

## · 基础理论与方法 ·

# 纵向数据中评估暴露总效应的序列条件平均模型

王小磊<sup>1</sup> 田梦圆<sup>1</sup> 张娜<sup>1,2</sup> 高红<sup>1</sup> 谭红专<sup>1</sup>

<sup>1</sup> 中南大学湘雅公共卫生学院流行病与卫生统计学系,长沙 410078; <sup>2</sup> 湖南省人民医院/湖南师范大学附属第一医院,长沙 410016

通信作者: 谭红专, Email: tanhz99@qq.com

**【摘要】** 在前瞻性队列研究中,经常需要对研究对象进行多次随访,其产生的多个观测值之间相互关联,常导致时依性混杂,这种情况下数据一般不满足传统的多因素回归分析的应用条件。序列条件平均模型(SCMM)是一种可以处理时依性混杂的新方法。本文主要对 SCMM 的基本原理、步骤及特点进行概括。

**【关键词】** 序列条件平均模型; 时依性协变量; 倾向评分; 广义估计方程

DOI:10.3760/cma.j.issn.0254-6450.2020.01.020

## A sequential conditional mean model for assessing total effects of exposure in longitudinal data

Wang Xiaolei<sup>1</sup>, Tian Mengyuan<sup>1</sup>, Zhang Na<sup>1,2</sup>, Gao Hong<sup>1</sup>, Tan Hongzhan<sup>1</sup>

<sup>1</sup> Department of Epidemiology and Health Statistics, Xiangya School of Public Health, Central South University, Changsha 410078, China; <sup>2</sup> Hunan Provincial People's Hospital/the First Affiliated Hospital of Hunan Normal University, Changsha 410016, China

Corresponding author: Tan Hongzhan, Email: tanhz99@qq.com

**【Abstract】** In prospective cohort study, multi follow up is often necessary for study subjects, and the observed values are correlated with each other, usually resulting in time-dependent confounding. In this case, the data generally do not meet the application conditions of traditional multivariate regression analysis. Sequential conditional mean model (SCMM) is a new approach that can deal with time-dependent confounding. This paper mainly summarizes the basic theory, steps and characteristics of SCMM.

**【Key words】** Sequential conditional mean model; Time-dependent covariate; Propensity score; Generalized estimating equation

DOI:10.3760/cma.j.issn.0254-6450.2020.01.020

在有重复测量的纵向研究中,对暴露与结局之间的因果效应进行估计是现代流行病学研究中一个常见的问题。该类研究方法的一个显著特点是需要对研究对象进行多次随访,每个个体经过多次随访会产生多个相互关联的观测值,且每次随访时暴露和结局都可能会随时间发生变化,该类暴露被称为时依性暴露。在估计时依性暴露的效应时可能会受到时依性混杂因素的影响,该混杂因素满足的 3 个条件:①随时间变化的变量;②该变量是结局的影响因素;③该变量既影响到随后的暴露同时又会受到先前暴露的影响<sup>[1-2]</sup>。由于该类数据存在各个观测值之间相互关联,所以直接采用传统的多因素回归模型对其分析可能会忽视组内相关从而产生偏倚。

Robins 等<sup>[1]</sup> 在 1999 年提出了边缘结构模型(marginal structural models, MSM),该模型作为一种可以处理时依性混杂的方法而被广泛应用。其原理

是通过计算逆概率权重对原人群进行加权从而构造出虚拟人群,在该虚拟人群中对暴露总效应进行评估<sup>[3-4]</sup>。但是,在对原人群进行加权时,由于某些个体协变量差异过大而导致极端权重的出现,如果直接对极端权重进行截断又可能导致某些重要信息缺失,在小样本中该暴露总效应的评估可能会存在偏倚<sup>[5]</sup>。同时,在暴露和非暴露前一阶段的协变量差异很大时,MSM 估计的边际效应可能不能真实的反映暴露的总效应。

本文将介绍另一种可以处理时依性混杂的新方法——序列条件平均模型(sequential conditional mean models, SCMM)。该方法是 Keogh 等<sup>[6]</sup> 在 2017 年提出的,是在传统回归方法的基础上发展起来的,与传统回归方法相比,其主要区别是将过去的暴露、结果作为时依性混杂因素纳入模型中进行校正。并且广义估计方程(generalized estimating

equation, GEE) 的发展与完善, 为 SCMM 模型参数的估计提供前提条件。下文将介绍如何使用 SCMM 对二分类暴露与连续性结果之间的总体效应进行评估, 并对 SCMM 的原理、暴露总效应评估过程、SCMM 的适用条件及优缺点进行概述。

## 一、基本原理

在重复测量的纵向研究中, 对研究对象进行 T 次随访,  $t=1, \dots, T$ , 在  $t$  次随访上观测其暴露 ( $X_t$ )、结局 ( $Y_t$ ) 以及时依性协变量 ( $L_t$ ), 其中  $X_t$  代表  $[t-1, t]$  期间的暴露状态、 $Y_t$  代表  $(t, t+1]$  期间的结局。 $U_x$ 、 $U_y$  分别表示影响暴露和结局未观测到的不可测量的随机效应。

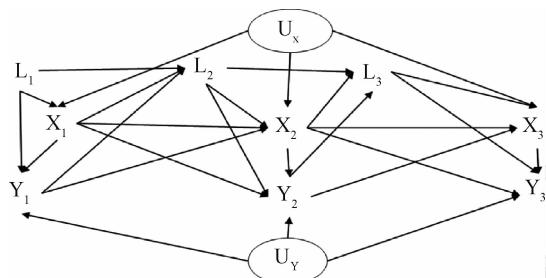


图1 因果路径图

如因果路径图所示:  $X_t$  受到前一阶段的暴露 ( $X_{t-1}$ )、前一阶段的结局 ( $Y_{t-1}$ )、时依性混杂协变量 ( $L_t$ ) 的影响, 并且每次随访时测量的  $X_t$  均会发生变化。同时  $Y_{t-1}$  也受到  $X_{t-1}$  和  $L_{t-1}$  的影响, 并对  $X_t$ 、 $Y_t$  产生影响, 即  $Y_{t-1}$  可以被看作影响  $X_t$  与  $Y_t$  之间因果关系的时依性混杂因素。暴露对结局的总效应可以分解为包含未来暴露的间接暴露效应和不包含未来暴露的直接暴露效应, 例如  $X_{t-1}$  对  $Y_t$  的暴露总效应可以分解为直接暴露途径  $X_{t-1} \rightarrow L_t \rightarrow Y_t$ 、 $X_{t-1} \rightarrow Y_t$  和间接暴露途径  $X_{t-1} \rightarrow X_t \rightarrow Y_t$ 、 $X_{t-1} \rightarrow L_t \rightarrow X_t \rightarrow Y_t$ 。

在 SCMM 中, 采用标准回归方法将  $X_{t-1}$ 、 $Y_{t-1}$  以及  $L_t$  纳入模型中, 通过模型对这些具有混杂作用的协变量进行校正, 从而对  $X_t$  与  $Y_t$  之间暴露总效应进行无偏的估计。该模型主要对二分类暴露与连续性结局之间的暴露总效应进行估计, 不能对某种特定暴露模式的联合效应进行评估<sup>[6]</sup>。

## 二、暴露总效应的估计

1.  $X_t$  对  $Y_t$  的总效应评估模型: 首先, 为  $Y_t$  拟合一个模型, 假设不存在  $U_y$ , 即  $Y_t$  仅受到  $X_t$ 、 $X_{t-1}$ 、 $L_t$  的影响, 同时  $Y_{t-1}$  对  $X_t$  的暴露效应也会产生影响<sup>[7]</sup>, 采用模型(1)可以对暴露总效应进行评估,  $\beta_{xi}$  代表  $X_t$  与  $Y_t$  之间的总体效应, 模型(1)即 SCMM。

$$E(Y_t | \bar{X}_t, \bar{L}_t, \bar{Y}_{t-1}) = \beta_0 + \beta_{x1} X_t + \beta_{x2} X_{t-1} + \beta_L^T L_t + \beta_Y Y_{t-1} \quad (1)$$

2.  $X_{t-a}$  对  $Y_t$  的总效应评估模型: 在模型(1)的基础上, 将交互项、基线协变量以及与时间有交互作用的协变量均拟合进模型中, 模型(1)可以直接拓展成模型(2), 模型(2)可用于评价  $X_{t-a}$  ( $a=1, 2, \dots$ ) 的总暴露效应。 $\beta_{xi}$  代表  $X_{t-a}$  与  $Y_t$  之间的总效应。

$$E(Y_t | \bar{X}_{t-a}, \bar{L}_{t-a}, \bar{Y}_{t-1}) = \beta_0 + \beta_{x1} X_{t-a} + \beta_{x2} X_{t-a-1} + \beta_Y Y_{t-1} + \beta_L^T L_{t-a} \quad (2)$$

3. 纳入倾向评分的模型: 倾向评分(propensity score, PS)指在一定协变量的情况下, 某个研究对象接受暴露的可能性大小, 即  $PS_t = \Pr(X_t = 1 | \bar{X}_{t-1}, \bar{L}_t, \bar{Y}_{t-1})$ 。其概括了协变量的作用, 可以有效地保证暴露组和对照组之间的均衡性(使两组的各个协变量均衡一致)<sup>[8]</sup>。PS 估计是在不存在  $U_x$  的情况下, 针对某个研究对象, 将暴露因素作为因变量, 将暴露的影响因素(协变量)作为自变量建立一个可以计算概率的模型, 计算出的概率可以看作是该研究对象接受暴露的可能性大小也称为该研究对象接受暴露的 PS<sup>[9]</sup>。本文主要探讨二分类暴露的总体效应, 所以可以通过 logistic 回归模型计算 PS。在 SCMM 模型中纳入 PS 是为了控制协变量可能导致的混杂。

如图1所示: 某研究对象在时间  $t$  上的暴露  $X_t$  的影响因素包括  $X_{t-1}$ 、 $L_t$  以及  $Y_{t-1}$ 。即建立  $X_t$  与  $X_{t-1}$ 、 $Y_{t-1}$ 、 $L_t$  的 logistic 回归模型。

$$\ln \left( \frac{\Pr}{1 - \Pr} \right) = \rho_0 + \rho_x X_{t-1} + \rho_L^T L_t + \rho_Y Y_{t-1} \quad (3)$$

$$PS_t = \Pr = \frac{\exp(\rho_0 + \rho_x X_{t-1} + \rho_L^T L_t + \rho_Y Y_{t-1})}{1 + \exp(\rho_0 + \rho_x X_{t-1} + \rho_L^T L_t + \rho_Y Y_{t-1})} \quad (4)$$

$$E(Y_t | \bar{X}_t, \bar{L}_t, \bar{Y}_{t-1}) = \beta_0 + \beta_{x1} X_t + \beta_{x2} X_{t-1} + \beta_L^T L_t + \beta_Y Y_{t-1} + \beta_P \hat{PS}_t \quad (5)$$

模型(3)、(4)是对某个研究类似的将 PS 看作是  $X_{t-1}$ 、 $L_t$ 、 $Y_{t-1}$  所产生混杂作用的综合。模型(5)是通过将 PS 作为特殊的混杂因子纳入模型(1)中进行校正所形成的 PS 模型。将 PS 纳入模型中, 对于模型的稳定程度以及估计精度都有提高, 只要模型(1)或模型(5)是正确设立的(即依据上述的原理图, 理清各变量之间的关系), 在大样本条件下, 线性模型就可以无偏且比较稳健地估计暴露效应  $\beta_{xi}$ 。此外, 对于那些很难找到同质可比的非暴露个体的暴露个体, 该方法可以降低其权重, 使其在没有较好同质性的对照人群中, 仍可以较好地估计暴露的效应<sup>[10-11]</sup>。

4. SCMM 的参数估计: SCMM 的参数估计可以看作是 GEE 的解。GEE 是在广义线性模型的基础上发展起来可以对具有组内相关性的纵向数据进行分析, 其要求不同观察对象之间的观测值相互独立,

表1 SCMM与MSM估计效应时的偏倚统计量

模型	Bias	95%CI	SD
SCMM			
$\beta_0 + \beta_{X1} X_t$	0.425	0.420 ~ 0.430	0.081
$\beta_0 + \beta_{X1} X_t + \beta_Y Y_{t-1}$	0.151	0.146 ~ 0.156	0.080
$\beta_0 + \beta_{X1} X_t + \beta_{X2} X_{t-1}$	0.115	0.109 ~ 0.120	0.092
$\beta_0 + \beta_{X1} X_t + \beta_{X2} X_{t-1} + \beta_Y Y_{t-1}$	-0.001	-0.007 ~ 0.005	0.095
纳入PS的SCMM			
$\beta_0 + \beta_{X1} X_t + \beta_{PS} \hat{PS}_t$	0.001	-0.005 ~ 0.007	0.096
$\beta_0 + \beta_{X1} X_t + \beta_Y Y_{t-1} + \beta_{PS} \hat{PS}_t$	0.001	-0.005 ~ 0.007	0.096
$\beta_0 + \beta_{X1} X_t + \beta_{X2} X_{t-1} + \beta_{PS} \hat{PS}_t$	-0.003	-0.002 ~ 0.009	0.096
$\beta_0 + \beta_{X1} X_t + \beta_{X2} X_{t-1} + \beta_Y Y_{t-1} + \beta_{PS} \hat{PS}_t$	-0.001	0.007 ~ 0.005	0.096
MSM			
不稳定权重 $w_0 + w_{X1} X_t + w_{X2} X_{t-1}$	0.007	0.012 ~ 0.026	0.306
稳定权重 $w_0 + w_{X1} X_t + w_{X2} X_{t-1}$	-0.002	-0.009 ~ 0.004	0.107

允许同一受试者多次观测值之间存在组内相关。但是, GEE 只有在不存在  $U_Y$  以及  $Y_{t-1}$  独立于  $X_t$ 、 $L_t$  的情况下才可以对参数进行无偏估计, 否则可能会产生偏倚(GEE 偏倚)。为了克服这种偏倚, SCMM 将  $Y_{t-1}$  纳入模型中进行校正来避免这种偏倚。

SCMM 的参数就是解释变量的系数  $\beta$ , 该参数的确切估计依赖于  $\emptyset$  和  $\alpha$ , 只有在给定确切的  $\emptyset$  和  $\alpha$  估计值后, 才能对  $\beta$  进行无偏估计。其中的  $\emptyset$  是离散参数, 其确切估计依赖于结局变量的分布类型, 在统计软件中体现于连接函数的正确选择;  $\alpha$  是相关系数参数, 其确切估计值依赖于作业相关矩阵的选择<sup>[12]</sup>。所以在进行统计软件分析时需要对连接函数和工作相关矩阵做出正确选择。首先, 连接函数的选择依赖于结局变量的分布类型, 例如结局变量是满足高斯分布的连续性变量, 其连接函数选择恒等函数、满足伯努利分布或者二项分布的二分类变量时选择 logit 函数、满足泊松分布的计数资料选择 log 函数。其次是需要选择正确的作业相关矩阵, 常见的几种可以解释重复测量间相关性的作业相关矩阵形式主要有可交换相关、独立相关、不确定型相关、自相关、相邻相关等<sup>[13]</sup>。其选择的方法有两种, 第一种是根据数据资料的特点, 例如对于重复测量等具有时间顺序特点的资料可以采用自相关和相邻相关、对于测量间无时间顺序关系的资料采用可交换相关、难以确定相关结构的采用不确定型相关<sup>[14]</sup>。同时, 如果在实际操作中没有确定作业相关矩阵, 软件初始默认采用独立作业相关矩阵, 其在迭代运算

中自动对矩阵进行更新。第二种方法是针对数据本身的特点, 通过准似然独立准则(Quasi-Likelihood under Independence Model Criterion, QIC)对模型进行判定<sup>[14-15]</sup>, 该准则不仅可以用于作业相关矩阵的选择, 还可以用于协变量的筛选从而对模型进行优化, 该方法可以直接在统计软件中操作, 其判断的标准是其统计量的估计值, 其值越小说明模型拟合越好。

### 三、模拟研究

Keogh 等<sup>[6]</sup>利用一个假设的“200例个体随访5次”的随机数据, 利用模型进行模拟研究。将单个模拟数据集的生成过程重复 1 000 次, 形成 1 000 个模拟数据集并分别用 SCMM、MSM 对暴露的总效应进行估计。对同一模型估计效应时所产生的 1 000 个偏倚进行统计分析, 包括偏倚的估计值(Bias)、95%CI、标准差(s), 应用这些统计指标对不同模型进行比较。

模拟结果提示, 在完全没有考虑时依性混杂因素(如  $X_{t-1}$ 、 $Y_{t-1}$ )时(SCMM 模型 1), 其偏倚达到 0.425, 随着将时依性混杂因素加入调整模型中(SCMM 模型 2 加入了  $X_{t-1}$ , SCMM 模型 3 加入了  $Y_{t-1}$ ), 其偏倚逐渐减少, 当全部时依性混杂因素都加入调整模型中时(SCMM 模型 4), 其效应估计是无偏的, 且标准差降至 0.095。在纳入 PS 的 SCMM 中, 所有模型的估计均是无偏估计, 即纳入 PS 可以提升 SCMM 模型控制偏倚的效果。虽然 MSM 在权重稳定时也可以对暴露效应进行无偏估计, 但其标准差大于 SCMM, 即在估计效应的稳定性方面不如 SCMM; 而在权重不稳定时, MSM 模型还是不能完全控制偏倚。

### 四、小结

对于具有组内相关性的纵向数据, 采用传统的多因素回归方法分析这类数据时由于无法解决时依性混杂因素而产生偏倚。SCMM 是分析这类数据的一种新方法, 该方法是在传统回归的基础上将时依性混杂因素纳入模型中进行校正从而对纵向数据中暴露与结局的效应进行无偏估计。与 MSM 相比, SCMM 具有简单、灵活等优势, 例如在拟合 MSM 时, 需要先构造虚拟人群并且由于可能存在差异较大的协变量, 在构造逆概率权重时可能需要注意极端权重的出现, 所以 MSM 的拟合相对于 SCMM 更加复杂。同时在交互作用处理方面, MSM 只能将基线协变量与暴露之间的交互作用通过逆概率权重的计算过程进行校正, 而 SCMM 可以直接将暴露与时

依性协变量之间的交互项纳入模型中进行校正,所以SCMM在处理交互项作用方面比MSM更加灵活。SCMM将PS纳入模型中,使得模型具有稳健性,并且SCMM还可以更容易地扩展以适应连续的暴露和删失数据<sup>[6]</sup>。SCMM也存在一些局限性,如SCMM只能估计当前单个暴露对后续结局的总效应,不能估计特定的联合暴露效应。

**利益冲突** 所有作者均声明不存在利益冲突

## 参 考 文 献

- [1] Robins JM, Hernán MA, Brumback B. Marginal structural models and causal inference in epidemiology [J]. *Epidemiology*, 2000, 11 (5) : 550–560. DOI: 10.1097/00001648-200009000-00011.
- [2] Arah OA, Sudan M, Olsen J, et al. Marginal structural models, doubly robust estimation, and bias analysis in perinatal and pediatric epidemiology [J]. *Paediatr Perinat Epidemiol*, 2013, 27 (3): 263–265. DOI: 10.1111/ppe.12049.
- [3] Zheng WJ, Luo ZH, van der Laan MJ. Marginal structural models with counterfactual effect modifiers [J]. *Int J Biostat*, 2018, 14(1). DOI: 10.1515/ijb-2018-0039.
- [4] 田丹平, 张敏. 边际结构模型基本原理及其应用实例介绍 [J]. 中国卫生统计, 2014, 31(4): 725–728.  
Tian DP, Zhang M. The basic principle and application examples of marginal structure model are introduced [J]. *Chin J Health Stat*, 2014, 31(4): 725–728.
- [5] Cole SR, Hernan MA. Constructing inverse probability weights for marginal structural models [J]. *Am J Epidemiol*, 2008, 168 (6): 656–664. DOI: 10.1093/aje/kwn164.
- [6] Keogh RH, Daniel RM, van der Weele TJ, et al. Analysis of longitudinal studies with repeated outcome measures: adjusting for time-dependent confounding using conventional methods [J]. *Am J Epidemiol*, 2018, 187 (5) : 1085–1092. DOI: 10.1093/aje/kwx311.
- [7] Newsome SJ, Keogh RH, Daniel RM. Estimating long-term treatment effects in observational data: A comparison of the performance of different methods under real-world uncertainty [J]. *Stat Med*, 2018, 37 (15) : 2367–2390. DOI: 10.1002/sim.7664.
- [8] Deb S, Austin PC, Tu JV, et al. A review of propensity-score methods and their use in cardiovascular research [J]. *Can J Cardiol*, 2016, 32(2): 259–265. DOI: 10.1016/j.cjca.2015.05.015.
- [9] Lee J, Little TD. A practical guide to propensity score analysis for applied clinical research [J]. *Behav Res Ther*, 2017, 98: 76–90. DOI: 10.1016/j.brat.2017.01.005.
- [10] Vansteelandt S, Daniel RM. On regression adjustment for the propensity score [J]. *Stat Med*, 2014, 33 (23) : 4053–4072. DOI: 10.1002/sim.6207.
- [11] Elze MC, Gregson J, Baber U, et al. Comparison of propensity score methods and covariate adjustment: evaluation in 4 cardiovascular studies [J]. *J Am Coll Cardiol*, 2017, 69 (3) : 345–357. DOI: 10.1016/j.jacc.2016.10.060.
- [12] Wang YG, Fu LY. Selection of working correlation structure in generalized estimating equations [J]. *Stat Med*, 2017, 36 (14) : 2206–2219. DOI: 10.1002/sim.7262.
- [13] Liang KY, Zeger SL. Longitudinal data analysis using generalized linear models [J]. *Biometrika*, 1986, 73 (1) : 13–22. DOI: 10.1093/biomet/73.1.13.
- [14] 朱玉, 王静, 何倩. 广义估计方程在SPSS统计软件中的实现 [J]. 中国卫生统计, 2011, 28(2): 199–201.  
Zhu Y, Wang J, He Q. Implementation of generalized estimation equation in SPSS statistical software [J]. *Chin J Health Stat*, 2011, 28(2): 199–201.
- [15] 冯丽云, 崔菊. 纵向数据准似然独立准则在GEE模型中的应用 [J]. 中国卫生统计, 2008, 25(4): 369–372.  
Feng LY, Cui J. Application of quasi-likelihood independence criterion in GEE analyses of longitudinal data [J]. *Chin J Health Stat*, 2008, 25(4): 369–372.

(收稿日期:2019-06-19)

(本文编辑:王岚)

## 中华流行病学杂志第八届编辑委员会通讯编委组成人员名单

(按姓氏汉语拼音排序)

鲍倡俊	陈 曦	陈 勇	冯录召	高 培	高立冬	高文静	郭 巍	胡晓斌
黄 涛	贾存显	贾曼红	姜 海	金连梅	靳光付	荆春霞	寇长贵	李 曼
李 霓	李 希	李杏莉	林 玖	林华亮	刘 昆	刘 莉	刘 森	马 超
毛宇嵘	潘 安	彭志行	秦 天	石菊芳	孙 凤	汤奋扬	汤后林	唐雪峰
王 波	王 娜	王 鑫	王海俊	王丽萍	席 波	谢 娟	闫笑梅	严卫丽
燕 虹	杨 鹏	杨祖耀	姚应水	余灿清	喻荣彬	张 本	张茂俊	张周斌
郑 莹	郑英杰	周 蕾	朱益民					