



北京大学

# 硕士研究生学位论文

题目： **基于图模型的因果推断**

——北京 PM2.5 浓度的影响因素实证分析

姓名： 袁见

学号： 1701214139

院系： 国家发展研究院

专业： 西方经济学

研究方向：

导师姓名： 胡大源 教授

二〇二〇年四月

## 版权声明

任何收存和保管本论文各种版本的单位和个人，未经本论文作者同意，不得将本论文转借他人，亦不得随意复制、抄录、拍照或以任何方式传播。否则，引起有碍作者著作权之问题，将可能承担法律责任。

## 摘要

无论在哪个领域，因果推断都是最重要的话题之一。因果模型有多种表现形式，在这些形式中，因果图以清晰易懂的特点突出，并且可以为许多问题提供简单明确的答案。本文在图模型的基础上，对因果推断理论进行综述讨论，提供了一整套因果识别的基本流程，并强调因果关系的推断不应由数据出发，而应该建立在学科知识的基础上，用数据来修改、检验假设。此外，本文将图模型对因果关系的识别方法与经济学中传统计量方法结合，将图模型中的条件独立性以及后门准则、前门准则等应用于评价控制变量的选择，并探讨在什么样的条件下，我们熟知的线性方程模型能识别因果并提供因果解释，为经济学实证中的模型和结果提供了因果关系的支撑。

本文将图模型用于北京 PM2.5 浓度影响的研究中，通过对变量关系的研究来构建相应的图模型，并以此设立相应的回归模型。同时本文回顾了动态因果模型，并借此分析不同滞后期风速对 PM2.5 浓度的影响。最后，本文将北京 2017 年底在城区和南部平原大规模整治燃煤、基本实现“无煤化”视为对模型的干预，即 Judea Pearl 强调的“do 因子”，借此评估北京内部污染排放对 PM2.5 浓度的因果效用，本文认为，北京自身污染排放对 PM2.5 浓度有很大的影响，2015-2018 年 PM2.5 的积聚过程变化也验证了这一点。

关键词：因果推断，图模型，后门准则，条件概率，PM2.5

## Research on Causal Inference Based On Graphic Model

——Empirical analysis of the influencing factors of Beijing's PM2.5

Yuan Jian

Directed by Dayuan Hu

### ABSTRACT

No matter in which subject, causal inference is one of the most important topics. There are many forms to express causal models. In these forms, causal diagrams are prominent because it provides a clearer and easier way to understand causal connections between different variables, and provides simpler answers to many questions. This paper reviews and discusses the theory of causal inference on the basis of the graphical model, provides a set of basic processes for causal identification, and emphasizes that the inference of causal relationships should be based on subject knowledge rather than data to modify and test hypotheses.

In addition, this paper combines the graph model and the traditional econometric method in economics, and applies conditional independence, the back-door criterion and the front-door criterion to evaluate the selection of control variables. This paper also discusses our well-known linear equation model can identify causality and provide causal explanation under what conditions. our well-known linear equation model can identify causality and provide causal explanation.

This paper applies the graph model to the research of the influencing factors of PM2.5 in Beijing. Firstly, the paper construct the relative graph model based on the prior study of the relationship between PM2.5 and other environment variables, and establish the corresponding regression model. Then, this paper reviews the dynamic causality model and analyzes the effect of wind speed at different lag periods on PM2.5. Finally, in order to evaluate the causal effect of Beijing's internal pollution emission on PM2.5, this article makes full use of the Beijing Daxing's fire incident in 2017, and regards the event as an intervention or a do-calculus created by Prof. Judea Pearl. The result shows that Beijing's own pollution emissions have a great impact on the PM2.5, and that the change in the accumulation process of PM2.5 from 2015 to 2018 also verifies this.

KEY WORDS: Causal Inference, Graph Model, Backdoor Criterion, Conditional Probability, PM2.5

# 目录

摘要 .....	I
ABSTRACT .....	II
第一章 引言 .....	1
1.1 研究背景和文献概述 .....	1
1.2 因果模型与随机试验 .....	2
1.2.1 因果的含义与因果模型 .....	2
1.2.2 因果与随机实验 .....	2
1.2.3 潜在结果与因果模型 .....	3
第二章 理论研究 .....	5
2.1 随机实验与回归 .....	5
2.1.1 随机实验的回归表达 .....	5
2.1.2 计量经济学框架下回归中的因果 .....	5
2.2 图模型总览 .....	6
2.2.1 结构因果模型的表示 .....	6
2.2.2 图模型的表示 .....	6
2.2.3 贝叶斯网络 .....	6
2.2.4 混杂因子与 do 因子 .....	7
2.2.5 贝叶斯网络与因果的关系 .....	8
2.2.6 基于图模型分析线性回归中的偏差 .....	9
2.2.7 基于图模型分析控制变量选择 .....	10
2.3 图模型的因果推断准则 .....	12
2.3.1 图模型的基本结构 .....	12
2.3.2 d 分离 .....	12
2.3.3 后门准则 .....	13
2.3.4 前门准则 .....	14
2.4 工具变量以及工具变量集 .....	15
2.5 时间序列与动态因果效应 .....	16
第三章 图模型的应用 .....	17
3.1 PM2.5 浓度与主要解释变量之间的因果关系 .....	17
3.1.1 北京 PM2.5 浓度主要影响因素 .....	18
3.1.2 北京空气污染物排放主要来源 .....	19

3.1.3	空气污染物扩散条件对 PM2.5 的影响 .....	22
3.1.4	PM2.5 影响因素模型设立 .....	23
3.2	数据及样本介绍 .....	23
3.3	PM2.5 浓度影响因素分析 .....	23
3.3.1	模型设定 .....	23
3.3.2	结果比较 .....	24
3.3.3	风速动态因果效应 .....	28
3.3.4	2015-2018 年 PM2.5 浓度影响因素结果 .....	30
第四章 结论与讨论 .....		35
参考文献 .....		37
致谢 .....		40
北京大学学位论文原创性声明和使用授权说明 .....		41





# 第一章 引言

## 1.1 研究背景和文献概述

根据观察记录和抽样调查数据通过统计和计量经济模型分析变量间的联系，进而探寻社会现象背后的规律是社会科学研究的常用方法。在统计推断的学习过程中，我们经常听到的一句忠告：“关联并不意味着因果”。然而，在许多社会科学实证研究中，关联关系与因果关系的区别常常难以分清。经典统计和计量经济学教科书中关于多变量线性回归模型的参数估计值的常规解释为：当其它变量保持不变，度量该解释变量变化一单位，平均而言被解释变量的变化程度。

应用计量经济模型研究中的一个关键问题就是：如何判断哪些回归模型可以用于推断因果关系？哪些不能？学者对“计量经济学是否是科学”有过频繁的争论（Hendry, 1980; Sims, 1980）。Leamer（1983）更是尖锐地指出，计量经济学通过在上千个统计模型或者说多元回归模型中寻找符合预期的估计结果在论文中进行报告，这让经济学陷入了“可信性”危机，而“可信性”危机的根源就是对因果关系的解释。

近年来，基于神经网络的深度学习在文本识别、图像识别以及图像识别等领域的卓越表现将人工智能的浪潮推向了新的高峰。深度学习、机器学习利用算法自动地调整训练模型参数让模型具有高精度度的结果，而计算的中间过程是模糊、难以报告的，同样也面临可解释性差的问题。2017年 Pearl 教授在 NIPS 会议中公开讨论了机器学习的理论局限性，他认为当前的机器学习几乎完全是统计学或黑箱的形式，这样的系统不能推断干预和反思，强人工智能的基础一定是现实模型的引导。同时他还提出因果推断具有三个层级，分别是关联、干预和反事实，无论是干预还是反事实都涉及到数据外的世界，而深度学习强调曲线拟合，曲线拟合的目标是最大化拟合以及最小化过拟合，在这样为目标的策略中，依然在优化及观察数据的一些属性，无论怎么变化始终牢牢地被限制在因果关系阶梯的第一阶段。同年，Ali Rahimi 和 Yann Lecun 关于“AI 是不是炼金术”的论战被广泛关注，机器学习能否突破“黑箱”的关键也恰恰在于对因果推断，因果推断是唯一一种能从根本上解决问题的方法。

自上世纪末以来，统计和数据科学家在图模型基础上研究因果推断的成果或许可以帮助我们改进应用计量经济模型的设定和变量选择，特别是当我们的研究范围扩展到那些缺乏成熟理论的跨学科领域，以及随计算机和网络技术的迅速发展而出现的新问题。

图模型用紧凑直观的形式将因果假设进行编码，具有透明、可试性的特点：透明性让我们得以从科学的角度了解假设是否可信，是否需要添加新的假设，可试性使我们可以通过数据来验证假设，不相容时分辨不合理和需要修改的假设。因果对经济学领域的

重要性不言而喻，而在经济学领域中，很少有人使用图模型来描述假设，Pearl 在 NIPS 会议中表示，从数学上讲，经济问题与流行病学家或者其他科学家面临的问题并无不同，对后者来说，图模型早已成为第二语言，而这也让规避掉图的经济学家很难判断假设的合理性。因此，图模型是否能给经济学中的因果识别提供新的启发？如何将图模型应用于经济学的研究中是值得关注的问题。

## 1.2 因果模型与随机试验

### 1.2.1 因果的含义与因果模型

1748 年，苏格兰著名哲学家大卫·休谟提出：

*“我们可以给一个原因下定义说，它是先行于、接近于另一个对象的一个对象，而且在这里，凡与前一个对象类似的一切对象都和后一个对象类似的那些对象在类似的先行关系和接近关系中。或者，换言之，假如没有前一个对象，那么后一个对象就不可能存在。——大卫·休谟”*

休谟对因果的定义虽然听起来有点晦涩和别扭，Pearl (2019) 认为休谟的定义包含了因果讨论中的两个重要定义和维度：规则性定义和反事实定义。规则性定义强调因后面跟着果，强调因果之间联系的必然性和时序性，结果的时间不可能发生在原因的前面；而反事实定义则强调“潜在结果”，关注在一个如果的世界，如果前者没有发生，那么后者会怎样。本质上，根据休谟的定义，因果的定义主要有两点，第一是原因在前，结果在后，第二点是，如果原因不发生，结果也不会发生。

虽然在不同领域对因果有不同的看法，但规则性定义和反事实定义永远贯穿其中。在众多学科中，特别对结果看重的法学和医学是最为重视因果的学科。在大陆法系刑法因果理论中，“条件说”既是起源也是之后所有相关理论的基石，“条件说”以“如无前者，既无后者”（but for test）为反证规则，揭示了人类思维在因果认识中的基本规则形式（朱德才，2005）。“条件说”的本质反映了因果的反事实定义。在医学中，对因果的探讨贯穿于诊断和治疗，在诊断中，病因是因，生病是果，在治疗中，去医院或者用药是因，病人康复是果，这些体现了因果的规则性，同时医学同样关注去医院的人如果不去医院会发生什么，吃药的人如果不吃药会发生什么，这体现了因果的反事实定义。

### 1.2.2 因果与随机实验

休谟认为我们无法用已经观察到的经验证明必然，而应该用经常性连接取代无法验证的必然联系。在这一哲学思想的指导下，学者将注意力放在从大量实验或观察数据中发现特定事物之间的因果关系，让因果关系进入“可计算”范畴。

物理学中，研究者认为理想的控制实验能够反映因果关系，例如，将除了  $x$  之外的因素全部控制不变，单独让  $x$  变化，然后观察  $y$  变化的情况，该实验下的结果就能反应  $x$  与  $y$  之间的因果关系。

在医学中， $x$  对应的可能是一种新型的药物或者治疗方案， $y$  是该药物的疗效或者病人的康复状况。为了理解二者的因果关系，研究者可以通过控制实验比较个体在不同状态下的结果差别。由于参加实验者的体制与生活方式等具有差异，不可能完全控制所有  $x$  外的其他因素，达到理想控制实验的条件。Fischer (1935) 提出使用随机实验的方法，将人群随机分配到两组，其中实验组进行药物实验，控制组服用“安慰药”，这种方法被称为“双盲实验”也被称为 A/B test，随机分组能有效地排除  $x$  外其他因素的干扰，从而得到  $x$  对  $y$  的因果效应。

然而，在经济学和其他社会科学领域，随机试验往往难以实现，那么如何在没有严格随机的条件下来理解因果是经济学中很重要的问题。

### 1.2.3 潜在结果与因果模型

长期以来，反事实定义的现实应用推动了关于因果效应的统计检验研究。统计学和经济学最初的因果效应研究可以上溯到 20 世纪 70 年代。鉴于有关因果推断研究的文献极为丰富，本文仅通过统计学家 Donald Rubin 和经济学家 James Heckman 的代表性研究成果简要介绍因果模型的发展路径。

著名的 Rubin 因果模型就是通过随机实验，在反事实“潜在结果”(potential outcome) 的研究基础上建立起来的 (Rubin, 1974; Rubin, 1978; Rubin, 1986; Rubin, 1990)，Rubin 通过随机化实验估计平均因果效应，奠定了用统计模型进行因果推断的理论基础。Rubin 认为，应该“按照倾向得分将人群进行匹配，形成一个近似的随机化试验”的设计。他特别看重“设计过程不依赖于结果变量”，认为“否则，将会出现如下的怪现象：社会科学的研究者不断地尝试加入或者剔除某些回归变量，直到回归的结果符合自己的‘故事’为止。这种现象在社会科学中实在太普遍了！”<sup>1</sup>

几乎是在同一时期，经济学家也开始通过建立计量经济模型对潜在结果开展研究 (Heckman, 1974; Heckman, 1978; Heckman, 1979; Heckman, 1989; Heckman, 2000)。

本世纪以来，有关因果推断的研究在社会学和公共医学，特别是流行病学研究领域备受关注 (Morgan and Winship, 2015; Hernan and Robins, 2020)，学术研究成果斐然。Rubin (2004) 曾作为特邀嘉宾在演讲中感慨，“统计学只能告诉我们关联，而关联并非因果的时代一去不复返了”。Heckman (2008, 2011) 结合公共政策评价对计量经济结构模型与 Rubin 因果模型进行对照比较研究，并结合因果推断，在数据基础上根据经济学

<sup>1</sup> 丁鹏, 2012. “因果推断简介之四”, 统计之都 (cosx.org)

原理来定义经济政策评价中的问题，用统计学方法探索解决办法。他对样本选择性偏差的研究成果颇丰，推动了微观计量经济学的持续发展。

与上世纪不同，本世纪出版的计量经济学教科书中开始大张旗鼓地讲授因果与非因果模型（Cameron and Trivedi 2005），讨论回归与因果关系（Angrist and Pischke 2009），介绍实验与准实验，估计动态因果效应（斯托克，沃森，2012）。

## 第二章 理论研究

### 2.1 随机实验与回归

#### 2.1.1 随机实验的回归表达

随机控制实验是发现因果关系的传统途径 (Pearl, 2009)。在测量药物对治疗效果的因果作用时,通过随机试验将病人分为两组,采取药物与否构成了最直观的干预变量  $D$ , 1 代表干预, 0 代表不干预。对于每一个个体  $i$ , 我们可以将干预的因果效应写为  $\tau_i = Y_{1i} - Y_{0i}$ , 对  $\tau$  的讨论是基于潜在结果的比较, 因为同一个个体  $i$  在同一时间只能有一种状态, 在评价干预的效果时, 我们只能对比现在的我吃药和现在的我不吃药之间的状态差异, 而估测潜在结果的差异无法靠单个个体来实现, 必须借助更大样本的观察。

面对多个样本的数据, 我们本能地想通过最基本的 OLS 模型  $Y_i = \alpha + \tau D_i + \varepsilon_i$  来估算, 但我们实际估算的系数是干预组与控制组样本均值的差别  $E[Y_i | D_i = 1] - E[Y_i | D_i = 0]$ , 而我们关心的是总体平均因果效应  $E[Y_{1i} - Y_{0i}]$ , 大多数情况下这二者是不相等的, 只有当  $E[Y_{0i} | D_i = 1] = E[Y_{0i} | D_i = 0]$  和  $E[Y_{1i} | D_i = 1] = E[Y_{1i} | D_i = 0]$  这两个条件同时满足时, 回归估算出的结果才是因果效应, 这两个条件本质上要求干预组和控制组是同质的, 也就是他们本身没有差异, 如果这两个条件只能满足一条, 我们通过回归只能得到干预组或者控制组的因果效应<sup>2</sup>。在这个例子中, 随机实验保证了感兴趣的变量与潜在的结果无关, 从而使被比较的组别之间是真正可比的, 也为回归的结果赋予了因果解释。

#### 2.1.2 计量经济学框架下回归中的因果

正如前面所说, 随机试验中的随机分配让我们可以对得到的估计量赋予一个因果解释。但由于实验技术的局限性, 绝大部分场合只能进行被动式观察, 而无法进行主动式干预 (Cooper G and Yoo C. 1999), 所以从观察数据进行因果推断具有重要的应用价值 (Muchnik L, et al. 2013; Aral S, Walker D. 2011)。经济学的大多数研究中, 回归模型使用的是观察到的数据, 而非随机实验产生的数据, 在没有随机分配可以利用时, 如何为回归估计量赋予一个因果解释是亟需解决的问题。

在将因变量从二值变量推广到更一般状态且模型中具有其他控制变量的情况下, 经济学用条件独立假设 (conditional independence assumption, CIA) 来为回归赋予因果解释, 通过控制一系列可观察变量来消除选择偏误 (Goldberger, 1972; Barnow, Cain and Goldberger, 1981)。条件独立假设 (CIA) 指的是给定观察到的特点, 选择性偏误消失。回归提供了一个简单易用的经验研究策略, 通过控制特定变量, 自动地将条件独立假设

<sup>2</sup> 具体可见赵西亮,《基本有用的计量经济学》

转化为感兴趣的因果效应。然而，不是所有的变量都是合格的控制变量，某些变量的加入固然可以改变回归系数，但实际上却不该将其加入。本质上，控制变量是为了通过使用观察数据来模拟随机实验下的变量变化。如何选择合格、合适的控制变量是为回归赋予因果解释的核心问题。

## 2.2 图模型总览

### 2.2.1 结构因果模型的表示

结构因果模型 (SCM) 可以通过元组  $\langle V, U, F, P(u) \rangle$  来表达，其中  $V = \{V_1, \dots, V_n\}$  代表可观测的变量， $U = \{U_1, \dots, U_m\}$  代表不可观测的变量，或者称为变量的误差项， $F = \{f_1, \dots, f_n\}$  是一系列代表变量的生成机制的方程，例如： $y = \alpha + \beta x + u_y$ ， $P(u)$  代表误差项的概率分布， $P(u)$  和  $F$  共同决定了可观察变量的生成机制以及相应的概率分布。

### 2.2.2 图模型的表示

以图模型表示的结构因果模型被称为因果图。图模型可以表示为  $\mathcal{G} = (V, E)$ ，其中  $V$  代表变量 (node)、 $E$  代表路径 (path)，根据路径种类的不同，可以将图模型分为有向图 (directed graph) 和无向图 (undirected graph)，有向图中的路径用箭头来表示，箭头代表着对变量间因果关系的假设，无向图通过直线或虚线来连接，只描述变量间的相关性而不对因果关系做任何假设。在有向图中，根据变量之间的关系，进一步可分为有环图和无环图，无环图表示不存在一条路径，使得变量自己导致自己，有环图则相反。本文后续内容将关注有向无环图 DAG (directed acyclic graphs)。

在一个 DAG 中，箭头代表了变量之间的直接因果关系，变量之间没有箭头代表我们假定两个变量之间没有直接因果关系，这二者是我们对变量之间关系最强的假设。DAG 是一个无参数模型，我们不对变量的分布做任何假设 (例如：正态分布或者泊松分布)，不对变量之间的因果关系的形式做任何假设 (例如：线性，非线性)，也不对变量之间影响的大小做任何假设。如果一个变量直接被另一个变量用箭头指向，我们分别将他们称之为彼此的“子”变量  $ch(\cdot)$  和“父亲”变量  $pa(\cdot)$ ，如果一个变量直接或者间接地被其他变量影响，我们分别将这些变量称之为彼此的“后代”  $de(\cdot)$  和“前代”  $an(\cdot)$ ，可以看出一个变量的“父亲”变量是它“前代”变量的子集。

### 2.2.3 贝叶斯网络

贝叶斯网络的 DAG 中的节点表示随机变量，连接节点的箭头代表这两个随机变量是非条件独立的，贝叶斯网络是一种概率图模型，采用 DAG 和条件概率分布来表示一

组变量的联合概率密度分布，即  $p(\mathbf{x}) = \prod_k p(x_k | \mathbf{x}_{pa(k)})$ 。贝叶斯网络通过一个 DAG 来表示变量间的条件独立关系，从而极大地降低联合概率表示的复杂性。




图 2.2: 贝叶斯网络

图 2.2 是一个有向无环图，根据链式法则（Chain Rule）可以将联合分布简化为：

$$\begin{aligned} &P(X_1, X_2, X_3, X_4, X_5, X_6, X_i, X_j) \\ &= P(X_1)P(X_2)P(X_3 | X_1)P(X_5 | X_2)P(X_6 | X_i) \\ &\cdot P(X_4 | X_1, X_2)P(X_i | X_3, X_4)P(X_j | X_4, X_5, X_6) \end{aligned}$$

### 2.2.4 混杂因子与 do 因子

前文提到，随机实验是发现因果关系最重要的方法之一，随机实验也是干预最重要的手段。Rubin (1974) 认为在因果推断中，没有干预就没有因果。Pearl (2009) 开发了一种新的符号体系来表达干预，称为 do 因子 (do-calculus)，do 因子可以被用于预测策略干预的效应 (Pearl, 1995; Tian and Pearl, 2002)。

在图模型中，do 因子可以用很简单的方式进行表达，在考虑变量 x 对变量 y 的因果效应时，只需要将所有指向 x 的箭头移去，就能得到干预后的图模型。




图 2.3: 干预前的图模型




图 2.4: 干预后的图模型

如图 2.3 所示, 在这个简单的模型中, 变量  $X$  对变量  $Y$  的影响除了直接影响外, 还会通过变量  $Z$  进行间接地影响, 如图 2.4 所示, 通过对变量  $X$  进行干预, 能够有效地消除变量  $Z$  带来的影响, 在干预后的模型中, 可以直接通过回归得到变量  $X$  对变量  $Y$  的因果效应。

在经济学的框架下, 变量  $Z$  是分析变量  $X$  对变量  $Y$  因果效用的遗漏变量, 在图模型中, 变量  $Z$  被称之为混杂因子, 控制  $Z$  也就等同于消除了混杂因子对结果的影响。与经济学寻找合适的控制变量类似, 在图模型中, 最重要的就是根据模型寻找混杂因子并通过干预的方式消除其影响。

在只有两个变量  $X$  和  $Y$  的情况下, 问题被简化为, 它们符合  $X \rightarrow Y$  还是  $X \leftarrow Y$  时:

$$P(Y = y | X = x) = P(Y = y | do(X) = x)$$

在如同上例中, 模型中含有更多变量的情况下, 问题变为在什么样的条件下, 能消除计算过程中的 do 概率, 从而能用观察数据得到干预或者反事实的结果。

正如 Cartwright (1989) 提到的, 根据数据和对因果的假设可以得到变量间的因果关系, Pearl (2016) 认为因果模型暗示了数据的生成机制, 无论是干预效果预测还是反事实推断, 最终都要回到观察数据中, 通过一系列算法或者实证策略来推断数据的生成机制, 从而推断变量间的因果关系。

## 2.2.5 贝叶斯网络与因果的关系

因果图可以帮助我们写出变量间唯一的联合分布, 但反过来是不成立的。根据从图中观察到的条件独立性, 可以将变量的条件独立关系写成:  $X_k \perp \mathbf{X}_{nd(k) \setminus pa(k)} | \mathbf{X}_{pa(k)}$ 。这种变量间的条件独立关系可能会得到完全不同的因果关系, 这也正是我们需要警惕的地方。从因果关系假设出发到用数据验证猜想和从数据出发推断因果有本质的不同, 前面说过通过选择合适的控制变量我们可以模拟 do 算子的影响, 例如我们能找到一个这样的控制变量  $Z$ , 可以识别变量  $X$  对变量  $Y$  的影响, 但同样的结果可能对应不同的因果解释, 在结构  $X \rightarrow Y$  和  $X \leftarrow Z \rightarrow Y$  中, 条件于变量  $Z$  可以识别变量  $X$  对变量  $Y$  的因果效用。在另一个结构  $Z \leftarrow X \rightarrow Y$  中, 变量之间的条件独立关系和前面的结构一样, 同时控制变量  $Z$  也不会造成结果的偏差, 但这两个模型完全代表了两个不同的因果解释, 所以仅仅从数据出发会造成很困惑。我们必须从学科本身的知识出发, 建立合理的符合逻辑的假设, 最后用数据来验证假设, 盲目地增加控制变量很容易导致结果的偏差或者因果的混乱。至此, 因果推断问题可以简化为找到合适的控制变量  $Z$  使得:

$$Y(x | Z = z) = f(\{pa_Y \setminus X\}(do(X) = x), X = x, \varepsilon_Y | Z = z)$$

相比传统计量经济学的表达, 因果图的一个主要优势就是让假设变得透明, 以供专家和决策者探讨和辩论。



## 2.2.6 基于图模型分析线性回归中的偏差

首先考虑以下两个模型：




图 2.5: 线性回归的图模型

在具体考虑变量间的关系前，无论我们对变量  $Z$  做什么假设，根据定义：

$$\beta_{yx \cdot z} = \frac{\partial}{\partial x} E(Y | X = x, Z = z) = \frac{\sigma_y}{\sigma_x} \frac{\rho_{yx} - \rho_{yz} \cdot \rho_{zx}}{1 - \rho_{xz}^2}$$

该系数代表只考虑  $Z = z$  时， $Y$  对  $X$  回归拟合线的斜率。当我们考虑图中的描述的关系时，可以发现 2.3 (a) 图包含了所有的基本结构： $X \leftarrow Z \rightarrow Y$ ， $X \rightarrow Y$ ， $Z \rightarrow Y \leftarrow X$ 。 $U_X, U_Y, Y_Z$  代表每个变量的误差项，根据假设的不同，误差项之间的关系也不用，在图 2.3 (a) 中所有误差项相互独立，而在图 2.3 (b) 中，变量的误差项之间存在相关性。为了简化模型，我们将所有的方差标准化，也就是  $\sigma_{xy} = \rho_{xy} = \beta_{xy}$ ，代入上式可以得到：

$$\beta_{yx \cdot z} = \frac{(\sigma_{yx} - \sigma_{yz} \sigma_{zx})}{(1 - \sigma_{xz}^2)}$$

同时由假设可以得到， $\sigma_{yx} = \alpha + \beta\gamma$ ， $\sigma_{xz} = \gamma$ ， $\sigma_{yz} = \beta + \alpha\gamma$ 。将所有的条件代入，可以计算得到：

$$\beta_{yx \cdot z} = [(\alpha + \beta\gamma) - (\beta + \alpha\gamma)\gamma] / (1 - \gamma^2) = \alpha$$

这样我们得到在变量  $X$  和  $Y$  之间没有无法观测的混杂因子的情况下，我们可以直接在回归中加入控制变量  $Z$  来得到  $X$  和  $Y$  之间的因果作用，再回到 Simpson 悖论，可以发现如果控制人群变量，我们可以得到正确的估计。在图 2.3 (b) 中，由于除了可观测的混杂因子  $Z$  之外，变量  $X$  和  $Y$  之间还有无法观测的混杂因子，它们造成的影响由变量  $X$  和  $Y$  误差项之间的相关性来刻画，此时  $\sigma_{xy} = \alpha + \beta\gamma + C_{XY}$ ，代入后可以得到：

$$\beta_{yx \cdot z} = \alpha + C_{XY}$$

这个估计显然是有偏的，我们无法从我们的假设中识别变量  $X$  和  $Y$  的因果关系。除了无法观测到的混杂因子造成的偏差，结果的偏差还有很多其他的可能性，例如控制结果变量造成的样本选择偏差（selection bias），无论偏差来自哪里，通过构建相应的图模型，我们都可以用同样的代数方法来分析这个偏差，这里不再一一展开，下面将用更为一般的方法，基于图模型来分析。

## 2.2.7 基于图模型分析控制变量选择

### 2.2.7.1 相关性与控制变量选择

在以相关性为基础的控制变量选择问题上，通常遵循以下两个原则：（1）与解释变量相关并且发生在解释变量之前；（2）与被解释变量相关。事实上，基于相关性的控制变量选择可能反而会带来偏差。




图 2.6: 控制变量的选择

在图 2.6 (a) 和 (b) 中，变量  $Z$  都符合以上两个条件：变量  $Z$  发生在  $X$  之前并与  $X$  相关，同时在无法观察的变量  $U$  的作用下，变量  $Z$  与  $Y$  也是相关的。在图 2.6 (a) 中，变量  $Z$  处于唯一一条变量  $X$  和变量  $Y$  之间的非因果路径上，所以变量  $Z$  必须加以控制，基于相关性的控制变量选择在这个模型中是适用的。在图 2.6 (b) 中，变量  $X$  和变量  $Y$  之间没有其他的非因果路径，而控制变量  $Z$  后，反而会增加一条非因果路径，导致选择性偏差或者内生性。

从实证的角度很难从数据出发区分图 2.6 (a) 和 (b) 中的两个模型，因为在这两个模型的假设下，变量的相关性、条件相关性、独立性、条件独立性都是一样的，这也恰恰说明，正确地选择控制变量需要对数据背后的因果结构有清晰的了解，仅靠观察到的相关性不足以进行因果推断，图模型能以简介清晰的方式表达数据背后的因果结构，并对控制变量的正确选择提供便利。

### 2.2.7.2 控制变量与直接影响、间接影响

最早由 Baron, Kenny (1986) 提出的中间变量分析（mediation analysis）被广泛地用于计算直接影响和间接影响。在理论上，由该方法导致的内生选择性偏差已被大量地

证明 (Rosenbaum, 1984; Holland, 1988; Robins, 1989; Smith, 1990; Wooldridge, 2005, 2006; Sobel, 2008), 在实证研究中, 由此导致的偏差却仍然存在。在传统的间接影响识别策略中, 为了检测变量  $X$  对变量  $Y$  是否存在间接影响, 通常是比较变量  $X$  对变量  $Y$  的总影响以及变量  $X$  对变量  $Y$  的直接影响, 其中总影响一般通过变量  $Y$  对变量  $X$  的直接回归得到, 直接影响通过变量  $Y$  对变量  $X$  以及相应的控制变量  $Z$  得到, 如果二者存在差异, 则认为变量  $X$  对变量  $Y$  存在间接影响, 同时变量  $Z$  在这个过程中扮演中间变量的角色。在这个识别策略中, 控制变量  $Z$  往往选择的是发生在变量  $X$  之后的变量, 控制变量  $Z$  往往会带来内生性选择偏差。

借用 Finn et al. (2005) 的高中一年级班级规模 ( $X$ ) 对高中毕业率 ( $Y$ ) 的研究, 除了变量  $X$  对变量  $Y$  的直接影响, 作者认为变量  $X$  可能会通过影响学生三年级的表现 ( $Z$ ) 从而对变量  $Y$  产生间接的影响。




图 2.7: 控制变量与直接影响、间接影响

如果班级规模 ( $X$ ) 是随机分配的, 在图 2.7 (a) 中, 因为变量  $X$  与变量  $Y$  没有共同原因, 所以变量  $X$  对变量  $Y$  的总影响可以直接通过变量  $Y$  对变量  $X$  的线性回归得到。变量  $Z$  发生于变量  $X$  之后, 这个变量就不再是随机变量了, 可能与变量  $Y$  之间存在不可观测的共同原因, 例如学生家长的教育背景、学生的能力、学生的学习激励等等, 在这样的情况下, 将变量  $Z$  作为控制变量加入回归中并不能得到变量  $X$  对变量  $Y$  的直接影响, 从而无法通过对比总影响和直接影响来识别间接影响。

考虑一个更极端的情况, 在图 2.7 (b) 中, 如果变量  $Z$  对变量  $Y$  的相关性完全来自于二者的共同原因, 变量  $Z$  对变量  $Y$  本身是没有因果效应的, 在这个假设下, 变量  $X$  对变量  $Y$  的总影响就是变量  $X$  对变量  $Y$  的直接影响。根据传统的识别策略, 将变量  $Z$  作为控制变量的加入, 会与不加入的结果产生差异, 并将此差异作为变量  $X$  对变量  $Y$  的间接影响, 这显然是存在偏差的, 据此得到的因果解释也是错误的。在更一般的情况下, 无论是直接影响还是间接影响都不能简单通过选择发生在解释变量之后的控制变量来得到, 必须基于相应的学科理论基础以及长期的观察做出假设, 并在此基础上用数据加以验证。

## 2.3 图模型的因果推断准则

### 2.3.1 图模型的基本结构

一个图模型根据假设的不同，会有完全不同的结构，但本质上图模型由三种基本结构组成，借助这些基本结构，我们就可以在我们构建的网络中表示所有的变量关系，这也是后面所有分析的基础。

第一种是  $A \rightarrow B \rightarrow C$ ，这种接合形式被称为“链”接合，在实际应用中， $B$  作为  $A$  和  $C$  的“中介物”，将  $A$  的效应传递给  $C$ ，例如“火灾  $\rightarrow$  烟雾  $\rightarrow$  报警”，火灾本身不会引起报警系统的反应，而是通过空气中的烟雾分子触发，如果给定烟雾被通风管道吸走，那么无论火灾发生与否，警报都不会触发。所以已知烟雾的值，我们可以认为火灾和警报条件独立。通过这个简单的例子，我们很容易就能推出，如果我们的三个观测变量有这样的关系，我们如果在回归中控制住变量  $B$ ，将无法估算出  $A$  对  $C$  的因果影响，这也是统计中提到的过度控制误差。

第二种是  $A \leftarrow B \rightarrow C$ ，这种接合形式被称为“叉”接合，在这个结构中， $B$  是  $A$  和  $C$  的共因，也被称为混杂因子，而  $B$  的存在也让  $A$  和  $C$  在统计上具有了关联，即使直接将  $A$  对  $C$  进行回归得到了显著的结果，我们也不能说这二者之间存在因果关系。此时如果我们控制住  $B$ ，我们将消除  $A$  和  $C$  之间的关联，所以  $A$  和  $C$  是关于  $B$  条件独立的，这里的独立性只是概率测度的一种性质而非事件本身的性质。

第三种是  $A \rightarrow B \leftarrow C$ ，这种接合形式被称为“对撞”接合或者称为“V 结构”，这种结构与前面的“叉”接合完全相反，这里  $A$  和  $C$  之间本来是相互独立的，但  $B$  的存在让他们彼此相关。例如学生迟到 ( $B$ ) 可能来源于早起 ( $A$ ) 或者交通工具故障 ( $C$ )，学生早起和交通工具故障这二者并无关联，但如果观察到学生迟到且他的交通工具并无障碍，可以判断他迟到的原因来自于早起。

在实际应用中，图模型远比这三种结构复杂，它们都被其他的因果路径所包围，这时必须将这些路径也考虑进来，而贝叶斯网络能够让我们通过这三种基本结构读取整个网络所蕴含的所有独立性，无论多么复杂，我们也能通过这些基本结构的性质来检测已有的因果模型，发现新的模型或者评估干预效应。

### 2.3.2 d 分离

根据前面的分析可以看到，图模型的本质是变量之间条件独立性的表达，在图模型中，d 分离 (d-separation) 被用于表达这样的条件独立性。

d 分离 (Pearl 1988):  $X, Y, Z$  是 DAG 中不相交的节点集合，给定一条从  $X$  到  $Y$  的路径，如果某个变量处于该路径上且满足以下两个条件，则称该节点阻断了这条路径，也称  $Z$  d 分离了  $X$  和  $Y$ ：

- (1) 如果该节点不是一个“冲撞点”，例如： $X \rightarrow Z \rightarrow Y$ ，或是  $X \leftarrow Z \rightarrow Y$ ，则该节点包含在  $Z$  中；
- (2) 如果该节点是一个“冲撞点”，则该节点以及它的“后代”节点不包含在  $Z$  中。

### 2.3.3 后门准则

根据前文对  $d$  分离的描述，如果说一个变量将另外两个变量  $d$  分离，那么控制住该变量会切断这两个变量之间的信息传递，我们关注的变量之间可能存在多个影响路径，可观测的和不可观测的混杂因子让回归的结果存在误差，但如果能找到一系列变量能够  $d$  分离这些对直接因果关系造成影响的路径，我们就能够估算出我们需要的因果关系。借此，在  $d$  分离的基础上，Pearl (1993, 2009) 提出了后门准则 (Backdoor criterion)。

后门准则 (Pearl 1993, 2009)：识别  $X$  对  $Y$  的因果关系时，可观测到的变量集合  $Z$  如果满足以下条件：

- (1)  $Z$  中的变量不是  $X$  的“后代”节点；
- (2)  $Z$  中的变量阻断了  $X$  和  $Y$  之间所有指向  $X$  的路径，或者说  $Z$  阻断了  $X$  和  $Y$  之间所有的后门路径。

则称变量集合  $Z$  对  $X$  和  $Y$  满足后门准则。后门准则的本质就是通过  $d$  分离阻断其他影响我们判断因果的路径，从而剩下的路径就是我们所关心的那个路径。将后门准则代入到前面的图 2.5 (a) 中，可以发现图中的  $Z$  很明显满足后门准则，控制住  $Z$  可以阻断混杂因子对识别  $X$  对  $Y$  的因果关系的影响。此时：

$$\begin{aligned} P(y | do(X) = x) &= \sum_z P(y, z | do(X = x)) \\ &= \sum_z P(y | x, z) P(z) \end{aligned}$$

根据定义，如果计算变量  $X$  增加一单位对变量  $Y$  的平均因果作用：

$$\begin{aligned} ACE(X \rightarrow Y) &= \sum_z E\{Y | do(X) = x+1, Z = z\} \Pr(Z = z) - \sum_z E\{Y | do(X) = x, Z = z\} \Pr(Z = z) \end{aligned}$$

从上面可以看出，如果我们能找到有效的  $Z$  变量， $ACE$  就是将  $Z$  变量控制后， $Y$  对  $X$  的回归系数。回到前面描述贝叶斯网络的例子，如今有了后门准则，我们不仅仅能将这个网络中的所有变量的联合分布简洁地表达出来，我们也能通过控制某些变量来准确地识别  $X_i$  对  $X_j$  的因果作用。

在图 2.2 中，仅仅控制  $X_4$  是不足以排除所有混杂影响的， $X_4$  是路径  $X_1 \rightarrow X_4 \leftarrow X_2$  中的碰撞点，所以控制  $X_4$  时， $X_1$  和  $X_2$  是相关的，此时  $X_i$  到  $X_j$  的信息传递还可以通过  $X_1$  和  $X_2$ ，这样估计出的系数是有偏差的。而我们将  $X_4$  和任意一个以上的其他变量同时控制时，我们就能估算出正确的因果关系，此时将所有变量控制不会造成过度控制带来的误差。

### 2.3.4 前门准则

后门准则依赖的是可观察的共因，而在图 2.2 (b) 中，除了变量  $Z$  外， $X$  和  $Y$  之间还有无法观察的共因，而且从图中我们可以看到这个共因由误差项的相关性导致，所以变量  $Z$  不足以控制所有的指向  $X$  的路径，最后回归结果仍然是有偏差的。

同样，在图 2.4 中，变量  $Z$  处于变量  $X$  和  $Y$  之间，且三个变量构成了“链”接合，传统的计量方法告诉我们，在  $X$  到  $Y$  的信息传递过程中，如果存在第三个变量，我们在回归中不能加入这个变量，因为这回阻断这个信息传递过程，从之前条件独立性的观点来看，如果我们控制这个变量，那么  $X$  和  $Y$  将条件独立。同时，因为它们的误差项相关，直接对  $X$  和  $Y$  回归无法得到它们的因果关系。对于这种变量之间无法观察到的共因，Pearl (1995) 提出了“前门准则” (frontdoor identification criterion)。




图 2.8: 前门准则图模型

前门准则 (Pearl 1995): 在 DAG 中，如果可观测到的变量集合  $Z$  如果满足以下条件：

- (1) 变量  $Z$  切断了所有  $X$  到  $Y$  的直接路径；
- (2)  $X$  到  $Z$  没有任何后门路径；
- (3) 所有  $Z$  到  $Y$  的后门路径被变量  $X$  阻断。

根据前门准则，我们可以通过两步来推断  $X$  对  $Y$  的因果关系。首先，根据前门准则的第二个条件， $X$  到  $Z$  没有任何后门路径，所以  $X$  对  $Z$  的因果关系是可以识别的。其次，根据第一个和第三个条件， $X$  对变量  $Z$  和  $Y$  满足后门准则，所以控制住变量  $X$ ， $Z$  对  $Y$  的因果关系也是可以识别的。根据以上两步，最后  $X$  对  $Y$  的因果关系也是可以识别的。再回到图 2.2 (b)，如果在  $X$  和  $Y$  之间的路径上我们能够再找到这样一个变量，我们就能通过前门准则估算出  $X$  对  $Y$  的因果关系。通过上述分析可以发现，前门准则本质上是后门准则的变形与应用，而后门准则本质上也是图模型三种基本结构的应用，三种基本结构给我们提供了不同情况下变量之间的条件独立关系，变量之间的条件独立关系来源于我们的假设，所以在我们给定变量的假设后并得出相应的图模型后，我们可能会发现前门准则和后门准则并不能直接帮助我们判断模型是否可识别，但正如前门准则是后门准则的应用一样，我们可以将变量间的独立关系以及三种基本结构灵活应用来判断模型的因果关系。

## 2.4 工具变量以及工具变量集

无论在计量经济学还是因果图中，工具变量都扮演了重要的角色，从计量和统计学的角度来看，工具变量  $Z$  需要满足两个条件：该变量与内生解释变量存在相关性且该变量对于被解释变量严格外生。例如：




图 2.9：图模型与工具变量

在图 2.7 中，变量  $Z$  满足工具变量的两个要求。具体来看， $Z$  与  $Y$  的相关性完全来自于  $Z$  与  $X$  的相关性，假设  $X$  对  $Y$  的因果关系系数为  $c$ ，那么可以推出： $\rho_{ZY} = c \cdot \rho_{ZX}$ ，而  $Z$  与  $X$  的相关性可以推出： $c = \rho_{ZY} / \rho_{ZX}$ ，因此系数  $c$  是可以被识别的。从图模型的角度来看，不控制  $X$  时， $X$  和  $Y$  之间的虚线和  $Z$  与  $X$  之间的箭头构成了一个“冲撞”接合，所以当直接计算  $Z$  与  $Y$  之间的相关系数时，混杂因子的影响被消除了，所以工具变量本质上还是图模型三种基本结构的应用。

在实际应用中，找到完全符合条件的工具变量往往不是一件容易的事情，对于这个问题，Pearl (2009) 通过变量之间的条件独立性，在条件工具变量 (conditional IV) 的基础上将工具变量方法的适用性进一步拓展。如果变量  $Z$  不满足工具变量的两个条件，但控制住另一个或多个变量  $W$  后满足工具变量的两个条件，那么  $X$  对  $Y$  的因果影响可以通过  $\rho_{ZY.W} / \rho_{ZX.W}$  来表示。

Pearl (2012) 认为，如果  $W$  满足以下条件：

- (1)  $W$  不包括任何  $Y$  的“后代”变量；
- (2) 将图模型中  $X \rightarrow Y$  这条边删除后，控制  $W$ ， $Z$  与  $X$  d 连接，而  $Z$  与  $Y$  d 分离。

则认为变量  $Z$  是条件工具变量，且  $X$  对  $Y$  的因果影响是可以识别的。




图 2.10：工具变量应用

Morgan, Winship (2015) 同样给出了相似的例子，在图 2.8 中，如果只关注  $D$  对  $Y$  的影响，此时条件工具变量提供了快速的推断方法：单纯从工具变量的角度来看，显然

变量  $Z$  不满足与变量  $Y$  的严格外生性要求, 当删除  $D \rightarrow Y$  时, 可以发现变量中  $W$  满足上述条件, 从而变量  $Z$  是一个条件于变量  $W$  的工具变量。从条件独立性来看, 条件工具变量正是后门准则和工具变量的结合, 通过找到一个新的可观测的变量来消除变量  $X$  与变量  $Y$  之间的混杂因素, 从而在特定条件下变量  $Z$  是一个可行的工具变量, 我们也能更快地推断我们所关注的因果关系。

Pearl 和 Morgan, Winship 对工具变量的选择是基于因果图以及后门准则等, 虽然本质上与传统计量经济学对工具变量的选择思路是一致的, 但方法上具有明显差异, 同时, 由于无法观测到的因素可能会影响工具变量的有效性, 所以需要根据具体结果来分析工具变量的选择是否合适。

## 2.5 时间序列与动态因果效应

联系的时序性是判别因果的重要维度。在时间序列的研究中, 格兰杰因果检验是最常用的方法之一 (Granger, 1969)。在时间序列数据中, 关注的变量在不同时间点上一致相关, 基于这一相关性, 格兰杰提出利用线性回归, 用变量的当前和过去值预测其未来值, 模型如下:

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \delta_{11} X_{1t-1} + \delta_{12} X_{1t-2} + \dots + \delta_{1q1} X_{1t-q1} + \dots + \delta_{k1} X_{kt-1} + \delta_{k2} X_{kt-2} + \dots + \delta_{kq2} X_{kt-q2} + u_t$$

用于检验其中一个回归变量滞后项是否包含了模型中其他回归变量没有包含的预测内容的 F 统计量被称为 Granger 因果系统统计量<sup>3</sup>。

斯托克, 沃森 (2012) 提到: “因果关系是用理想化随机试验的术语定义的, 相反, Granger 因果关系指如果  $X$  granger 导致了  $Y$ , 则给定回归中的其他变量后  $X$  是  $Y$  的有用预测变量, 术语 Granger 预测性比因果关系更加准确。”

斯托克, 沃森 (2012) 在时间序列平稳性检验的基础上用分布滞后模型来讨论因果关系, 让单个对象在不同时间点上扮演干预组和控制组, 以此来模拟随机试验。基本模型如下:

$$Y_t = \beta_0 + \beta_1 X_t + \beta_2 X_{t-1} + \beta_3 X_{t-2} + \dots + \beta_{r+1} X_{t-r} + u_t$$

其中,  $X$  必须是外生的, 就如同在理想化随机试验中随机确定的。如果  $X$  同时还满足严格外生性, 即  $X$  的未来值也与  $Y$  独立, 可以通过自回归分布滞后模型或 GLS 估计动态因果效应。如果  $X$  不满足严格外生性, 可直接通过 OLS 来估计分布滞后模型的参数。

<sup>3</sup> [美]詹姆斯·H·斯托克、[美]马克·W·沃森:《计量经济学:第2版》,孙燕译,2009年8月第1版,410页。



## 第三章 图模型的应用

北京的空气污染问题长期以来受到广泛的关注，而环境问题与经济活动密切相关，环境污染的治理往往伴随着经济活动的下降，所以北京和河北到底谁影响谁的话题争论已久，彼此都认为对方是污染的主要来源。在环境变量间，彼此的影响相对复杂，受到的干扰也很多，无论是将北京还是河北的污染指数作为因变量还是自变量，都会因为各种无法观测的混杂因素造成结果的误差。变量关系的复杂性让我们无法单单通过想象来构建变量间的相互关系，因果图最大的特点就是将复杂问题简单化，所以本文试图通过因果图来分析北京 PM2.5 浓度的因果问题，并希望借此能为后面的研究提供一点启发，能将因果图适用于更复杂的问题。此外，2017 年北京大兴发生了重大火灾事件，在哀悼的同时，北京城乡结合部也借机清理了北京的非法燃煤问题，一定程度上根除了燃煤对空气污染的影响，从因果图的观点来看，此事件是绝佳的干预，完全可以视为 do 因子，所以本文也将结合该事件探讨北京自身污染排放对 PM2.5 浓度的影响。

### 3.1 PM2.5 浓度与主要解释变量之间的因果关系

PM2.5 是指空气中直径等于或者小于 2.5 微米的大气颗粒物（后文简称 PM2.5），PM2.5 是近年来持续雾霾天气，能见度降低等的主要原因之一。PM2.5 会吸附空气中的有毒有害物质，并能随着呼吸进入人体肺部，长期暴露于过高 PM2.5 浓度的环境中，会对人体健康产生严重危害。北京作为首都也是雾霾重灾区，其空气质量持续受到社会、媒体等的广泛关注。近年来，政府一直不懈努力希望通过相关措施降低北京市 PM2.5 浓度，无论哪种措施都与经济息息相关，在稳定经济的前提下，找到有效措施降低 PM2.5 浓度的重要前提就是对 PM2.5 浓度的影响因素有直观的认识，本文试图通过因果推断的方式，研究并比较不同因素对 PM2.5 浓度的影响。

### 3.1.1 北京 PM2.5 浓度主要影响因素

PM2.5 浓度的影响因素很多，但主要包括两类：空气污染物排放（后文简称排放）和空气污染物扩散条件（后文简称扩散条件）。其中，空气污染物排放指所有导致 PM2.5 增加的污染源的排放，空气污染物扩散条件主要指气象条件，由于 PM2.5 是粒径小、在空气中停留时间长的大气颗粒物，其浓度会直接被气象条件所影响，最直观的就是风速对 PM2.5 浓度的影响，高浓度 PM2.5 主要出现在静风天气，而大风天气下，基本不会出现雾霾天气。二者对 PM2.5 浓度的影响如下：

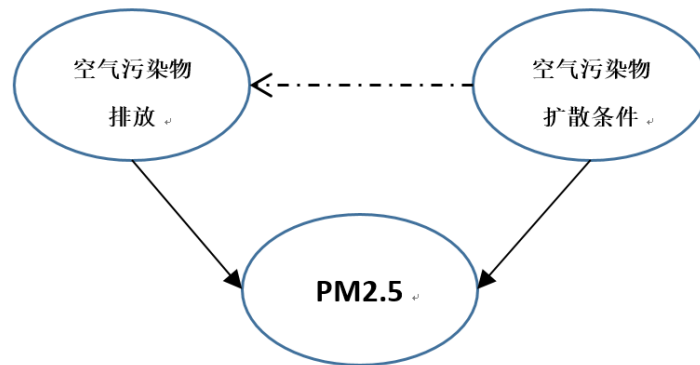


图 3.1: PM2.5 浓度主要影响因素

其中  $V = \{\text{排放}, \text{扩散条件}, \text{PM2.5}\}$ ,  $F = \{f_1, f_2\}$

$f_1$  :  $\text{PM2.5} = f_1(\text{排放}, \text{扩散条件})$

$f_2$  :  $\text{排放} = f_2(\text{排放}, \text{扩散条件})$

### 3.1.2 北京空气污染物排放主要来源

北京空气污染物的排放主要有四个来源，分别是燃煤、机动车排放、生活油烟排放以及区域传输，而这几个来源都是无法被观测和量化的，具体如下：

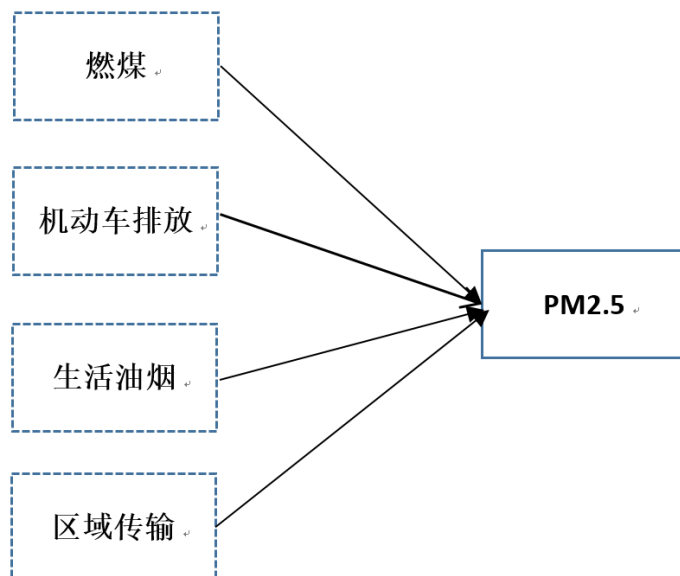


图 3.2：空气污染物排放主要来源

具体来看，燃煤对 PM2.5 的影响主要有两个渠道，第一是燃煤产生烟尘等造成的一次污染，第二是燃煤产生的二氧化硫（ $SO_2$ ）造成的二次污染。其中，二氧化硫是一种化学气体，本不会直接进入 PM2.5 的计算范畴，但二氧化硫会在空气中发生化学反应从而生成硫酸盐等细颗粒物造成 PM2.5 浓度的增加。具体如下：




图 3.3：燃煤对 PM2.5 的影响

其中， $V = \{SO_2, PM2.5\}$ ， $U = \{燃煤\}$ ， $F = \{f_1, f_2\}$

$f_1$  :  $PM2.5 = f_1(燃煤, SO_2)$

$f_2$  :  $SO_2 = f_2(燃煤)$

在实际观察中，具体燃煤的数目是无法被量化的，只能观察到二氧化硫在大气中的浓度，通过对上图的分析可以看出，将 PM2.5 对 SO<sub>2</sub> 进行回归也无法得到 SO<sub>2</sub> 造成的二次污染对 PM2.5 的影响，因为燃煤在这里充当了它们二者间的混杂因子，除了 SO<sub>2</sub> 对 PM2.5 的直接影响，路径 SO<sub>2</sub> ← 燃煤 → PM2.5 是无法被阻断的，所以结果是有偏差的。如果燃煤是可以被观察的，就可以测量燃煤对 PM2.5 的总影响，以及一次污染二次污染分别造成的影响，因为对 SO<sub>2</sub> 和 PM2.5 来说，燃煤符合后门准则，将燃煤加以控制，可以有效地计算出 SO<sub>2</sub> 对 PM2.5 的直接影响。

后门准则要求燃煤是可以观测的，而正如前面所说，SO<sub>2</sub> 对 PM2.5 的影响是通过硫酸盐造成的，所以，如果能观察到硫酸盐的浓度，也能通过前门准则测算出 SO<sub>2</sub> 对 PM2.5 的影响，如下图所示：




图 3.4：前门准则的应用

与燃煤类似，机动车对 PM2.5 的影响同样可以分为一次污染和二次污染，机动车一次污染主要来源于机动车轮胎与地面摩擦产生的细颗粒物，二次污染主要来源于氮氧化物在空气中形成的盐类颗粒物。具体如下：




图 3.5：机动车排放对 PM2.5 的影响

其中,  $V = \{O_3, CO, NO_2, PM2.5\}$ ,  $U = \{\text{机动车}\}$ ,  $F = \{f_1, f_2, f_3\}$

$f_1 : PM2.5 = f_1(CO, \text{机动车}, NO_2, O_3)$

$f_2 : O_3 = f_2(NO_2)$

$f_3 : CO = f_3(\text{机动车})$

其中, 臭氧 ( $O_3$ ) 通常被作为控制变量加入回归方程中, 但可以看到臭氧与一氧化碳都是气体, 不会对 PM2.5 产生影响, 而其中臭氧对 PM2.5 的影响会被氮氧化物阻挡, 而由于机动车排放是无法观测的, 所以需要将一氧化碳作为解释变量来观察其对 PM2.5 的影响。某些文献中, 臭氧 ( $O_3$ ) 也被认为在温度的影响下, 通过光化学反应会增加 PM2.5 颗粒质量, 从而提高 PM2.5 浓度, 所以臭氧 ( $O_3$ ) 具体对 PM2.5 浓度的影响应该对比来看。

除了燃煤和机动车排放, 生活油烟和区域传输也是重要的污染物来源, 但生活油烟无法观测也无法找到合适的代理变量, 区域传输主要受到气象影响, 具体在下一节进行分析。据此, 可以将污染物排放对 PM2.5 的影响归纳如下:

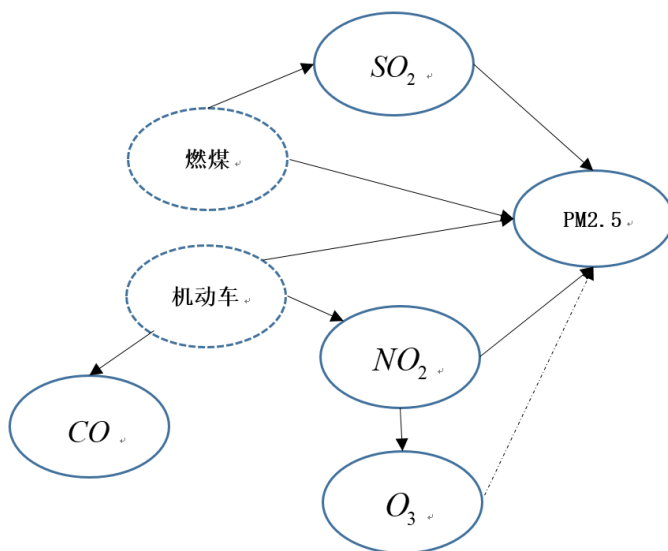


图 3.6: 空气污染物排放对 PM2.5 的影响

### 3.1.3 空气污染物扩散条件对 PM2.5 的影响

空气污染物扩散条件主要包括风速、风向、相对湿度和温度。具体模型如下：




图 3.7：空气污染物扩散条件对 PM2.5 的影响

其中， $V = \{\text{风速}, \text{风向}, \text{湿度}, \text{温度}, \text{PM2.5}\}$ ， $U = \{\text{外地输入}, \text{逆温}\}$ ， $F = \{f_1, f_2\}$

$$f_1 : \text{PM2.5} = f_1(\text{风速}, \text{风向}, \text{湿度}, \text{温度}, \text{外地输入}, \text{逆温})$$

$$f_2 : \text{湿度} = f_2(\text{风向}, \text{温度}, \text{逆温})$$

相比其他因素风速对 PM2.5 浓度的影响是最复杂的，给定颗粒物的数量，风速会直接影响颗粒物在空气中呈现的浓度，风速还会影响外部传输，即使风向有利于污染物的输入，但在静风条件下，污染物还是无法从外地传输进来。

湿度对 PM2.5 的影响除了直接影响外，还存在逆温等混杂因子，所以直接加入湿度对 PM2.5 进行回归得到的结论是有偏差的。同时，温度不会直接影响 PM2.5，却会影响湿度，此时温度满足工具变量的要求，可以考虑将温度作为湿度的工具变量，消除由逆温等无法观测变量造成的混杂影响。

### 3.1.4 PM2.5 影响因素模型设立

根据上文对空气污染物排放和空气污染物扩散条件对 PM2.5 影响的具体分析，可以将整体的图模型设置如下：

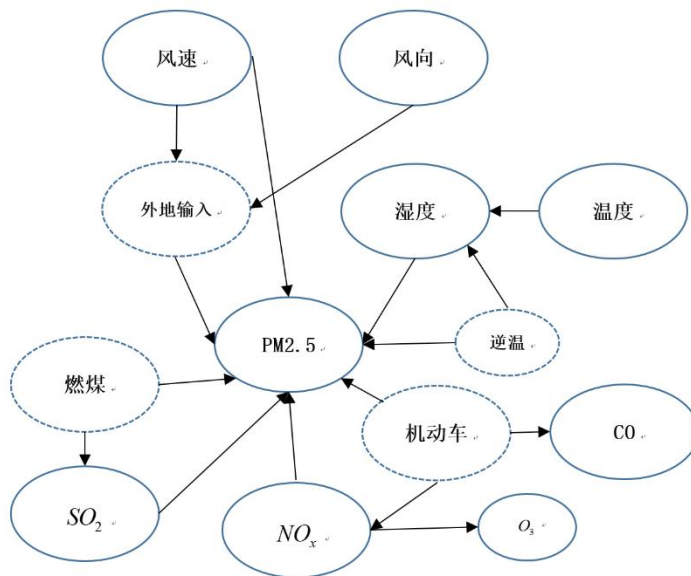


图 3.8：PM2.5 影响因素图模型

## 3.2 数据及样本介绍

本文使用 2015 年 1 月-2018 年 12 月北京市气象台观测的亦庄地区每小时的 PM2.5 浓度、污染气体以及气象数据，缺失值用相应机场数据进行插补，合计 35064 个观测值。气象数据主要包括风向、风速、温度和相对湿度，其中风向有 17 种取值，分别对应风向 16 方位图以及静风或不定风，为了避免控制变量过多，将风向进行合并，最后生成八种风向以及静风<sup>45</sup>。

## 3.3 PM2.5 浓度影响因素分析

### 3.3.1 模型设定

本文根据 PM2.5 浓度影响因素之间关系的假设，绘制出相应的图模型，并据此用后门准则等判定解释变量、控制变量的选择，此节将对模型进行实证分析。

根据前文对图模型的分析，模型初步设定如下：

$$PM25 = \beta_0 + \beta_1 humidity + \beta_2 SO_2 + \beta_3 NO_2 + \beta_4 windspeed + \beta_{wd} Winddirection + \beta_{season} Season$$

<sup>4</sup> 北京环境与气象数据主要来源网站：<http://zx.bjmemc.com.cn/>；  
<http://zx.bjmemc.com.cn/getAqiList.shtml?timestamp=1586650096480>；<http://www.weather.com.cn/air/>；  
<http://www.weather.com.cn/weather/101010100.shtml>；

<sup>5</sup> 感谢王敏老师，徐晋涛老师，中国气象局朱定真老师和北京市气象台的帮助。

其中 PM2.5 代表实时的 PM2.5 质量浓度，单位是  $\mu\text{g}/\text{m}^3$ ， $\text{SO}_2$  代表二氧化硫质量浓度，单位是  $\mu\text{g}/\text{m}^3$ ， $\text{NO}_2$  代表二氧化氮质量浓度，单位是  $\mu\text{g}/\text{m}^3$ ，windspeed 代表风速，单位是 m/s，Winddirection 代表根据 16 风向图调整后的风向控制变量，共包括八种风向，分别是：北+北东北 (N\_NNE)，东北+东东北 (NE\_ENE)，东+东东南 (E\_ESE)，东南+南东南 (SE\_SSE)，南+南西南 (S\_SSW)，西南+西西南 (SW\_WSW)，西+西西北 (W\_WNW)，西北+北西北 (NW\_NNW)。

此外，根据前文假设，一氧化碳 (CO) 和臭氧 ( $\text{O}_3$ ) 也有可能通过某些无法被阻挡的路径对 PM2.5 浓度产生影响，将以此加入回归中，分析其对参数的印象。一氧化碳 (CO) 单位是  $\text{mg}/\text{m}^3$ ，臭氧 ( $\text{O}_3$ ) 单位是  $\mu\text{g}/\text{m}^3$ 。

由于 PM2.5 在空气中停留时间长，所以风速对其影响是滞后的，在平稳性检验通过的前提下，可以加入风速的多期滞后项进行结果的比较。

### 3.3.2 结果比较

由于北京市对于空气污染的治理每年都有不同的措施，所以本文先选取 2015 年 1 月-12 月的样本数据进行不同模型的估计。结果如下：

表 3.1: OLS 回归结果

	(1)	(2)	(3)	(4)
	ols1	ols2	ols3	ols4
VARIABLES	PM25	PM25	PM25	PM25
SO2	1.164 (0.040)	0.416 (0.033)	0.416 (0.033)	0.416 (0.032)
NO2	1.494 (0.025)	0.566 (0.024)	0.592 (0.024)	0.816 (0.025)
CO		44.003 (0.603)	43.635 (0.605)	40.307 (0.599)
O3				0.328 (0.013)
humidity	1.348 (0.033)	0.549 (0.028)	0.562 (0.029)	0.794 (0.029)
windspeed	12.952 (0.650)	6.094 (0.521)	3.717 (0.711)	3.942 (0.509)
L.windspeed			2.959 (0.846)	
L2.windspeed			1.833 (0.847)	
L3.windspeed			-0.035 (0.838)	
L4.windspeed			-2.026 (0.687)	



winter	32.147 (2.104)	27.81 (1.726)	27.26 (1.731)	24.038 (1.969)
spring	23.172 (1.910)	21.54 (1.505)	21.457 (1.515)	37.169 (1.576)
autumn	-1.900 (1.828)	4.678 (1.444)	4.303 (1.444)	17.797 (1.485)
E_ESE	11.022 (6.094)	-1.994 (4.806)	-1.050 (4.803)	-0.031 (4.638)
NE_ENE	-8.249 (5.846)	-12.802 (4.608)	-11.773 (4.608)	-7.966 (4.450)
NW_NNW	-0.762 (6.254)	-6.472 (4.930)	-5.519 (4.927)	1.630 (4.767)
N_NNE	-15.442 (5.985)	-15.797 (4.718)	-14.911 (4.713)	-9.755 (4.557)
SE_SSE	22.337 (6.272)	10.790 (4.946)	12.008 (4.945)	5.630 (4.776)
SW_WSW	15.186 (5.936)	6.725 (4.680)	7.768 (4.677)	5.592 (4.515)
S_SSW	24.332 (5.878)	12.756 (4.636)	14.029 (4.635)	7.213 (4.477)
W_WNW	2.839 (6.385)	-4.367 (5.034)	-3.097 (5.032)	0.008 (4.859)
Observations	8,760	8,760	8,756	8,760
R-squared	0.645	0.779	0.780	0.795

列（1）中仅加入二氧化硫和二氧化氮作为解释变量，可以看到二者对 PM2.5 浓度有显著正向影响，而根据前文的描述，由于无法具体观测到燃煤和机动车排放的数值，所以二者的系数不能完全反应其对 PM2.5 浓度的直接影响，二氧化硫和二氧化氮对 PM2.5 浓度的影响是通过空气中化学反应生成的硫酸盐、硝酸盐等，属于二次污染，而这两个系数还混杂了燃煤、机动车排放造成的一次污染。同时根据季节控制变量和风向控制变量可以看到，春冬季 PM2.5 浓度会显著上升，这与这些季节供暖是一致的，在风向为南部，东南部的风向时，PM2.5 浓度会显著上升，根据北京的地理位置，西北部没有污染源，东南部是河北，具有较多污染源，所以区域传输对北京 PM2.5 浓度增加的影响是不可忽视的。

列（2）中加入了一氧化碳作为解释变量，根据前文的描述，一氧化碳主要来源于机动车，而机动车排放无法被测量，所以一氧化碳对 PM2.5 浓度的影响是不会被二氧化氮等所阻挡的，一定程度上一氧化碳可以衡量机动车一次排放对 PM2.5 浓度的影响。加入一氧化碳后，二氧化氮的系数显著降低，原因是一氧化碳一定程度上剔除了二氧化氮系数中一次污染造成的影响。列（3）在列（2）的基础上，加入了风速的滞后项，滞后项的选择是根据风速自回归的 BIC、AIC 准则，选取了 4 期作为滞后期，可以发现风速对

PM2.5 浓度的驱散作用是存在滞后的，而当期以及短滞后期的风速对 PM2.5 浓度的影响都是正向的，关于这一点，有两种可能的解释，第一，在风速较低的情况下，会起到搅拌空气中颗粒物从而提高 PM2.5 浓度的作用，样本中大部分风速都是较小的，所以系数为正，第二，PM2.5 观测值是滞后的，具体滞后期数不确定，可能一期到两三期之间，所以滞后风速对 PM2.5 驱散作用在滞后项中才体现出来。

列（4）在列（2）的基础上，加入了臭氧作为控制变量，根据上文的描述，虽然臭氧与 PM2.5 浓度之间存在明显的正相关关系，但臭氧对 PM2.5 浓度是否有直接影响这一论断是不确定的，可能其正相关关系来源于臭氧与二氧化氮之间的关系。根据列（4）的结果，可以发现，二氧化硫的系数没有发生变化，与前文的描述是一致的，臭氧与二氧化硫之间没有可能的路径，其次，二氧化氮的系数发生了显著上升，而且臭氧对 PM2.5 具有显著正向影响，所以猜测臭氧与 PM2.5 之间是可能存在路径的，这条潜在的路径可能来自于臭氧对 PM2.5 浓度的直接影响，也可能来自于臭氧与温度的关系，臭氧的可能影响机制是光照下的光化学反应，而光照与温度是正相关的，温度可能会通过相对湿度作用于 PM2.5 浓度，所以下文将继续通过工具变量来分析温度对 PM2.5 浓度的影响以及臭氧对 PM2.5 浓度的可能影响。

如前文所述，湿度与 PM2.5 浓度间可能存在无法观测的变量从而产生混杂影响，例如逆温，逆温会导致 PM2.5 的积聚，而逆温数据难以获得，所以考虑通过温度来作为湿度的工具变量。如下图所示：




图 3.9：温度作为湿度的工具变量

同时，臭氧与 PM2.5 浓度之间可能也存在连接，而温度也会对臭氧产生影响，从而在绝对意义上，温度与 PM2.5 浓度之间的联系可能存在除了湿度之外的路径，在这样的假设下，根据前文描述，温度此时可作为湿度的条件工具变量。如下图所示：

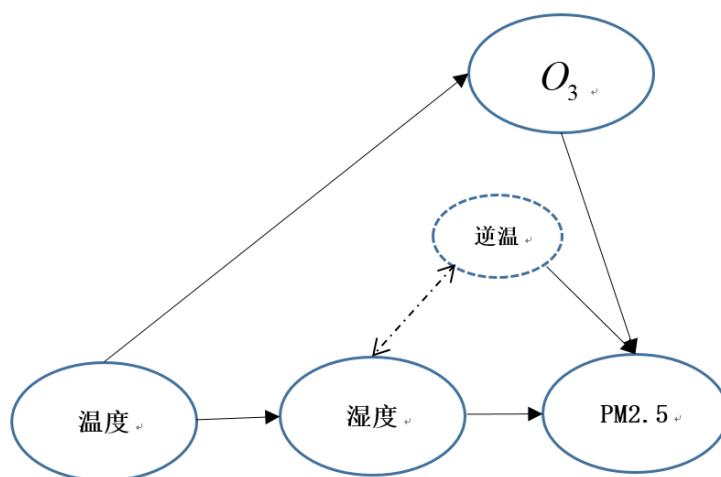


图 3.9: 温度作为湿度的条件工具变量

将温度作为湿度的工具变量或条件工具变量后，结果如下：

表 3.2: 温度作为工具变量回归结果

	(1)	(2)	(3)	(4)
	iv1	iv2	iv3	iv4
VARIABLES	PM25	PM25	PM25	PM25
SO2	0.59 (0.068)	-0.51 (0.082)	-0.488 (0.079)	-1.053 (0.482)
NO2	1.834 (0.042)	0.54 (0.031)	0.501 (0.032)	0.328 (0.165)
CO		62.419 (1.589)	61.421 (1.526)	76.145 (11.731)
O3				-0.058 (0.192)
humidity	-0.452 (0.162)	-1.705 (0.173)	-1.617 (0.165)	-3.222 (1.310)
windspeed	1.559 (1.249)	-8.931 (1.316)	-5.754 (1.151)	-16.053 (6.581)
L.windspeed			-1.031 (1.127)	
L2.windspeed			-0.230 (1.101)	
L3.windspeed			-1.437 (1.084)	
L4.windspeed			-3.408 (0.889)	
winter	20.149 (2.646)	30.197 (3.054)	26.993 (2.858)	67.451 (30.030)
spring	-0.040 (2.999)	-3.906 (2.742)	-0.537 (2.536)	-31.174 (22.455)

autumn	1.579 (2.132)	11.143 (1.952)	11.313 (1.928)	4.587 (5.055)
E_ESE	16.372 (7.050)	-1.734 (6.298)	-2.696 (6.181)	-3.129 (8.333)
NE_ENE	-4.256 (6.757)	-10.448 (6.041)	-12.193 (5.928)	-12.881 (8.097)
NW_NNW	-25.447 (7.536)	-35.199 (6.809)	-32.946 (6.655)	-58.454 (21.352)
N_NNE	-26.32 (6.974)	-27.551 (6.244)	-26.96 (6.129)	-39.217 (12.582)
SE_SSE	11.619 (7.300)	-5.476 (6.594)	-5.869 (6.497)	-10.952 (10.089)
SW_WSW	9.684 (6.869)	-2.686 (6.173)	-2.906 (6.069)	-7.316 (9.086)
S_SSW	20.549 (6.793)	3.874 (6.110)	3.468 (6.014)	3.034 (8.101)
W_WNW	-13.621 (7.510)	-24.943 (6.773)	-24.711 (6.668)	-40.473 (15.788)
Observations	8,760	8,760	8,756	8,760
R-squared	0.526	0.621	0.635	0.346

通过表中数据可以看到，二氧化氮和一氧化碳的结果与前面基本是一致的，同时，根据结果可以判断，臭氧对 PM2.5 浓度不存在显著影响，其影响主要通过温度对湿度的影响造成，这也与前面的理论和假设一致，臭氧不会对 PM2.5 直接产生影响，在选作控制变量甚至解释变量时需要慎重。

相比之下，二氧化硫的系数发生了较大的变化，从正向影响变成了负向影响，这与长期观察的结果是不一致的，可能二氧化硫与 PM2.5 之间还存在其他未知的影响方式与路径。综上所述，虽然根据现有理论假设，温度是湿度合适的工具变量，但由于未知的影响因素或者说混杂因子，所以将温度作为工具变量仍是有待商榷的。

### 3.3.3 风速动态因果效应

相比其他气象条件，风速对 PM2.5 的影响是最复杂也是相对最为持续的，风速也符合外生和严格外生性，可以被用来分析其对 PM2.5 浓度的动态因果效应。此外，由于在风速小的时候，可能在一定程度上会起到搅动空气颗粒物从而增加 PM2.5 浓度的作用，所以此节将考虑风速超过 3m/s 时，对 PM2.5 浓度的影响。

本节参照斯托克，沃森（2012）的动态因果效应模型，增加风速的滞后期进行结果的比较，因为 PM2.5 浓度的测量具有滞后性，如果将当期风速加入的话，可能会造成结果导致原因的可能，本文将风速滞后两期开始进行计算，结果如下：

表 3.3: 动态因果效应

(1) (2)

VARIABLES	lag10 PM25	accumulated	lag24 PM25	accumulated
L2.windspeed	-0.677 (0.821)	-0.677	-0.839 (0.825)	-0.839
L3.windspeed	0.030 (0.943)	-0.647	-0.106 (0.946)	-0.945
L4.windspeed	0.010 (0.983)	-0.637	-0.060 (0.986)	-1.005
L5.windspeed	-0.347 (0.965)	-0.984	-0.375 (0.967)	-1.38
L6.windspeed	-0.412 (1.003)	-1.396	-0.477 (1.008)	-1.857
L7.windspeed	-0.248 (1.012)	-1.644	-0.176 (1.017)	-2.033
L8.windspeed	-0.496 (1.015)	-2.14	-0.453 (1.020)	-2.486
L9.windspeed	-0.280 (1.023)	-2.42	-0.447 (1.029)	-2.933
L10.windspeed	0.165 (1.046)	-2.255	0.018 (1.052)	-2.915
L11.windspeed	0.047 (1.056)	-2.208	0.280 (1.071)	-2.635
L12.windspeed	-1.421 (0.858)	-3.629	0.002 (1.084)	-2.633
L13.windspeed			-0.453 (1.092)	-3.086
L14.windspeed			-0.593 (1.100)	-3.679
L15.windspeed			-0.045 (1.104)	-3.724
L16.windspeed			0.474 (1.091)	-3.25
L17.windspeed			-0.766 (1.053)	-4.016
L18.windspeed			-1.461 (1.039)	-5.477
L19.windspeed			-0.231 (1.009)	-5.708
L20.windspeed			1.066 (1.039)	-4.642
L21.windspeed			-0.613 (1.033)	-5.255
L22.windspeed			-0.514	-5.769

		(1.048)	
L23.windspeed		-0.416	-6.185
		(1.089)	
L24.windspeed		0.741	-5.444
		(1.068)	
L25.windspeed		0.130	-5.314
		(1.044)	
L26.windspeed		0.034	-5.28
		(0.849)	
Observations	1,731	1,726	
R-squared	0.634	0.638	

表中分别考察了风速滞后 10 期和 24 期对 PM2.5 浓度的影响，这一回归的系数为某小时风速增加一单位对接下来 10 小时或 24 小时 PM2.5 浓度变化的动态因果效应估计，例如，当风速增加一单位后，下个小时 PM2.5 浓度将减少 0.839 个单位，下两个小时将再减少 0.106 个单位。第 2、4 列为这一设定形式下的累计动态乘数，即 1、3 列中给出的动态乘数累计和。根据结果显示，一阵大风来后，对 PM2.5 浓度的影响是相对持续的，维持时间至少超过 24 小时。

### 3.3.4 2015-2018 年 PM2.5 浓度影响因素结果

根据前文的分析，一氧化碳应该被加入回归中，而臭氧不应该被加入，本节将据此将 2015-2018 年的数据分别进行测算并比较。结果如下：

表 3.4: 2015-2018 基本 OLS 回归

	(1)	(2)	(3)	(4)
	year_15	year_16	year_17	year_18
VARIABLES	PM25	PM25	PM25	PM25
SO2	0.416 (0.033)	1.351 (0.037)	1.903 (0.044)	1.172 (0.064)
NO2	0.566 (0.024)	0.683 (0.024)	0.415 (0.020)	0.284 (0.016)
CO	44.003 (0.603)	24.989 (0.606)	27.388 (0.557)	56.924 (0.889)
windspeed	6.094 (0.521)	8.86 (0.523)	5.723 (0.458)	3.431 (0.354)
humidity	0.549 (0.028)	0.973 (0.030)	0.665 (0.025)	0.223 (0.022)
winter	-2.781 (1.726)	-15.156 (1.820)	1.858 (1.525)	7.386 (1.193)
spring	21.54 (1.505)	15.266 (1.630)	15.763 (1.355)	16.99 (1.059)

autumn	4.678 (1.444)	-5.805 (1.459)	7.761 (1.252)	11.187 (1.036)
E_ESE	-1.994 (4.806)	-4.303 (3.905)	-2.597 (2.772)	-4.022 (2.852)
NE_ENE	-12.802 (4.608)	-19.086 (3.716)	-12.151 (2.566)	-8.07 (2.707)
NW_NNW	-6.472 (4.930)	0.027 (4.083)	1.893 (2.926)	-1.049 (2.902)
N_NNE	-15.797 (4.718)	-13.281 (3.920)	-5.848 (2.776)	-5.483 (2.808)
SE_SSE	10.79 (4.946)	10.93 (4.110)	7.941 (3.025)	1.252 (2.921)
SW_WSW	6.725 (4.680)	2.723 (3.825)	8.396 (2.615)	5.386 (2.764)
S_SSW	12.756 (4.636)	11.786 (3.810)	12.024 (2.619)	3.686 (2.743)
W_WNW	-4.367 (5.034)	-9.974 (4.236)	1.716 (3.065)	-2.878 (2.984)
Observations	8,760	8,784	8,753	8,760
R-squared	0.779	0.669	0.676	0.671

表 3.5: 2015-2018 加入风速滞后项的 OLS 回归

	(1)	(2)	(3)	(4)
	year_15	year_16	year_17	year_18
VARIABLES	PM25	PM25	PM25	PM25
so	0.416 (0.033)	1.367 (0.037)	1.9 (0.044)	1.186 (0.064)
NO2	0.592 (0.024)	0.732 (0.024)	0.443 (0.021)	0.306 (0.016)
CO	43.635 (0.605)	24.685 (0.606)	27.126 (0.558)	56.826 (0.890)
humidity	0.562 (0.029)	1.001 (0.031)	0.681 (0.025)	0.239 (0.022)
windspeed	3.717 (0.711)	5.128 (0.710)	3.872 (0.600)	2.164 (0.470)
L.windspeed	2.959 (0.846)	3.74 (0.856)	2.178 (0.708)	1.384 (0.562)
L2.windspeed	1.833 (0.847)	2.774 (0.855)	1.266 (0.706)	0.604 (0.561)
L3.windspeed	0.035 (0.838)	1.000 (0.849)	0.467 (0.700)	0.281 (0.556)
L4.windspeed	-2.026 (0.687)	-2.015 (0.686)	-1.257 (0.570)	0.019 (0.453)

winter	-2.726 (1.731)	16.057 (1.826)	17.06 (1.526)	7.168 (1.193)
spring	21.457 (1.515)	14.355 (1.637)	15.554 (1.357)	16.473 (1.066)
autumn	4.303 (1.444)	-6.08 (1.453)	7.674 (1.251)	11.092 (1.035)
E_ESE	-1.050 (4.803)	-3.385 (3.892)	-1.940 (2.771)	-3.484 (2.853)
NE_ENE	-11.773 (4.608)	-17.798 (3.706)	-11.53 (2.565)	-7.387 (2.709)
NW_NNW	-5.519 (4.927)	1.008 (4.071)	2.222 (2.924)	-1.012 (2.903)
N_NNE	-14.911 (4.713)	-12.608 (3.907)	-5.514 (2.774)	-5.079 (2.808)
SE_SSE	12.008 (4.945)	12.087 (4.097)	8.568 (3.025)	1.926 (2.923)
SW_WSW	7.768 (4.677)	3.627 (3.812)	8.767 (2.613)	5.907 (2.765)
S_SSW	14.029 (4.635)	13.172 (3.799)	12.792 (2.620)	4.299 (2.745)
W_WNW	-3.097 (5.032)	-8.242 (4.226)	2.427 (3.065)	-1.998 (2.989)
Observations	8,756	8,784	8,753	8,760
R-squared	0.780	0.672	0.677	0.672

通过对比可以发现，二氧化氮对 PM2.5 浓度的影响是逐年降低的，而一氧化碳的影响具有较大波动性，此外二氧化硫对 PM2.5 浓度的影响从 2017 年到 2018 年有大幅度的下降，原因可能是 2017 年底北京在城六区和南部平原区大规模全面整治燃煤，实现“无煤化”相当于对燃煤的干预 (do calculus)。前文提到，do 算子要求将所有指向解释变量的箭头移除，此次对非法燃煤的全面治理基本实现了北京的“无煤化”，从而阻断了燃煤对造成的 PM2.5 一次污染，相当于移除了燃煤指向二氧化硫的箭头，二氧化硫此时对 PM2.5 浓度的影响是没有燃煤这个混杂因子的，在该模型中，该系数可以解释为二氧化硫对 PM2.5 浓度的直接影响或是因果效应。

最后，图 3.10-3.13 分别用柱状图展示了 2015 年到 2018 年北京的 PM2.5 积聚过程分布状况，纵轴表示每次积聚过程末端时的 PM2.5 浓度。



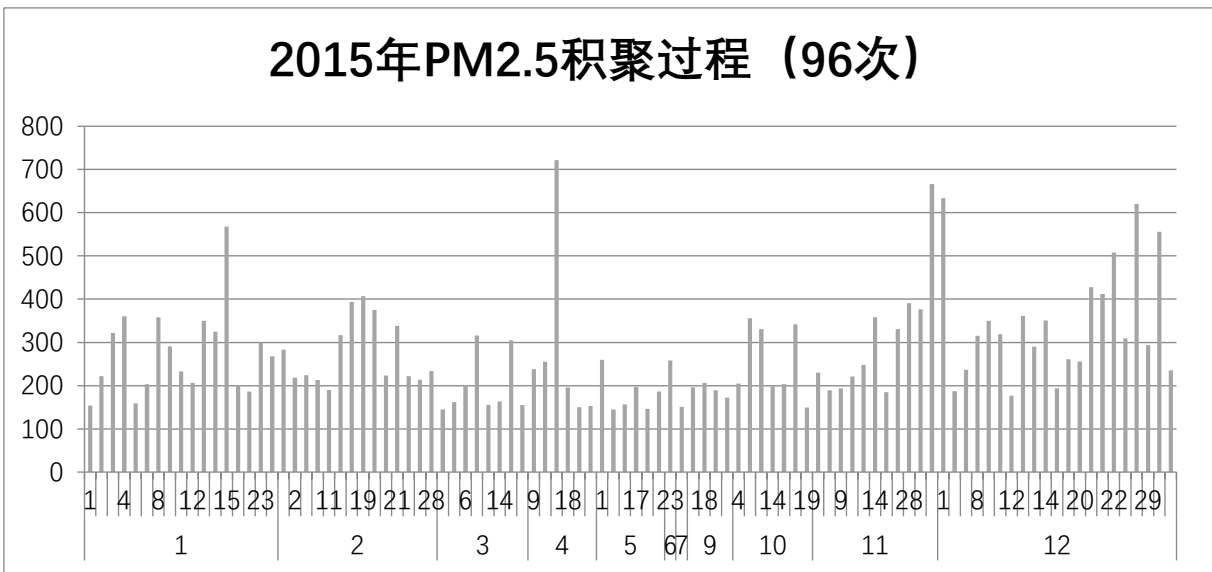


图 3.10: 2015 年 PM2.5 积聚过程




图 3.11: 2016 年 PM2.5 积聚过程




图 3.12: 2017 年 PM2.5 积聚过程

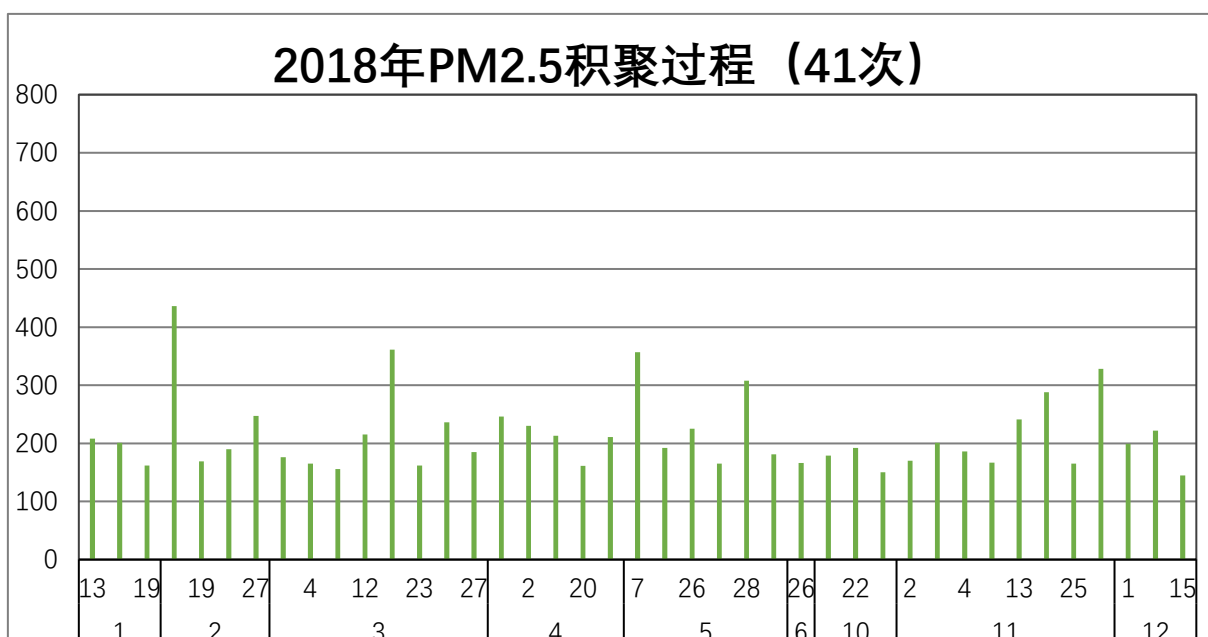


图 3.13: 2018 年 PM2.5 积聚过程

通过对比可以发现，除了整体 PM2.5 积聚次数的下降，相比 2015 年和 2016 年的 11 月、12 月以及来年的 1 月、2 月，2017 年和 2018 年的 PM2.5 积聚过程在供暖季有很明显的下降，这同样与 2017 年底北京治理非法燃煤是有关的，这也与前文的分析结果较为吻合。

## 第四章 结论与讨论

无论在哪个领域,因果推断都是最重要的话题之一。虽然因果模型有多种表现形式,但因果图以清晰易懂的特点突出,并且可以为许多问题提供简单明确的答案。本文首先回顾了因果效用的定义,并梳理传统识别因果效用的方法,强调因果关系的推断不应该由数据出发,而是应该建立在学科知识的基础上,用数据加以验证修改,从数据出发可能会导致结果的“可信性”问题。接着本文由浅入深回顾了图模型在因果推断中的理论和应用,将图模型分解为三种基本结构,同时结合条件独立性的概念,对后门准则和前门准则以及工具变量的选择进行了梳理,本文认为无论多复杂的策略,本质还是后门准则的灵活应用,而后门准则是条件独立性以及图模型三种基本结构的具体应用,所以,面对比文中更复杂的图模型时,即使本文介绍的策略无法进行因果推断,也能通过后门准则以及条件独立性的组合来进行因果分析。本文将图模型与传统计量方法中控制变量、工具变量的选择结合,认为变量的选择基于后门准则,或是说通过阻碍无用信息的传递,去除混杂来获取关注变量间的因果关系,而没有理论或经验判断支撑的控制变量选择,将造成结果的偏误,使其不具有因果解释。

为了更进一步理解图模型的实际应用,本文将图模型用于北京 PM<sub>2.5</sub> 影响因素的因果研究中。本文详细分析了各个可观测变量对 PM<sub>2.5</sub> 浓度的影响,在此基础上绘制出相应的图模型。对无法直接对 PM<sub>2.5</sub> 浓度产生影响的因素,例如一氧化碳、臭氧和温度等,本文根据图模型的推断准则将其作为控制变量或者工具变量,并观察主要解释变量参数的变化。本文认为,一氧化碳虽然无法直接形成颗粒物从而增加空气中 PM<sub>2.5</sub> 浓度,但在控制二氧化氮后,一氧化碳浓度可以在一定程度上衡量机动车排放与行驶对 PM<sub>2.5</sub> 浓度的直接影响;在之前的文献中,臭氧往往被作为控制变量或者解释变量加入回归方程,通过将温度作为湿度的工具变量,本文认为臭氧对 PM<sub>2.5</sub> 浓度没有直接影响,臭氧与 PM<sub>2.5</sub> 浓度的相关性来源于温度以及湿度与 PM<sub>2.5</sub> 浓度之间不可观测的逆温,但加入工具变量后,二氧化硫的系数发生了较大的变化,说明温度与二氧化硫之间可能存在其他的混杂因子,需要进一步研究,将温度作为工具变量也同样需要慎重。由于风速对 PM<sub>2.5</sub> 浓度的影响系数变化较大,本文在动态因果模型的基础上,分析了更长滞后期下,风速对 PM<sub>2.5</sub> 浓度影响的系数变化,本文认为风速对 PM<sub>2.5</sub> 浓度的影响不是简单的线性过程,风速小时,可能对 PM<sub>2.5</sub> 浓度的增加有促进作用,随着风速增加,促进作用将变成抑制作用,同时风速对 PM<sub>2.5</sub> 浓度影响的时间跨度较长。

最后,本文将 2017 年底北京全面整治燃煤、实现“无煤化”作为燃煤变量的干预或是说 do 因子,二氧化硫系数的值可视为二氧化硫对 PM<sub>2.5</sub> 浓度的直接影响,二氧化硫系数的变化在一定程度上可视为燃煤直接排放对 PM<sub>2.5</sub> 浓度的影响,同时本文根据

2015-2018 年北京 PM<sub>2.5</sub> 浓度的积聚过程分析了北京 PM<sub>2.5</sub> 浓度的变化，本文认为北京 2017 年底北京实现“无煤化”对空气质量有显著改善。

## 参考文献

- Angrist, J. D., & Pischke, J. S. (2009). *Mostly harmless econometrics: An empiricist's companion*. Princeton university press.
- 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.
- Brito, C. (2004). Graphical Models for Identification in Structural Equation Models.
- Cameron, A. C., & Trivedi, P. K. (2005). *Microeconometrics: methods and applications*. Cambridge university press.
- Dahlhaus, R., & Eichler, M. (2003). Causality and graphical models in time series analysis. *Oxford Statistical Science Series*, 115-137.
- Elwert, F. (2013). Graphical causal models. In *Handbook of causal analysis for social research* (pp. 245-273). Springer, Dordrecht.
- Eichler, M., & Didelez, V. (2012). Causal reasoning in graphical time series models. arXiv preprint arXiv:1206.5246.
- Heckman, J. (1974). Shadow prices, market wages, and labor supply. *Econometrica: journal of the econometric society*, 679-694.
- Heckman, J. J. (1978). *Dummy endogenous variables in a simultaneous equation system* (No. w0177). National Bureau of Economic Research.
- Heckman, J. J. (1989). Causal inference and nonrandom samples. *Journal of Educational Statistics*, 14(2), 159-168.
- Heckman, J. J. (2000). Causal parameters and policy analysis in economics: A twentieth century retrospective. *The Quarterly Journal of Economics*, 115(1), 45-97.
- Heckman, J. J. (2008). Econometric causality. *International statistical review*, 76(1), 1-27.
- Heckman, J. J. (2010). Building bridges between structural and program evaluation approaches to evaluating policy. *Journal of Economic literature*, 48(2), 356-98.
- Hernan, Miguel A., & James M. Robins 2020. *Causal Inference: What If*. CRC Press
- Holland, P. W. (1988). Causal inference, path analysis, and recursive structural equation models. *Sociological Methodology*, 18, 449–484.
- Maathuis, M., Drton, M., Lauritzen, S., & Wainwright, M. (2018). *Handbook of graphical models*. CRC Press.
- Morgan, S. L., & Winship, C. (2015). *Counterfactuals and causal inference*. Cambridge University Press.
- Neuberg, L. G. (2003). Causality: models, reasoning, and inference, by judea pearl, cambridge university press, 2000. *Econometric Theory*, 19(4), 675-685.
- Pearl, J. (1995). Causal diagrams for empirical research. *Biometrika*, 82(4), 669-688.
- Pearl, J. (2009). Causal inference in statistics: An overview. *Statistics surveys*, 3, 96-146.

- Pearl, J. (2013). Linear models: A useful “microscope” for causal analysis. *Journal of Causal Inference*, 1(1), 155-170.
- Pearl, J., Glymour, M., & Jewell, N. P. (2016). *Causal inference in statistics: A primer*. John Wiley & Sons.
- Pearl, J. (2017). A linear “microscope” for interventions and counterfactuals. *Journal of Causal Inference*, 5(1).
- Pearl, J., & Mackenzie, D. (2018). *The book of why: the new science of cause and effect*. Basic Books.
- Robins, J. M. (1989). The control of confounding by intermediate variables. *Statistics in Medicine*, 8, 679–701.
- Rosenbaum, P. R. (1984). The consequences of adjustment for a concomitant variable that has been affected by the treatment. *Journal of the Royal Statistical Society, Series A*, 147(5), 656–666.
- Rubin, D. B. (1974). Estimating causal effects of treatments in randomized and nonrandomized studies. *Journal of Educational Psychology*, 66(5), 688.
- Rubin, D. B. (1978). Bayesian inference for causal effects: The role of randomization. *The Annals of Statistics*, 34-58.
- Rubin, D. B. (1986). Which ifs have causal answers; Comment on Holland (1986). *Journal of the American Statistical Association*, 81, 961-962.
- Rubin, D. B. (1990). Formal mode of statistical inference for causal effects. *Journal of statistical planning and inference*, 25(3), 279-292.
- Rubin, D. B. (2004). Direct and indirect causal effects via potential outcomes. *Scandinavian Journal of Statistics*, 31(2), 161-170.
- Smith, H. L. (1990). Specification problems in experimental and nonexperimental social research. *Sociological Methodology*, 20, 59–91.
- Smith, P. W., Berrington, A., & Sturgis, P. (2009). A comparison of graphical models and structural equation models for the analysis of longitudinal survey data. *Methodology of longitudinal surveys*, 381-392.
- Sobel, M. E. (2008). Identification of causal parameters in randomized studies with mediating variables. *Journal of Educational and Behavioral Statistics*, 33(2), 230–251.
- Tian, J., & Pearl, J. (2002, July). A general identification condition for causal effects. In Aaai/iaai (pp. 567-573).
- Wooldridge, J. (2005). Violating ignorability of treatment by controlling for too many factors. *Econometric Theory*, 21, 1026–1028.
- Wooldridge, J. (2006). Acknowledgement of related prior work. *Econometric Theory*, 22, 1177–1178.
- 白志鹏等,《空气颗粒物污染与防治》,化学工业出版社,2011。
- 北京空气质量: <http://zx.bjmemc.com.cn/>;
- 北京市环境保护局,“2017 北京市环境状况公报”,2018。
- 曹军骥等,《PM2.5 与环境》,科学出版社,2014。
- 贺克斌等,《大气颗粒物与区域复合污染》,科学出版社,2011。
- 蒋维楣等,《空气污染气象学教程》,气象出版社,2004。
- 吴兑,《探秘 PM2.5》,气象出版社,2013。
- 中国天气: <http://www.weather.com.cn/air/>

詹姆斯. (2012). H· 斯托克, 马克· W· 沃森. *计量经济学 (第三版)*, 340-341.

赵西亮. (2017). *基本有用的计量经济学*. 北京大学出版社.

## 致谢

时间过的很快，当年初来燕园时的紧张与兴奋历历在目，转瞬三年，如今硕士学业即将结束，将迈向人生的下一个阶段，有憧憬也有很多的不舍。

感谢我的父母，一直以来默默地支持着我的选择，让我没有顾虑地尝试、任性，让我明白了亲人的支持是前进最大的动力。

感谢我的同学们，三年同窗之情将是今生最令人珍重的回忆，道路且长，希望将来能在不同的地方相聚、畅谈。

感谢胡大源老师，这篇论文的写作以及修改过程向我展示他极强的责任心以及一丝不苟的治学态度，在未来的求学、工作生涯中，我将永远铭记这一点。

感谢北京大学的培养，三年的求学生涯，有收获也有遗憾，希望未来能保持积极向上的心态，风雨无阻、砥砺前行。



---

# 北京大学学位论文原创性声明和使用授权说明

## 原创性声明

本人郑重声明：所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已经注明引用的内容外，本论文不含任何其他个人或集体已经发表或撰写过的作品或成果。对本文的研究做出重要贡献的个人和集体，均已在文中以明确方式标明。本声明的法律结果由本人承担。

论文作者签名：                    日期：      年   月   日

## 学位论文使用授权说明

(必须装订在提交学校图书馆的印刷本)

本人完全了解北京大学关于收集、保存、使用学位论文的规定，即：

- 按照学校要求提交学位论文的印刷本和电子版本；
- 学校有权保留学位论文的印刷本和电子版，并提供目录检索与阅览服务，在校园网上提供服务；
- 学校可以采用影印、缩印、数字化或其它复制手段保存论文；
- 因某种特殊原因需要延迟发布学位论文电子版，授权学校一年/两年/三年以后，在校园网上全文发布。

(保密论文在解密后遵守此规定)

论文作者签名：                    导师签名：

日期：      年   月   日