | Y ON Y&1; !求自回归效应  $\beta_{Yj}$

LogV1 | Y; !求  $\varepsilon_{Yij}$  的方差的对数

%BETWEEN%

M ON X(a)

Z(d)

XZ(g);

Y ON Z(f)

X

M(b)

XZ(h)

MZ(k);

[Y]; [BETA1]; [LogV1]; !求  $I_Y$ 、 $\beta_Y$ 、 $\omega_Y$

Y; BETA1; LogV1; !求  $I_{Yj}$ 、 $\beta_{Yj}$ 、 $\mu_{Yj}$  的误差的方差

Y BETA1 LogV1 with Y BETA1 LogV1;

model constraint: new(ind1 ind2 ind3);

ind1=(a+g\*Zhig)\*(b+k\*Zhig); !用实际数据的  $Z_{high}$  值取代公式中的“Zhig”

ind2=(a+g\* Zlow)\*(b+k\*Zlow); !用实际数据的  $Z_{low}$  值取代公式中的“Zlow”

ind3=ind1-ind2;

PLOT(indirect);

```

LOOP(moderator,Zmin, Zmax,0.1); !用实际数据的  $Z_{max}$  值和  $Z_{min}$  值取代 “Zmax” 和 “Zmin”
indirect = (a+g*moderator)*(b+k*moderator);
OUTPUT: tech1; tech8; cinterval(hpd);
PLOT: type=plot2;
注: 同附录 2 的注。

```

#### 4. 前半路径被层 1 变量调节的 1-1-1 中介效应分析(模型 10)的 Mplus 程序

步骤一: 抽取  $X_{(t-1)j}^c$  和  $Z_{(t-1)j}^c$  的值, 保存为因子分数

```

DATA: FILE =111.dat;
VARIABLE: NAMES = X M Y Z day PERSON;
USEVARIABLES = X Z;
CLUSTER=PERSON;
AUXILIARY = M Y day; !变量 M Y day 将原封不动地保存在 111mome.dat 文件中
ANALYSIS: TYPE=TWOLEVEL RANDOM;
ESTIMATOR=MLR;
MODEL = NOCOVARIANCES; !MODEL 中没有指明的所有协方差都固定为 0
MODEL:
%WITHIN%
X_W BY X@1; X@0; !将 X 的组内部分设置为潜变量
Z_W BY Z@1; Z@0; !将 Z 的组内部分设置为潜变量
%Between%
SAVEDATA: FILE = 111mome.dat;
SAVE = FSCORES; !保存为因子分数
FORMAT = free;

```

注: 在最终保存的 111mome.dat 文件中保存的变量依次是 X、Z、M、Y、day、X\_W、Z\_W、B\_X、B\_X\_SE、B\_Z、B\_Z\_SE、PERSON。

步骤二:

```

DATA: FILE =111mome.dat;
VARIABLE: NAMES = X Z M Y day X_W Z_W B_X B_X_SE B_Z B_Z_SE PERSON;
USEVARIABLES = X Z M Y X_W Z_W day PERSON XZ;
Lagged = Y(1) M(1) Z(1) X(2) XZ(1); !创造前一时刻的预测变量  $Y_{(t-1)j}$ 、 $M_{(t-1)j}$ 、 $Z_{(t-1)j}$ 、 $X_{(t-2)j}$ 、 $XZ_{(t-1)j}$ 
CLUSTER=PERSON; !被试为层 2 的组
TINTERVAL = day(1);
DEFINE: XZ= X_W * Z_W; !定义调节项 XZ
ANALYSIS: TYPE = TWOLEVEL RANDOM; !随机斜率的两层数据分析
ESTIMATOR = BAYES; !用贝叶斯方法
BITERATIONS= (20000); !迭代至少 20000 次
MODEL: %WITHIN% !层 1 部分
BETA1 | Y ON Y&1; !求自回归效应  $\beta_{Yj}$ 
BETA2 | X ON X&1; !求自回归效应  $\beta_{Xj}$ 
BETA3 | M ON M&1; !求自回归效应  $\beta_{Mj}$ 
BETA4 | Z ON Z&1; !求自回归效应  $\beta_{Zj}$ 
XZ ON XZ&1; ! 改为 “XZ ON XZ&1@0;” 表示自回归效应固定为 0

```

```

GAMA2 | M ON X&1; !求一阶滞后效应  $a_j$ 
GAMA4 | M ON Z&1; !求一阶滞后效应  $d_j$ 
GAMA5 | M ON XZ&1; !求一阶滞后效应  $g_j$ 
GAMA1 | Y ON X&2; !求一阶滞后效应  $c'_j$ 
GAMA3 | Y ON M&1; !求一阶滞后效应  $b_j$ 
LogV1 | Y; !求  $\varepsilon_{Yj}$  的方差的対数
LogV2 | X; !求  $\varepsilon_{Xj}$  的方差的対数
LogV3 | M; !求  $\varepsilon_{Mj}$  的方差的対数
LogV4 | Z; !求  $\varepsilon_{Zj}$  的方差的対数
%BETWEEN%
[Y]; [X]; [M]; [Z]; !求  $l_Y$ 、 $l_X$ 、 $l_M$ 、 $l_Z$ 
[BETA1]; [BETA2]; [BETA3]; [BETA4]; !求  $\beta_Y$ 、 $\beta_X$ 、 $\beta_M$ 、 $\beta_Z$ 
[GAMA2](a);
[GAMA3](b);
[GAMA1];
[GAMA4];
[GAMA5](g);
[LogV1]; [LogV2]; [LogV3]; [LogV4]; !求  $\omega_X$ 、 $\omega_M$ 、 $\omega_Y$  和  $\omega_Z$ 
GAMA2 with GAMA3(cab);
Y X M Z BETA1-BETA4 GAMA1-GAMA5 LogV1-LogV4 with Y X M Z BETA1-BETA4 GAMA1-GAMA5
LogV1-LogV4;
Y; X; M; Z; !求  $l_{Yj}$ 、 $l_{Xj}$ 、 $l_{Mj}$ 、 $l_{Zj}$  的误差的方差
BETA1; BETA2; BETA3; BETA4; !求  $\beta_{Yj}$ 、 $\beta_{Xj}$ 、 $\beta_{Mj}$ 、 $\beta_{Zj}$  的误差的方差
GAMA1; GAMA2; GAMA3; GAMA4; GAMA5; !求  $c'_j$ 、 $a_j$ 、 $b_j$ 、 $d_j$ 、 $g_j$  的误差的方差
LogV1; LogV2; LogV3; LogV4; !求  $\mu_{Xj}$ 、 $\mu_{Mj}$ 、 $\mu_{Yj}$ 、 $\mu_{Zj}$  的方差
model constraint: new(ind1 ind2 ind3);
ind1=(a+g*Zhigh)*b+cab; ! $Z_{high}$  的条件中介效应
ind2=(a+g*Zlow)*b+cab; ! $Z_{low}$  的条件中介效应
ind3=ind1-ind2;
PLOT(indirect); !画图的纵坐标是 indirect
LOOP(moderator,Zmin, Zmax,0.1);
indirect = (a+g*moderator)*b+cab;
OUTPUT: tech1; !给出参数的先验分布
tech8; !给出 PSR 值检验 Markov 链是否收敛
cinterval(hpd); !给出最高后验密度的可信区间
PLOT: type=plot2; !画图

```

注:如果是被层 2 变量调节的一阶滞后的 1-1-1 中介效应分析,则将“Lagged = Y(1) M(1) X(2) XZ(1);”中的“X(2)”改为“X(1)”,“GAMA1 | Y ON X&2;”中的“X&2”改为“X&1”即可。