空间滞后分位数回归模型的截面估计法①

李坤明[1]　方丽婷[2]

（1. 福建农林大学经济学院；2. 福州大学经济与管理学院）

研究目标：提出空间滞后分位数回归模型并构建其估计方法。**研究方法**：根据截面估计思想构建模型的估计方法，分别利用数理推导和蒙特卡洛模拟方法得到估计量的大样本性质和估计方法的小样本表现，并通过应用实例考察理论方法的实用性。**研究发现**：利用所构建估计方法得到的估计量具有一致性和渐近正态性，且估计方法在小样本条件下具有良好的估计精度和稳定性，实际应用结果也展示了模型的应用价值。**研究创新**：本文提出的模型不仅考虑了因变量的截面相依性，还能考察自变量对因变量整个条件分布的影响，所构建的估计方法可以避免传统方法中工具变量的选择问题，估计精度更高。**研究价值**：本文构建的理论方法将为分析经济、金融、环境等领域中常见的具有厚尾特征的数据提供强有力的研究工具。

关键词　空间计量　空间滞后模型　分位数回归　截面估计法　碳排放

中图分类号　F064.1　　**文献标识码**　A

引　言

空间依赖性已成为有关溢出效应（Spillovers）、邻近效应（Neighborhood Effects）、外部性（Externalities）、社会互动（Social Interactions）、社会规范（Social Norms）、策略互动（Strategic Interaction）等经济、管理和社会学众多热点研究领域的标准概念。空间计量模型因能处理变量的空间依赖性而受到广泛关注，目前已成为分析空间溢出、空间集聚等空间效应的标准模型，在许多学科领域都有成功的应用。

经过几十年的发展，空间计量在均值回归模型的统计推断方面已取得一系列理论成果（Ord，1975；Anselin，1988；Conley，1999；Kelejian 和 Prucha，1997、1998；Smirnov 和 Anselin，2001；Lee，2002，2004；Elhorst，2003、2005；Yu 等，2008；Lee 和 Yu，2010a、2010b；Moscone 和 Tosetti，2011；Baltagi 等，2013）。不过，均值回归模型是关于条件期望的回归，其描述的是自变量对因变量条件期望的影响，只能反映因变量条件分布的位置信息，不能描述分布的尺度或形状，因而，使用均值回归模型进行实证研究的时候，可能会遗漏掉一些重要的信息，例如当因变量的条件分布呈尖峰、厚尾特征时，尾部信息就显

① 本文获得国家自然科学基金青年项目“非参数空间滞后分位数回归模型的理论与应用研究”（71703025）、教育部人文社会科学研究青年项目“面板数据空间滞后分位数回归模型的理论与应用研究”（17YJC910004）、福建省自然科学基金项目“空间面板平滑转换模型的理论与应用研究”（2016J05172）、福建省社会科学规划项目（青年项目）“空间滞后面板平滑转换模型的贝叶斯估计及其应用研究”（FJ2017C058）、福建省中青年教师教育科研项目“分位数空间计量模型的统计推断及应用研究”（JAS150251）的资助。

得尤其重要，但通过均值回归模型并不能获取此类信息。分位数回归模型可以弥补均值回归模型的上述缺陷，其是关于条件分位数的回归，允许针对响应分布（Response Distribution）的不同分位点分别建模，因而能够得到因变量条件分布的位置、尺度及形状等全方位信息，尤其是能够充分捕捉分布的尾部特征，当分布出现左偏或右偏以及尖峰厚尾现象时，它更加能精确地刻画分布的整体特征；同时，分位数回归模型对异常数据具有耐抗性，对随机误差项也没有严格的要求，因而其估计较为稳健。

虽然分位数回归模型具有诸多优点，但空间分位数回归还是空间计量经济学的一个新的领域，直至最近才开始有研究者将分位数回归技术引入空间计量模型，相关的研究还比较有限。与均值回归模型类似，由于空间滞后项的存在会产生内生性问题，利用传统分位数回归模型的估计方法将不能得到空间分位数回归模型参数的一致估计。Su 和 Yang 是最早关注这一模型的学者，他们在其工作论文 Su 和 Yang（2007）、Su 和 Yang（2011）中提出了空间滞后分位数回归模型，并将 Chernozhukov 和 Hansen（2006）的方法推广到该模型，提出了分位数工具变量回归（IVQR）估计法。

Su 和 Yang（2007）首次将空间计量模型由均值回归拓展到分位数回归领域，Su 和 Yang（2011）则进一步将 Chernozhukov 和 Hansen（2006）的估计方法扩展到具有更一般的空间依赖关系的空间分位数回归模型中。与 Su 和 Yang（2007）不同，Zietz 等（2008）利用 Kim 和 Muller（2004）的方法处理内生性问题，构建了空间滞后分位数回归模型的两阶段分位数回归（2SQR）估计法。Kostov（2013）则建议使用经验似然（Empirical Likelihood，EL）估计法，其研究表明这种估计方法在模型包含多重空间权重矩阵的情况下有较好的效果。此外，戴晓文等（2016）构建了固定效应面板数据空间误差模型的 IVQR 估计法。由于分位数回归模型在信息提取、估计稳健性等方面相对于均值回归模型具有较为明显的优势，空间分位数回归模型的提出也逐渐受到应用研究者的关注，近期有一批文献将此类模型应用到有关农地价格、住房价格、止赎房产、土地价值和环境评价的实证研究中（Kostov，2009；Liao 和 Wang，2012；Zhang 和 Leonard，2014；McMillen，2015；Zhang，2016）。

从上文的文献梳理不难发现，现有相关文献主要采用工具变量法对空间分位数回归模型进行参数估计，此方法在理论上具有诸多优点，但最根本的问题在于合适工具变量的选择，尤其在应用中，有效工具变量的寻找是一件困难的事情。因而有必要寻求一种新的模型估计方法以解决上述难题，这正是本文的研究目标。

根据对空间依赖性的处理方式的不同可以将空间计量模型分为空间滞后模型（Spatial Lag Model）和空间误差模型（Spatial Error Model），前者假定空间依赖关系源于因变量，后者假定空间依赖关系存在于随机误差项当中，空间误差模型实质上可以看作具有特殊异方差结构的传统计量模型，可以转化成空间滞后模型的一种推广形式——空间杜宾模型（Spatial Durbin Model），而且空间误差模型仍然可以通过传统估计方法得到参数的一致估计，可见，在某种意义上空间滞后模型是更为一般的空间模型（Su 和 Yang，2007，2011）。因而，本文选择以空间滞后分位数回归模型作为研究对象。

与现有文献相比，本文的主要贡献在于构建了空间滞后分位数回归模型的一种新的估计方法——截面估计法，此方法与常用的工具变量法不同，截面估计法无须使用工具变量，因而可以有效克服实际应用中经常面临的工具变量选择困难问题。

一、模　型

经典线性参数空间计量模型的数学形式为

$$Y = \lambda WY + X\beta + u, \quad u = \delta Wu + \varepsilon, \quad \varepsilon \sim N(0, \Omega) \tag{1}$$

其中，$Y=(y_1, y_2, \cdots, y_N)'$是$N\times 1$的因变量向量，$X=(x_1, x_2, \cdots, x_N)'$为$N\times P$的外生自变量矩阵，其中$x_i=(x_{i1}, x_{i2}, \cdots, x_{iP})'$，$i=1, \cdots, N$，$W$代表$N\times N$的空间权重矩阵，$\beta$是$P\times 1$的参数向量，$\lambda$和$\delta$分别代表源自因变量和误差项的空间自相关系数，$u=(u_1, u_2, \cdots, u_N)'$和$\varepsilon=(\varepsilon_1, \varepsilon_2, \cdots, \varepsilon_N)'$表示随机误差。在模型（1）中，一般将向量$WY$称为空间滞后项，如果$\lambda\neq 0$，$\delta=0$，则所得模型为空间滞后模型，相反，若$\lambda=0$，$\delta\neq 0$则为空间误差模型。值得一提的是，根据式（1），空间误差模型为：

$$Y = X\beta + (I - \delta W)^{-1}\varepsilon \tag{2}$$

可以进一步简化得到：

$$Y = \delta WY + X\beta - \delta WX\beta + \varepsilon \tag{3}$$

式（3）表示的即空间 Durbin 模型，它实际上是一种特殊的空间滞后模型，这说明空间误差模型可以转化成空间滞后模型。

根据模型（1），线性参数空间滞后模型可表示为如下形式：

$$\begin{gathered} y_i = \lambda d_i + x'_i\beta + \varepsilon_i \\ i = 1, 2, \cdots, N \end{gathered} \tag{4}$$

其中，d_i为空间滞后项WY的第i个元素。空间滞后变量d_i的存在是空间模型与传统计量模型的主要区别，它的引入打破了传统计量模型中截面单元独立或不相关的假设，使得截面依赖成为建模的可能选项，与时间序列模型的时间依赖有异曲同工之处。不过，空间滞后变量的引入同样也带来一些困难，一方面，与时间依赖的单向依赖性不同，空间模型的截面依赖具有多向性，更为复杂，增加了处理难度；另一方面，滞后变量的加入会导致内生性问题，使得传统的估计方法不再适用或不能简单地推广到空间模型。

如果在模型（4）中加入因变量或随机误差项的矩条件，比如常见的一阶矩条件$E(\varepsilon_i \mid X)=0$，$i=1, \cdots, N$，并利用此条件进行估计，则得到的模型为均值回归模型。为了说明这一点，在式（4）两边取关于X的条件期望，并利用一阶矩条件可得：

$$E(y_i - \lambda d_i \mid X) = x'_i\beta + E(\varepsilon_i \mid X) = x'_i\beta \tag{5}$$

式（5）表明我们得到的实际上只是因变量的条件期望的估计，因而称作均值回归模型，此类模型的参数估计值仅能反映自变量对因变量期望值的边际影响，这是在空间计量模型的应用研究中经常采用的分析工具。

受一阶矩条件与均值回归的关系所启发，我们也可以在模型中添加随机误差项的其他分布信息，比如分位数信息，来考察模型的其他特征。例如，如果在模型（4）的基础上增加分位数限制条件：$\Pr(\varepsilon_i\leqslant 0 \mid X)=\tau$，也就是随机误差的$\tau$分位数等于 0 的约束，那么，模型（4）可以转化成如下形式：

$$\Pr[y_i - \lambda d_i - x'_i\beta(\tau) \leqslant 0 \mid X] = \Pr[y_i - \lambda d_i \leqslant x'_i\beta(\tau) \mid X] = \tau \tag{6}$$

很显然，式（6）表明我们所得到的是因变量条件分布的 τ 分位数的估计。因而，对于任意的分位点 τ，参数空间滞后分位数回归模型可表示为：

$$\begin{gathered} y_i = \lambda d_i + x'_i\beta(\tau) + \varepsilon_i \\ i = 1,2,\cdots,N \\ \Pr(\varepsilon_i \leqslant 0 \mid X) = \tau, \quad \forall i \end{gathered} \tag{7}$$

不难发现，理论上，如果让 τ 取遍［0，1］上的所有值，则我们可以得到因变量的整个条件分布的估计。同时，对于每一个给定的 τ，都有一组参数估计值与之对应，也就是通过分位数回归模型我们可以考察自变量对因变量不同分位数的边际影响。因而，分位数回归相对于均值回归具有显著的优势：均值回归模型得到的只是因变量条件分布期望值的估计，而分位数回归模型则可以得到条件分布任意位置（分位数）的估计，均值回归只能考察自变量对因变量期望值的边际影响，分位数回归模型则可以得到自变量对因变量条件分布中任意位置的边际影响。

若令 $\tilde{y}_i = y_i - \lambda d_i$，则模型（7）可进一步简化为

$$\begin{gathered} \tilde{y}_i = x'_i\beta(\tau) + \varepsilon_i \\ i = 1,2,\cdots,N \\ \Pr(\varepsilon_i \leqslant 0 \mid X) = \tau, \quad \forall i \end{gathered} \tag{8}$$

因而，如果 λ 已知，那么模型（8）实际上就是普通的线性分位数回归模型，这一点非常重要，下文中我们正是据此构造模型的估计方法。

二、模型估计方法

根据前文的论述，空间滞后项的存在会带来内生性问题从而导致传统估计方法不再适用于空间分位数回归模型，也就是如果将空间滞后项当作额外变量对待，那么得到的参数估计将是不一致的。因而必须构造新的估计方法。根据上文讨论，如果 λ 已知，则可将 $\tilde{y}_i = y_i - \lambda d_i$ 看作新的因变量，由于消除了空间滞后项，可以用传统的分位数回归模型的估计方法估计参数 $\beta(\tau)$。基于上述思想本文构建了模型（8）的一个新的估计方法——截面估计法，具体步骤如下：

步骤 1：假定 λ 已知，则模型变成式（8）所示的普通线性分位数回归模型，可以通过求解如下最优化问题得到对应于 τ 分位点的参数估计值：

$$\hat{\beta}(\lambda,\tau) = \arg\min_{\beta \in R^P} \sum_{i=1}^{N} \rho_\tau(\tilde{y}_i - x'_i\beta) = \sum_{i=1}^{N} (\tilde{y}_i - x'_i\beta)[\tau - I(\tilde{y}_i - x'_i\beta < 0)] \tag{9}$$

此时得到的估计 $\hat{\beta}(\lambda, \tau)$ 实际上是 λ 的函数。进一步，对于每一给定的（λ，τ），我们都可以得到一个最小化的目标函数值：

$$R(\lambda,\tau) = \sum_{i=1}^{N} \rho_\tau[\tilde{y}_i - x'_i\hat{\beta}(\lambda,\tau)] = \sum_{i=1}^{N} [\tilde{y}_i - x'_i\hat{\beta}(\lambda,\tau)][\tau - I(\tilde{y}_i - x'_i\hat{\beta}(\lambda,\tau) < 0)] \tag{10}$$

步骤 2：选择使式（10）最小的 λ 作为其估计值，即：

$$\hat{\lambda} = \arg\min_{\lambda\in[-1,1]} R(\lambda,\tau)$$

根据模型的设定形式，理论上，对于任意的分位点 τ，λ 的估计值应该一样，但考虑到尾部估计方差较大，在具体估计时我们借鉴 He（1997）的做法，通过中位数回归得到参数 λ 的估计值，即以 τ=0.5 时 λ 的估计作为其估计值，即：

$$\begin{aligned}\hat{\lambda} &= \arg\min_{\lambda\in[-1,1]} R(\lambda,0.5)\\ &= \arg\min_{\lambda\in[-1,1]} \sum_{i-1}^{N}\rho_{0.5}[\tilde{y}_i - x'_i\hat{\beta}(\lambda,0.5)]\\ &= \arg\min_{\lambda\in[-1,1]} \sum_{i-1}^{N}[\tilde{y}_i - x'_i\hat{\beta}(\lambda,0.5)][0.5 - I(\tilde{y}_i - x'_i\hat{\beta}(\lambda,0.5)<0)]\end{aligned} \tag{11}$$

步骤 3：将步骤 2 所得到的 λ 的估计值代入式（9），可以得到 β（τ）的最终估计，即：

$$\begin{aligned}\hat{\beta}(\tau) &= \hat{\beta}(\hat{\lambda},\tau)\\ &= \arg\min_{\beta\in R^P}\sum_{i-1}^{N}\rho_\tau(y_i - \hat{\lambda}d_i - x'_i\beta)\\ &= \arg\min_{\beta\in R^P}\sum_{i-1}^{N}(y_i - \hat{\lambda}d_i - x'_i\beta)[\tau - I(y_i - \hat{\lambda}d_i - x'_i\beta<0)]\end{aligned} \tag{12}$$

三、估计量的渐近性质

为了推导参数估计的渐近性质，我们需要一些假设条件，在此之前，我们先给出几个有用的定义。

定义 1：Q（τ，λ，β）=E［ρ_τ（$\tilde{y}_i - x'_i\beta$）］，Q_N（τ，λ，β）$=n^{-1}\sum_{i=1}^{N}\rho_\tau$（$\tilde{y}_i - x'_i\beta$）。

定义 2：β（λ，τ）$=\arg\min\limits_{\beta} Q$（$\tau$，$\lambda$，$\beta$），$\hat{\beta}$（$\lambda$，$\tau$）$=\arg\min\limits_{\beta} Q_N$（$\tau$，$\lambda$，$\beta$）。

定义 3：$\lambda^*=\arg\min\limits_{\lambda} Q$［$\tau$，$\lambda$，$\beta$（$\lambda$，$\tau$）］，$\hat{\lambda}=\arg\min\limits_{\lambda} Q_N$［$\tau$，$\lambda$，$\beta$（$\lambda$，$\tau$）］。

定义 4：$\hat{\beta}$（τ）$=\hat{\beta}$［$\hat{\lambda}$（τ），τ］，β^*（τ）$=\beta$（λ^*，τ）。

定义 5：Π（λ，β，τ）=E｛［$\tau - I$（$\tilde{y}_i - x'_i\beta$）］X｝。

下面给出推导估计量渐近性质所需的假设条件：

假设 1：$\{x_i\}_{i-1}^{n}$ 为独立随机序列，其分布函数为 F_i，且拥有连续可微的概率密度函数 f_i，其中 $0<f_i<\infty$，且概率密度函数的一阶导数 f'_i 有界。

假设 2：$\forall\tau\in T$，［λ，β（λ，τ）］$\in \mathrm{int}L\times B$，且 $L\times B$ 为凸紧集，其中 T，L，B 分别表示 τ，λ，β（λ，τ）的参数空间。

假设 3：$\dfrac{\partial\,\Pi(\lambda,\beta,\tau)}{\partial(\lambda,\beta)}$ 连续且在 $L\times B$ 上一致满秩，其中 $L\times B$ 是连通集，给定（λ，τ），映射 $\beta\rightarrow\Pi$（λ，β，τ）的像是单连通集；给定 τ，映射 $\lambda\rightarrow\beta$（λ，τ）是 1～1 映射。

假设 4：$\{x_i\}_{i=1}^{n}$ 和 $\{y_i\}_{i=1}^{n}$ 均是有界序列。

假设 5：存在唯一的参数［λ_0，$(\beta_0(\tau))'$］$'$ 使得模型（7）或模型（8）成立。

上述假设条件是模型（7）或模型（8）所需满足的正则条件。其中，假设 1 是分位数回归模型的标准假设，假设 2 和假设 5 保证了模型参数的存在性和唯一性，假设 3 为

模型参数可识别性条件，假设4限定变量都是有界变量。以上假设条件是证明分位数回归模型参数估计大样本性质的常用假设，例如 Koenker 和 Bassett（1978）、Koenker（2005）、Chernozhukov 和 Hansen（2006）、Su 和 Yang（2007，2011）等经典文献中也采用了类似的假设。

在上述假设条件的基础上，我们可以建立模型估计量的一致性和渐近正态性。下面的定理1给出了参数估计量的一致性，定理2则进一步建立参数估计量 $\hat{\beta}(\tau)$ 的渐近正态性①。

定理1：当假设1～5满足时，$[\lambda^*,(\beta^*(\tau))']'$ 等于模型的真实参数，即 $[\lambda^*,(\beta^*(\tau))']'=[\lambda_0,(\beta_0(\tau))']'$，且 $(\hat{\lambda},\hat{\beta}')'\rightarrow_p[\lambda_0,(\beta_0(\tau))']'$，"$\rightarrow_p$"表示依概率收敛。

定理2：当假设1～5满足时，对于任意分位点 τ 都有 $\hat{\beta}(\tau)$ 依分布收敛于正态分布，即 $\sqrt{n}(\hat{\beta}(\tau)-\beta_0(\tau))\rightarrow_F N(0,\Sigma)$，其中 $\Sigma=J_\beta^{-1}S(J_\beta^{-1})'$，$J_\beta=\left.\frac{\partial\Pi(\lambda,\beta,\tau)}{\partial\beta}\right|_{(\lambda,\beta)=[\hat{\lambda}_0,\beta(\hat{\lambda}_0,\tau)]}$，$S=\tau(1-\tau)\mathrm{E}[XX']$，"$\rightarrow_F$"表示依分布收敛。

从理论的角度看，分位数回归模型估计量大样本理论的证明一般是从分位数回归的定义出发，借助分位数回归目标函数的梯度条件或次梯度条件进行推导，本文也采用这种经典的证明思路，对此，Koenker 和 Bassett（1978）、Koenker（2005）和 Chernozhukov 和 Hansen（2006）均有详细讨论。

四、蒙特卡洛模拟

本节将对前面构建的空间滞后分位数回归模型的截面估计法进行蒙特卡洛数值模拟，对模拟结果进行评估，考察所构建的估计方法的小样本表现。对于每个估计量，分别计算了偏差（Bias）和均方根误（Root Mean Squared Error，RMSE），RMSE 的计算方法为：$RMSE=[mcn^{-1}\sum_{i=1}^{mcn}(\hat{\theta}_i-\theta)^2]^{1/2}$，其中 mcn 为模拟次数，$\hat{\theta}_i$，$i=1,\cdots,mcn$ 为每次模拟得到的参数估计值，θ 为参数的真实值。偏差和均方根误可用于测度估计方法的精度和稳健性，绝对值越小，表明估计方法越精确。

1. 数据生成过程

为了考察前文所提出的估计方法在不同模型下的估计效果，我们分别考虑了独立同分布（$i.i.d$）和异方差随机扰动下的数据生成过程。借助模型（4）的表述，$i.i.d$ 随机扰动下的数据生成过程为：

$$y_i=\lambda d_i+\alpha+\beta_1x_{i1}+\beta_2x_{i2}+\varepsilon_i\qquad i=1,2,\cdots,N \tag{13}$$

其中：$\lambda=0.5$，$\alpha=0.5$，$\beta_1=1.5$，$\beta_2=2$，$x_i=(x_{i1},x_{i2})$ 为二维随机变量，每个变量独立产生于均匀分布 $U(-2,2)$ 与标准正态分布 $N(0,1)$ 的混合分布，具体形式为②：

$$x_{ik}=\frac{U(-2,2)}{\sqrt{1-0.7^2}}+\frac{N(0,1)}{1-0.7}\qquad i=1,\cdots,N,\qquad k=1,2\cdots$$

ε_i 为 $i.i.d$ 的随机误差项，为了考察估计方法对随机误差分布的敏感性，我们分别将随

① 由于篇幅所限，文中未给出定理的详细证明过程，如有需要可向作者索取。

② Zhang 和 Shen（2015）、戴晓文等（2016）也采用类似的设定形式。

机误差项的分布设置成标准正态分布 N（0，1）和厚尾对称 t 分布 t（3）。

为了考察空间权重矩阵对估计效果的影响，我们分别将权重矩阵设置成理论和实际应用中常见的 Rook 矩阵和 Case（1991）所提出的权重矩阵（在下文中记为 Case 矩阵）。对于 Rook 矩阵，相邻仅指每一个空间单元和与其成直角关系的空间单元的连接，居中、边界和角落单元分别有四个、三个和两个相邻空间单元。在 Case 矩阵中，假设有 r 个地区，每个地区有 m 个成员，同一地区的成员之间都是“邻居”，并且任意成员之间具有相同权重，从而权重矩阵可表示为 $W=I_r\otimes B_m$，其中 $B_m=(1_m1'_m-I_m)/(m-1)$，1_m 为分量全为 1 的 m 维列向量，I_m 为 $m\times m$ 单位阵。针对 Rook 矩阵，分别取样本数为 $N=100$，400，1600，针对 Case 权重矩阵，分别取（r，m）=（10，10），（10，40），（40，10），（40，40）。

为了考察估计方法在不同分位点下的估计效果，分别取分位点为 $\tau=$（0.25，0.5，0.75），分别作为低分位、中位数和高分位的代表。

需要说明的是，式（13）表示的是位置变化（Location Shift）模型，除了截距项随分位点变化之外，其他自变量的系数在任意分位点下均保持不变。对于任意分位点 τ，容易得到截距项的真实值应为 $\alpha_\tau=F_\varepsilon^{-1}(\tau)$，其中 $F_\varepsilon^{-1}(\tau)$ 表示 ε 的 τ 分位数。

异方差随机扰动下的数据生成过程为：

$$y_i=\lambda d_i+\alpha+\beta_1x_{i1}+\beta_2x_{i2}+\sigma(x_i)\varepsilon_i \qquad i=1,2,\cdots,N \tag{14}$$

其中，扰动项的方差由 x_i 决定，且假设 $\sigma(x_i)=1+0.15x_{i1}+0.15x_{i2}$，其他设定与同方差情形相同。

值得注意的是，式（14）代表的是尺度变化（Scale Shift）模型，对其进行分位数回归实际上得到的是：

$$\begin{aligned}Q_\tau(\tilde{y}\mid x)&=\alpha+\beta_1x_1+\beta_2x_2+(1+0.15x_1+0.15x_2)F_\varepsilon^{-1}(\tau)\\&=[\alpha+F_\varepsilon^{-1}(\tau)]+[\beta_1+0.15F_\varepsilon^{-1}(\tau)]x_1+[\beta_2+0.15F_\varepsilon^{-1}(\tau)]x_2\\&=\alpha_\tau+\beta_{1\tau}x_1+\beta_{2\tau}x_2\end{aligned}$$

易知各参数系数在不同的分位点下并不相同，对于任意给定的分位点 τ，截距项、x_1、x_2 各变量系数的真实值分别为：$\alpha_\tau=\alpha+F_\varepsilon^{-1}(\tau)$，$\beta_{1\tau}=\beta_1+0.15F_\varepsilon^{-1}(\tau)$，$\beta_{2\tau}=\beta_2+0.15F_\varepsilon^{-1}(\tau)$。

2. 模拟结果

针对上文的每个数据生成过程，本文均进行了 1000 次模拟，即取 $mcn=1000$，模拟结果分别报告在表 1～表 4 中，每个表格的上半部分和下半部分报告的分别是空间权重矩阵为 Rook 矩阵和 Case 矩阵时的模拟结果。从表中可以观察到以下结果。首先，整体上，无论误差分布是 N（0，1）还是“厚尾”分布 t（3），本文提出的截面估计法都具有优良的小样本表现，即使样本不大，估计的偏差和均方根误也可以达到较低的水平，而且随着样本量的增加，偏差和均方根误都有明显的下降趋势，这说明截面估计法具有良好的估计精度和稳定性；其次，观察每一表格上下两部分的模拟结果可以发现，两种空间权重矩阵下的参数估计精度并没有太大差别，说明本文的估计方法适用于不同空间依赖方式的空间数据，即对数据的空间结构具有稳健性；同时，对比表 1 和表 3 以及表 2 和表 4 可以发现，当随机误差是 $i.i.d$ 时，参数（α，β_1，β_2）的估计精度明显大于存在条件异方差时，但参数 λ 的估计精度在两种随机误差设定下差别不大；此外，从不同分位点的模拟结果看，无论是在低分位、中

位数还是高分位，估计方法都有良好的表现，估计精度相差无几，这进一步体现了估计方法的稳健性。

表 1　　正态 [N (0, 1)] i. i. d 随机扰动下的模拟结果

样本	均值回归估计		τ=0.25			τ=0.5			τ=0.75		
	系数	RMSE	True	Bias	RMSE	True	Bias	RMSE	True	Bias	RMSE
100	0.497	0.017	0.500	0.004	0.023	0.500	0.004	0.022	0.500	0.004	0.023
	0.495	0.113	0.175	0.007	0.144	0.500	0.006	0.132	1.175	0.014	0.137
	1.499	0.027	1.500	0.000	0.038	1.500	0.002	0.034	1.500	0.000	0.038
	2.002	0.026	2.000	0.004	0.038	2.000	0.000	0.036	2.000	0.002	0.040
400	0.498	0.009	0.500	0.004	0.012	0.500	0.004	0.011	0.500	0.004	0.012
	0.500	0.044	0.175	0.003	0.070	0.500	0.005	0.064	1.175	0.007	0.070
	1.500	0.016	1.500	0.001	0.018	1.500	0.001	0.017	1.500	0.002	0.019
	2.000	0.014	2.000	−0.001	0.019	2.000	−0.002	0.017	2.000	−0.002	0.019
1600	0.501	0.004	0.500	0.005	0.007	0.500	0.004	0.007	0.500	0.005	0.007
	0.498	0.025	−0.175	−0.003	0.034	0.500	−0.005	0.033	1.175	−0.004	0.034
	1.500	0.006	1.500	−0.001	0.009	1.500	−0.001	0.009	1.500	−0.001	0.009
	1.999	0.007	2.000	−0.001	0.009	2.000	−0.002	0.009	2.000	−0.001	0.009
(10, 10)	0.501	0.020	0.500	0.003	0.025	0.500	0.002	0.026	0.500	0.003	0.025
	0.505	0.117	−0.175	0.006	0.144	0.500	−0.005	0.139	1.175	−0.014	0.138
	1.500	0.028	1.500	−0.001	0.040	1.500	0.000	0.035	1.500	−0.002	0.038
	1.999	0.028	2.000	−0.001	0.038	2.000	−0.001	0.034	2.000	−0.001	0.039
(10, 40)	0.496	0.022	0.500	0.002	0.025	0.500	0.002	0.026	0.500	0.002	0.025
	0.510	0.062	−0.175	0.004	0.075	0.500	0.003	0.071	1.175	−0.006	0.073
	1.500	0.014	1.500	0.000	0.019	1.500	0.000	0.018	1.500	0.001	0.019
	2.000	0.013	2.000	0.001	0.019	2.000	0.000	0.017	2.000	0.000	0.019
(40, 10)	0.501	0.008	0.500	0.003	0.011	0.500	0.003	0.012	0.500	0.003	0.011
	0.496	0.052	−0.175	0.002	0.069	0.500	−0.001	0.066	1.175	−0.006	0.069
	1.500	0.014	1.500	0.000	0.019	1.500	0.000	0.017	1.500	0.000	0.018
	1.999	0.014	2.000	−0.001	0.019	2.000	−0.001	0.017	2.000	0.000	0.018
(40, 40)	0.500	0.009	0.500	0.003	0.012	0.500	0.002	0.012	0.500	0.003	0.012
	0.500	0.032	−0.175	−0.002	0.035	0.500	−0.003	0.034	1.175	−0.002	0.036
	1.501	0.007	1.500	0.000	0.009	1.500	0.000	0.008	1.500	0.000	0.009
	2.001	0.006	2.000	0.000	0.009	2.000	−0.001	0.009	2.000	0.000	0.009

为了便于比较，我们也针对各种数据生成过程估计了均值回归模型，模型参数估计的均值和均方根误分别由表 1～表 4 中的第 2 列和第 3 列给出。对比均值回归模型和分位数回归模型的模拟结果可以发现。首先，均值回归模型的系数估计与分位数模型的中位数系数估计结果非常接近，说明在因变量的条件分布是对称分布的条件下，中位数回归可以充分揭示均值回归所包含的信息；其次，当随机扰动是 $i.i.d$ 时，均值回归系数的均方根误与中位数回归系数相当靠近，而当随机扰动存在异方差时，均值回归系数的均方根误则明显大于中位数

回归系数，这说明分位数回归估计相比均值回归具有更强的稳健性；最后，从分位数模型的估计结果可以看出，不同分位点的系数估计存在明显差异，说明自变量对因变量条件分布的不同位置的影响是不同的，这部分信息是均值回归所不能得到的。所以，总的来看，数值模拟结果直观体现了分位数回归模型的优势。

表 2 厚尾［*t*（3)］*i. i. d* 随机扰动下的模拟结果

样本	均值回归估计		τ=0.25			τ=0.5			τ=0.75		
	系数	RMSE	True	Bias	RMSE	True	Bias	RMSE	True	Bias	RMSE
100	0.499	0.022	0.500	0.005	0.025	0.500	0.006	0.024	0.500	0.006	0.024
	0.537	0.178	−0.265	−0.007	0.172	0.500	0.000	0.149	1.265	0.001	0.186
	1.496	0.046	1.500	−0.002	0.048	1.500	−0.003	0.039	1.500	−0.003	0.048
	2.004	0.054	2.000	−0.003	0.048	2.000	−0.002	0.039	2.000	−0.001	0.048
400	0.498	0.014	0.500	0.006	0.014	0.500	0.006	0.013	0.500	0.006	0.014
	0.497	0.088	−0.265	−0.007	0.089	0.500	−0.007	0.069	1.265	−0.004	0.087
	1.502	0.024	1.500	−0.003	0.024	1.500	−0.002	0.019	1.500	−0.001	0.024
	2.006	0.023	2.000	−0.001	0.025	2.000	−0.001	0.019	2.000	−0.002	0.024
1600	0.500	0.008	0.500	0.007	0.009	0.500	0.006	0.009	0.500	0.007	0.009
	0.499	0.045	−0.265	−0.009	0.043	0.500	−0.008	0.035	1.265	−0.008	0.043
	1.499	0.013	1.500	−0.002	0.012	1.500	−0.001	0.009	1.500	−0.001	0.011
	1.999	0.011	2.000	−0.002	0.012	2.000	−0.002	0.009	2.000	−0.002	0.012
（10，10）	0.493	0.041	0.500	0.003	0.029	0.500	0.003	0.028	0.500	0.006	0.027
	0.503	0.178	−0.265	0.000	0.186	0.500	0.000	0.151	1.265	0.003	0.185
	1.502	0.044	1.500	−0.002	0.049	1.500	−0.001	0.039	1.500	−0.002	0.047
	1.990	0.051	2.000	0.000	0.048	2.000	−0.001	0.041	2.000	−0.002	0.049
（10，40）	0.493	0.035	0.500	0.002	0.027	0.500	0.004	0.028	0.500	0.002	0.028
	0.508	0.090	−0.265	0.003	0.093	0.500	−0.002	0.076	1.265	0.003	0.092
	1.501	0.023	1.500	0.000	0.024	1.500	−0.001	0.019	1.500	0.000	0.024
	2.004	0.024	2.000	0.001	0.023	2.000	0.000	0.019	2.000	0.000	0.023
（40，10）	0.497	0.017	0.500	0.004	0.012	0.500	0.004	0.013	0.500	0.004	0.013
	0.505	0.082	−0.265	−0.003	0.087	0.500	−0.008	0.070	1.265	−0.003	0.085
	1.502	0.022	1.500	−0.002	0.022	1.500	−0.002	0.020	1.500	0.000	0.023
	1.997	0.022	2.000	−0.001	0.023	2.000	0.000	0.019	2.000	0.000	0.023
（40，40）	0.502	0.013	0.500	0.003	0.013	0.500	0.004	0.012	0.500	0.004	0.013
	0.497	0.042	−0.265	−0.006	0.045	0.500	−0.006	0.038	1.265	−0.004	0.045
	1.499	0.012	1.500	−0.001	0.011	1.500	0.000	0.009	1.500	0.000	0.012
	2.001	0.012	2.000	0.000	0.011	2.000	0.000	0.010	2.000	0.000	0.011

表 3 正态条件异方差随机扰动下的模拟结果

样本	均值回归估计		τ=0.25			τ=0.5			τ=0.75		
	系数	RMSE	True	Bias	RMSE	True	Bias	RMSE	True	Bias	RMSE
100	0.499	0.022	0.500	0.002	0.014	0.500	0.002	0.014	0.500	0.003	0.014
	0.491	0.142	−0.175	0.005	0.165	0.500	−0.002	0.147	1.175	−0.006	0.168
	1.500	0.047	1.399	0.028	0.046	1.500	−0.001	0.030	1.601	−0.030	0.047
	1.995	0.041	1.899	0.029	0.046	2.000	−0.001	0.030	2.101	−0.030	0.048
400	0.501	0.013	0.500	0.003	0.006	0.500	0.003	0.006	0.500	0.003	0.006
	0.507	0.069	−0.175	0.005	0.083	0.500	−0.007	0.075	1.175	−0.008	0.077
	1.499	0.023	1.399	0.026	0.031	1.500	−0.001	0.014	1.601	−0.027	0.032
	2.002	0.022	1.899	0.026	0.032	2.000	−0.001	0.014	2.101	−0.027	0.032
1600	0.500	0.004	0.500	0.002	0.003	0.500	0.002	0.003	0.500	0.002	0.003
	0.496	0.034	−0.175	0.002	0.041	0.500	−0.001	0.037	1.175	−0.010	0.041
	1.501	0.010	1.399	0.025	0.026	1.500	0.000	0.007	1.601	−0.026	0.027
	1.997	0.012	1.899	0.024	0.026	2.000	−0.001	0.007	2.101	−0.026	0.028
(10，10)	0.496	0.029	0.500	0.002	0.017	0.500	0.001	0.016	0.500	0.001	0.016
	0.494	0.140	−0.175	0.003	0.167	0.500	0.001	0.146	1.175	−0.001	0.166
	1.498	0.044	1.399	0.029	0.046	1.500	0.001	0.029	1.601	−0.030	0.046
	1.995	0.044	1.899	0.029	0.046	2.000	0.000	0.030	2.101	−0.029	0.045
(10，40)	0.493	0.029	0.500	0.001	0.013	0.500	0.001	0.014	0.500	0.001	0.013
	0.503	0.069	−0.175	0.005	0.084	0.500	−0.005	0.074	1.175	−0.009	0.086
	1.499	0.019	1.399	0.026	0.031	1.500	−0.001	0.014	1.601	−0.027	0.032
	1.997	0.017	1.899	0.025	0.031	2.000	−0.001	0.014	2.101	−0.027	0.032
(40，10)	0.500	0.010	0.500	0.002	0.006	0.500	0.002	0.006	0.500	0.002	0.006
	0.502	0.062	−0.175	−0.002	0.085	0.500	−0.006	0.073	1.175	−0.008	0.080
	1.498	0.019	1.399	0.024	0.030	1.500	−0.001	0.013	1.601	−0.027	0.032
	2.004	0.020	1.899	0.025	0.030	2.000	−0.001	0.014	2.101	−0.027	0.032
(40，40)	0.500	0.012	0.500	0.001	0.005	0.500	0.001	0.005	0.500	0.001	0.005
	0.492	0.036	−0.175	0.004	0.041	0.500	−0.001	0.037	1.175	−0.008	0.041
	1.497	0.009	1.399	0.025	0.026	1.500	0.000	0.007	1.601	−0.026	0.027
	1.999	0.011	1.899	0.025	0.026	2.000	0.000	0.006	2.101	−0.025	0.026

表 4　　厚尾异方差随机扰动下的模拟结果

样本	均值回归估计		τ=0.25			τ=0.5			τ=0.75		
	系数	RMSE	True	Bias	RMSE	True	Bias	RMSE	True	Bias	RMSE
100	0.491	0.036	0.500	0.005	0.018	0.500	0.005	0.017	0.500	0.004	0.016
	0.520	0.239	−0.265	−0.016	0.213	0.500	−0.005	0.160	1.265	0.008	0.206
	1.505	0.073	1.385	0.031	0.055	1.500	0.001	0.034	1.615	−0.034	0.056
	2.006	0.075	1.885	0.031	0.054	2.000	−0.003	0.033	2.115	−0.036	0.058
400	0.498	0.019	0.500	0.003	0.007	0.500	0.004	0.007	0.500	0.004	0.008
	0.512	0.121	−0.265	0.003	0.100	0.500	−0.008	0.083	1.265	0.000	0.100
	1.502	0.034	1.385	0.031	0.038	1.500	−0.001	0.016	1.615	−0.031	0.038
	2.008	0.036	1.885	0.030	0.037	2.000	−0.002	0.016	2.115	−0.032	0.039
1600	0.500	0.010	0.500	0.003	0.004	0.500	0.003	0.004	0.500	0.003	0.004
	0.487	0.053	−0.265	0.002	0.049	0.500	−0.003	0.039	1.265	−0.004	0.050
	1.496	0.017	1.385	0.030	0.032	1.500	−0.001	0.007	1.615	−0.031	0.033
	1.995	0.018	1.885	0.029	0.031	2.000	−0.001	0.007	2.115	−0.030	0.032
(10，10)	0.493	0.040	0.500	0.002	0.019	0.500	0.001	0.018	0.500	0.002	0.019
	0.493	0.224	−0.265	−0.015	0.217	0.500	0.001	0.165	1.265	0.002	0.209
	1.491	0.073	1.385	0.033	0.057	1.500	−0.001	0.035	1.615	−0.037	0.058
	1.994	0.067	1.885	0.032	0.054	2.000	0.001	0.033	2.115	−0.034	0.057
(10，40)	0.495	0.042	0.500	0.002	0.015	0.500	0.002	0.014	0.500	0.003	0.007
	0.496	0.134	−0.265	−0.004	0.106	0.500	−0.001	0.077	1.265	−0.002	0.099
	1.502	0.035	1.385	0.030	0.037	1.500	0.000	0.014	1.615	−0.031	0.038
	1.999	0.035	1.885	0.030	0.037	2.000	0.000	0.014	2.115	−0.031	0.038
(40，10)	0.498	0.017	0.500	0.002	0.006	0.500	0.002	0.006	0.500	0.001	0.014
	0.512	0.116	−0.265	−0.001	0.096	0.500	−0.006	0.081	1.265	0.002	0.099
	1.501	0.032	1.385	0.030	0.037	1.500	−0.001	0.015	1.615	−0.031	0.038
	1.998	0.032	1.885	0.031	0.038	2.000	−0.001	0.015	2.115	−0.031	0.037
(40，40)	0.498	0.020	0.500	0.002	0.006	0.500	0.002	0.005	0.500	0.002	0.005
	0.494	0.066	−0.265	0.002	0.049	0.500	−0.001	0.041	1.265	−0.008	0.050
	1.499	0.015	1.385	0.030	0.032	1.500	0.000	0.007	1.615	−0.030	0.032
	1.998	0.016	1.885	0.030	0.032	2.000	0.000	0.007	2.115	−0.030	0.032

五、应用研究实例

由于对气候、环境和经济都有重要影响，碳排放问题是学术界经久不衰的一个研究话题，其中，碳排放的驱动机制是已有相关文献所关注的焦点（如 York 等，2003；Cole， 2004；Liddle 和 Lung，2010；Liddle，2011；李国志和李宗植，2010；马晓钰等，2013；方齐云和陶守来，2017）。不过，现有文献大部分以均值回归模型作为研究方法，正如前文所述，均值回归只能反映驱动因素对碳排放的平均影响，但是我们更加关心的是那些碳排放较为严重的地区的碳排放驱动机制，这是均值回归模型无法解决的，而分位数回归模型可以通过尾部参数估计方便地识别此类信息。基于此，本文利用前文所构建的空间分位数回归模型重新检验中国碳排放驱动机制，以该模型作为分析工具的优点除了可以获得尾部信息之外，还能控制被很多研究所证实的碳排放的空间依赖关系，因而估计结果可能更加稳健。

1. 实证分析框架

在评估人类活动的环境影响方面，Ehrlich 和 Holdren（1972）以及 Commoner（1971）所提出的 IPAT（Impacts，Population，Affluence，Technology）恒等式是一个被广泛认可的方法，其在实际应用中经常被作为分析环境变化驱动因素的理论框架。IPAT 等式将人类活动的环境影响（I）设定为人口规模（P）、人均财富（A）和技术水平（T）三个因素的乘积，也就是

$$I = PAT \tag{15}$$

Dietz 和 Rosa（1994）将 IPAT 等式转换成随机形式，提出了 STIRPAT（Stochastic Impacts by Regression on Population，Affluence，and Technology）模型，其数学表达式如下

$$I = aP^bA^cT^de \tag{16}$$

式中 a、b、c、d 是待估系数，e 代表随机扰动项。很明显，如果对式（16）两边的变量取对数形式，将会得到一个多元线性回归模型：

$$\ln I = \alpha + \beta\ln P + \gamma\ln A + \theta\ln T + \ln e \tag{17}$$

其中 β、λ 和 θ 分别代表人口、财富和技术三种因素对环境影响的弹性系数，即生态弹性（York 等，2003）。需要说明的是，在实际应用中，由于影响环境的技术因素众多，很难找到合适的代理变量，所以很多文献直接将技术因素归入扰动项，转而估计如下模型：

$$\ln I = \alpha + \beta\ln P + \gamma\ln A + \xi \tag{18}$$

York 等（2003）认为既然技术水平包括影响单位产出环境效应（Impact per Unit of Production）的任何因素，所以只要不违背 IPAT 等式的乘积原则（即 T 可以表示成其影响因素的乘积），就可以通过对技术因素 T 的分解将影响技术水平的任意变量加入模型（18）中。也就是说，我们可以根据实际需要将需要控制的人口、财富之外的变量加入回归模型中，只要这些额外变量能够被概念化为技术乘数的组成部分。

2. 实证模型设定

本文的实证研究将基于上述 STIRPAT 分析框架，对应于 IPAT 等式，I 为碳排放（CO_2），考虑到有些研究发现财富水平对环境存在非线性影响，如环境库兹涅茨效应，所以，我们也将此变量的二次项作为主要变量纳入模型中，同时，根据 York 等（2003）的思想，我们还将人口结构、经济结构等影响技术的变量作为控制变量加入模型，将基本实证模型设定为如下形式：

$$\ln CO2_{it} = \alpha_1 \ln POP_{it} + \alpha_2 \ln PGDP_{it} + \alpha_3 (\ln PGDP_{it})^2 + \beta' Control_{it} + u_i + \varepsilon_{it} \tag{19}$$

其中下标 i，t 分别表示省份和时间，$CO2$ 为二氧化碳排放量，POP 为人口规模，$PGDP$ 为人均 GDP，代表人均财富水平，$Control_{it}$ 是控制变量，u_i 为不可观测的个体效应，ε_{it} 为随机误差项。

为了控制碳排放的空间相关性，同时捕捉碳排放机制的差异性，我们在基本模型的基础上进一步建立如下空间分位数回归模型：

$$\begin{aligned} \ln CO2_{it} &= \rho\sum_{j=1}^{N} W_{ij}\ln CO2_{jt} + \alpha_1(\tau)\ln POP_{it} + \alpha_2(\tau)\ln PGDP_{it} \\ &\quad + \alpha_3(\tau)(\ln PGDP_{it})^2 + \beta'(\tau)Control_{it} + u_i(\tau) + \varepsilon_{it} \\ \Pr(\varepsilon_i &\leqslant 0 \mid X) = \tau, \forall i \end{aligned} \tag{20}$$

式中 ρ 为空间相关系数，W_{ij} 为空间权重矩阵 W 的第（i，j）元素。结合本文所研究的问题，我们选取二元邻接矩阵作为空间权重矩阵，也就是如果两个地区具有共同边界，则两者相对对方的权重都设置为 1，否则为 0。在进行模型估计时，为了使得参数估计值具有良好的统计性质，一般需要对空间权重矩阵进行标准化处理，本文采用行标准化。

3. 变量选取及测度

由于没有公开的碳排放数据，我们参照林伯强和刘希颖（2010）的计算方法测算历年各省份二氧化碳排放量，以此测度碳排放指标。同时，本文遵循大部分文献的做法，选取人均 GDP（PGDP）度量财富 A，以各省份的年底常住人口总数衡量人口规模（POP）。以上三个变量构成 STIRPAT 分析框架的核心变量，同时，考虑到有大量文献发现了环境库兹涅茨现象的存在（如 York 等，2003），我们也将人均财富的平方项纳入模型中，除此之外，人口结构、产业结构、外商投资、能源消费结构等因素也已被相关文献证实可能通过影响技术水平进而影响碳排放，有必要将这些因素作为控制变量加入实证模型中，我们最终选择的控制变量及其测度方法如下：

（1）人口城乡结构（URB）：以人口城镇化率测度，即城镇人口占总人口的比重。

（2）工业结构（INS）：用工业增加值与 GDP 的比值进行测度。

（3）外商直接投资（FDI）：以实际利用外资金额与 GDP 的比值测度。

（4）能源消费结构（ENS）：采用煤炭消费占能源总消费的比重作为测度指标。

值得注意的是，正如上文所述，在 STIRPAT 模型框架下，控制变量是被当作技术乘数的组成部分而加入模型的，也就是假设技术可以表示成控制变量的乘积形式，因而根据式(17)，控制变量一般要以对数形式进入实证模型，只有这样才能保持 STIRPAT 模型假设的逻辑一致性，这一点在 York 等（2003）中有详细的讨论。本文所用控制变量均为比例变量，STIRPAT 模型框架要求将比例变量以对数形式纳入实证模型，因而控制变量系数估计值的解释需要特别注意，它表示的是弹性，即比例变量变化 1%所带来的碳排放量的百分比变化，以城镇化率为例，假设其系数估计值为 1.2，假如现在的城镇化率为 50%，则该系数的含义应该是当城镇化率从 50%增加到 50.5%（即增长 1%）时将导致碳排放量增长 1.2%（1.2 乘以 1%），York 等（2003）也将比例变量的对数形式纳入实证模型，其对估计系数的解释与本文类似。

基于数据的可获得性和统计指标的一致性问题的考虑，本文以 2001～2015 年全国省级面板数据作为样本，西藏地区由于数据缺失较为严重予以剔除，所用统计指标的原始数据分别来自历年各省份统计年鉴和《中国环境年鉴》《中国能源统计年鉴》《新中国 60

年统计资料汇编》《中国统计年鉴》和《中国人口统计年鉴》。为了与 STIRPAT 模型的假设保持一致，在实证研究中本文对所有变量进行对数化处理，主要变量的描述性统计见表 5。

表 5　　主要变量的描述性统计

变量	样本量	均值	中位数	标准差	最小值	最大值
ln*CO2*	450	10.010	10.036	0.820	6.919	11.795
ln*PGDP*	450	9.983	10.041	0.777	8.006	11.590
ln*POP*	450	8.152	8.247	0.758	6.260	9.292
ln*URB*	450	3.857	3.844	0.290	3.198	4.495
ln*INS*	450	3.649	3.717	0.241	2.574	3.971
ln*FDI*	450	0.597	0.725	0.996	−2.684	2.684
ln*ENS*	450	4.147	4.210	0.287	2.617	4.547

4. 模型估计结果

我们接着利用上文的估计方法对实证模型（20）进行参数估计，并根据上文的结论对参数进行假设检验，同时，为了进行比较，我们还估计了空间面板均值回归模型，参数估计结果在表 6 中给出。其中，ln*PGDP2* 表示人均 GDP 对数值的平方。需要注意的是，由于所有变量均取对数形式，因而自变量的系数估计值实际上代表的是弹性系数。

表 6　　均值回归与分位数回归模型参数估计结果

变量	均值回归模型参数估计	分位数回归模型主要分位点参数估计				
		Q05	Q25	Q50	Q75	Q95
ln*PGDP*	1.486***	1.860**	1.853***	0.834*	0.053	−0.023
	(0.357)	(0.723)	(0.582)	(0.492)	(0.450)	(0.472)
ln*PGDP2*	−0.053***	−0.078**	−0.077***	−0.024	0.017	0.022
	(0.017)	(0.035)	(0.029)	(0.026)	(0.023)	(0.024)
ln*POP*	0.667***	1.323***	1.128***	0.660**	0.294	0.023
	(0.192)	(0.338)	(0.251)	(0.257)	(0.232)	(0.259)
ln*URB*	0.176	0.483*	0.519**	0.467*	0.357*	0.365*
	(0.156)	(0.292)	(0.207)	(0.266)	(0.210)	(0.187)
ln*INS*	0.380***	0.500***	0.422***	0.417***	0.410***	0.279***
	(0.068)	(0.137)	(0.096)	(0.094)	(0.083)	(0.102)
ln*FDI*	−0.065***	−0.026	−0.043*	−0.072***	−0.062***	−0.052***
	(0.015)	(0.024)	(0.023)	(0.021)	(0.018)	(0.015)
ln*ENS*	0.012	0.277	0.345**	0.332***	0.244**	0.274***
	(0.062)	(0.234)	(0.149)	(0.126)	(0.111)	(0.091)
ρ	0.093*	0.085*	0.085*	0.085*	0.085*	0.085*
	(0.055)	(0.052)	(0.050)	(0.051)	(0.051)	(0.052)

注：括号中报告的是标准差，“***”、“**”、“*”分别表示 0.01、0.05、0.1 的显著水平。其中，分位数回归模型中的 ρ 采用 Bootstrap 方法进行检验。

从均值回归模型和分位数回归模型的估计结果可以看出，空间相关系数 ρ 在两种模型中均显著不为 0，说明不能忽略碳排放的空间相关性，以空间模型作为分析工具是更稳健的做法。均值回归模型其他参数的估计结果显示。首先，人均财富的一次项系数估计值显著为正，二次项的估计值显著为负，说明碳排放存在显著的库兹涅茨效应，即人均财富与碳排放之间存在倒“U”形曲线关系，这与 York 等（2003）、郑丽琳和朱启贵（2012）的研究结论相似，不过，从估计结果看，倒“U”形曲线的拐点较大，说明现阶段我国碳排放仍延续随着人均财富的增长而增长的态势。其次，人口规模的增长对碳排放具有显著的正向推动作用，这与大部分文献的结论一致，从数值上看，人口规模的系数估计值小于 1，说明人口增长对碳排放的正向影响是缺乏弹性的，也就是人口增长并不会带来碳排放的等比例增长，这与 Liddle 和 Lung（2010）、李国志和李宗植（2010）的结论相同。最后，从控制变量看，城镇化率和能源消费结构对碳排放的影响虽然是正的，但在统计上不显著，Liddle 和 Lung（2010）、Sadorsky（2014）也得到类似的结论，其含义是城镇化的推进和煤炭消费比例的下降虽然分别可以导致碳排放的增加和抑制碳排放，但这种影响效应比较微弱；此外，工业结构和 FDI 对碳排放则分别具有显著的正向和负向影响，工业结构的正向影响不难理解，因为工业碳排放是碳排放的主要来源，而 FDI 的负向影响可能是由于外资的引入带来了先进的生产技术，有利于节能降耗进而提高能源效率，而且这种积极影响要大于外资进入引致的经济规模扩张对碳排放的不利影响，林伯强和刘泓汛（2015）也得到类似结果。

均值回归模型得到的结论与现有文献的结论基本相符，不过，正如前文所述，均值回归只能从平均意义上考察潜在驱动因素对碳排放的影响，而这种影响是否因碳排放强度的不同而发生变化？即对于不同碳排放状况的地区，其碳排放驱动机制是否存在差异？此类问题无法通过均值回归模型进行考察。分位数回归模型则很好地解决了这一问题。

总的来看，比较表 6 中均值回归与分位数回归结果不难发现，均值回归系数与中位数回归系数存在较大差别，说明本例中碳排放的分布是非对称的，所以仅用均值回归得到的信息并不能很好地刻画碳排放的驱动机制，采用分位数回归可以得到更多更有价值的信息。

从表 6 中可以看到，不同分位点的参数估计结果存在明显差异，这说明对于不同碳排放强度的地区其碳排放驱动机制可能并不相同。分位数回归结果显示：首先，人均财富和人口对碳排放的影响只在碳排放较少（较低分位）的地区显著，影响的大小都呈现随分位点增高而下降的趋势，而且碳排放的库兹涅茨现象也仅在较低碳排放（低分位）的地区存在；其次，城镇化率和能源消费结构在各分位点对碳排放均存在显著的正向影响，但在高分位的影响要略小于低分位，这一结果与均值回归差异较大；再次，工业结构对碳排放具有显著的推动作用，但是这种推动作用的强度随着分位数的增加而下降；最后，分位数回归结果还表明 FDI 对碳排放的负向影响在不同的分位点上也不一致，呈现对碳排放分布两端的影响大、中间影响较小的特点。

相比均值回归模型，由于保留了更多分布信息，分位数回归模型所揭示的政策含义也更为详细和直观。比如在本例中，分位数回归结果显示人均财富和人口两种规模因素对碳排放的影响在高碳排放地区并不显著，而城镇化率、工业结构、外商直接投资、能源消费结构等结构因素对碳排放的影响在所有地区都十分显著，这说明在高碳排放地区，碳排放的主要驱动因素是结构性因素而非规模因素，因而有关部门在制定政策的时候应该更注重结构调整而非规模限制。

六、结　　论

空间分位数回归模型是空间计量经济学的一个新领域，与均值回归模型类似，解决内生性问题是估计此类模型的关键。Chernozhukov 和 Hansen（2006）提出的IVQR法是处理内生性问题的常用方法，但工具变量的选择问题成为此方法在应用中面临的最大困难。针对上述困难，本文提出一种新的解决方法，即截面估计法，该方法的特点是不需要借助工具变量，因而在具体应用中具有更大的可行性。本文构建了上述估计方法的具体实施步骤，并证明了估计量的一致性和渐近正态性等大样本性质，同时，通过蒙特卡洛数值模拟发现所提出的估计方法在小样本条件下具有良好的估计精度和稳定性，对于不同的随机误差、空间权重矩阵和不同的分位点，估计方法的估计精度不会受到太大的影响。此外，我们还将所提出的理论方法应用于对我国碳排放驱动因素的实证研究中，分位数回归模型的估计结果揭示了均值回归模型所无法获取的很多信息，展示了其应用价值。

参考文献

[1] Anselin L., 1988, *Spatial Econometrics: Methods and Models* [M], Boston: Kluwer.

[2] Baltagi B., Egger P., Pfaffermayr, M., 2013, *A Generalized Spatial Panel Data Model with Random Effects* [J], Econometric Reviews, 32 (5～6), 650～685.

[3] Chernozhukov V., Hansen C., 2006, *Instrumental Quantile Regression Inference for Structural and Treatment Effect Models* [J], Journal of Econometrics, 132 (2), 491～525.

[4] Cole M., 2004, *Trade, the Pollution Haven Hypothesis and the Environmental Kuznets Curve: Examining the Linkages* [J], Ecological Economics, 48 (1), 71～81.

[5] Conley T. G., 1999, *GMM Estimation with Cross-Sectional Dependence* [J], Journal of Econometrics, 92 (1), 1～45.

[6] Commoner B., 1971, *The Closing Circle* [M], New York: Knopf.

[7] Dietz T., Rosa E., 1994, *Rethinking the Environmental Impacts of Population, Affluence and Technology* [J], Human Ecology Review, 1 (2), 277～300.

[8] Ehrlich P., Holdren J., 1972, *A Bulletin Dialogue on the "Closing Circle" Critique: One Dimensional Ecology* [J], Bulletin of the Atomic Scientists, 28 (5), 16～27.

[9] Elhorst J., 2003, *Specification and Estimation of Spatial Panel Data Models* [J], International Regional Science Review, 26 (3), 244～268.

[10] Elhorst J., 2005, *Unconditional Maximum Likelihood Estimation of Linear and Log-Linear Dynamic Models for Spatial Panels* [J], Geographical Analysis, 37 (1), 85～106.

[11] He X., 1997, *Quantile Curves without Crossing* [J], The American Statistician, 51 (2), 186～192.

[12] Kelejian H., Prucha I., 1997, *Estimation of Spatial Regression Models with Autoregressive Errors by Two-stage Least Squares Procedures: A Serious Problem* [J], International Regional Science Review, 20 (1), 103～111.

[13] Kelejian H., Prucha I., 1998, *A Generalized Spatial two Stage Least Squares Procedure for Estimating a Spatial Autoregressive Model with Autoregressive Disturbances* [J], Journal of Real Estate Finance and Economics, 17 (1), 99～121.

[14] Kim T., Muller C., 2004, *Double-Stage Quantile Regressions* [J], Econometrica, 7 (1), 218～231.

[15] Koenker R., 2005, *Quantile Regression* [M], Cambridge: Cambridge University Press.

[16] Koenker R., Bassett G., 1978, *Regression Quantiles* [J], Econometrica, 46 (1), 33～50.

[17] Kostov P., 2009, *A Spatial Quantile Regression Hedonic Model of Agricultural Land Prices* [J], Spatial Economic Analysis, 4 (1), 53～72.

[18] Kostov P., 2013, *Empirical Likelihood Estimation of the Spatial Quantile Regression* [J], Journal of Geographical Systems, 15 (1), 51～69.

[19] Lee L., 2002, *Consistency and Efficiency of Least Squares Estimation for Mixed Regressive Spatial Autoregressive Models* [J], Econometric Theory, 18 (2), 252～277.

[20] Lee L., 2004, *Asymptotic Distributions of Quasi-Maximum Likelihood Estimators for Spatial Autoregressive Models* [J], Econometrica, 72 (6), 1899～1925.

[21] Lee L., Yu J., 2010a, *Estimation of Spatial Autoregressive Panel Data Models with Fixed Effects* [J], Journal of Econometrics, 154 (2), 165～185.

[22] Lee L., Yu J., 2010b, *Some Recent Developments in Spatial Panel Data Models* [J], Regional Science and Urban Economics, 40 (5), 255～271.

[23] Liao W., Wang X., 2012, *Hedonic House Prices and Spatial Quantile Regression* [J], Journal of Housing Economics, 21 (1), 16～27.

[24] Liddle B., 2011, *Consumption-Driven Environmental Impact and Age Structure Change in OECD Countries: A Cointegration-STIRPAT Analysis* [J], Demographic Research, 24 (30), 749～770.

[25] Liddle B., Lung S., 2010, *Age-structure, Urbanization, and Climate Change in Developed Countries: Revisiting STIRPAT for Disaggregated Population and Consumption-related Environmental Impacts* [J], Population and Environment, 31 (5), 317～343.

[26] McMillen D., 2015, *Conditionally Parametric Quantile Regression for Spatial Data: An Analysis of Land Values in Early Nineteenth Century Chicago* [J], Regional Science and Urban Economics, 55 (11), 28～38.

[27] Moscone F., Tosetti E., 2011, *GMM Estimation of Spatial Panels with Fixed Effects and Unknown Heteroskedasticity* [J], Regional Science and Urban Economics, 41 (5), 487～497.

[28] Ord J., 1975, *Estimation Methods for Models of Spatial Interaction* [J], Journal of the American Statistical Association, 70 (349), 120～126.

[29] Sadorsky P., 2014, *The Effect of Urbanization on CO_2 Emissions in Emerging Economies* [J], Energy Economics, 41, 147～153.

[30] Smirnov O., Anselin L., 2001, *Fast Maximum Likelihood Estimation of very Large Spatial Autoregressive Models: A Characteristic Polynomial Approach* [J], Computational Statistics and Data Analysis, 35 (3), 301～319.

[31] Su L., Yang Z., 2007, *Instrumental Variable Quantile Estimation of Spatial Autoregressive Models* [R], Working Paper, School of Economics, Singapore Management University.

[32] Su L., Yang Z., 2011, *Instrumental Variable Quantile Estimation of Spatial Autoregressive Models* [R], Working Paper, School of Economics, Singapore Management University.

[33] Vaart A., Wellner J., 1996, *Weak Convergence and Empirical Processes* [M], Berlin: Springer.

[34] York R., Rosa E., Dietz T., 2003, *STIRPAT, IPAT and ImPACT: Analytic Tools for Unpacking the Driving Forces of Environmental Impacts* [J], Ecological Economics. 46 (3), 351～365.

[35] Zhang L., 2016, *Flood Hazards Impact on Neighborhood House Prices: A Spatial Quantile Regression Analysis* [J], Regional Science & Urban Economics, 60, 12～19.

[36] Zhang L., Leonard T., 2014, *Neighborhood Impact of Foreclosure: A Quantile Regression Approach* [J], Regional Science and Urban Economics, 48 (9), 133～143.

[37] Zhang Y., Shen D., 2015, *Estimation of Semi-parametric Varying-coefficient Spatial Panel Data Models with Random-Effects* [J], Journal of Statistical Planning and Inference, 159, 64～80.

[38] Zietz J., Zietz, E., Sirmans G., 2008, *Determinants of House Prices: A Quantile Regression Ap-*