

中国省域电子商务发展的空间格局及影响因素研究

何进松

贵州大学数学与统计学院, 贵州 贵阳

收稿日期: 2026年7月15日; 录用日期: 2026年7月28日; 发布日期: 2026年9月24日

摘要

本文在空间自回归模型以及贝叶斯框架下, 基于2023年中国31个省级行政区的相关数据, 结合Metropolis-Hastings算法与Gibbs抽样算法探究了我国省域电子商务发展的空间格局及影响因素。模拟仿真研究证实了模拟的有效性, 同时实证分析发现我国省域电子商务发展呈现显著的头部集聚与非均衡特征, 形成“东高西低、沿海强内陆弱”的空间分异格局, 市场开放度与人均GDP是驱动电商发展的核心动力, 数字基建、科创投入等要素的赋能效应尚未充分释放。

关键词

电子商务, 空间自回归模型, 贝叶斯估计, 省域

Spatial Pattern and Influencing Factors of Provincial E-Commerce Development in China

Jinsong He

School of Mathematics and Statistics, Guizhou University, Guiyang Guizhou

Received: July 15, 2026; accepted: July 28, 2026; published: September 24, 2026

Abstract

Under the framework of the spatial autoregressive model and Bayesian statistics, this paper explores the spatial pattern and influencing factors of provincial e-commerce development in China based on the relevant data of 31 provincial-level administrative regions in 2023, by integrating the Metropolis-Hastings algorithm and Gibbs sampling. The simulation study verifies the effectiveness

文章引用: 何进松. 中国省域电子商务发展的空间格局及影响因素研究[J]. 电子商务评论, 2026, 15(9): 877-886.

DOI: 10.12677/ec.2026.1591069

of the proposed estimation method. Meanwhile, the empirical analysis reveals that China's provincial e-commerce development presents significant top-tier agglomeration and unbalanced characteristics, forming a spatial differentiation pattern of "high in the east and low in the west, strong in coastal areas and weak in inland areas". Market openness and per capita GDP are the core driving forces for e-commerce development, while the empowering effects of factors such as digital infrastructure and scientific and technological innovation investment have not been fully unleashed.

Keywords

E-Commerce, Spatial Autoregressive Model, Bayesian Estimation, Provincial-Level

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

数字经济是继农业经济、工业经济之后的主要经济形态，电子商务作为数字经济与实体经济深度融合的核心业态，不仅是重塑商品流通体系、激活消费市场的关键载体，更是推动区域协调发展、赋能乡村振兴的重要引擎。近年来，我国电子商务产业规模持续扩大，业态模式不断创新，已成为国民经济稳增长、保就业、促转型的重要支撑力量。与此同时，我国区域发展不平衡问题在电商领域凸显，省际间电商发展水平差距显著，产业空间布局呈现出极强的极化特征，东部沿海发达地区与中西部欠发达地区之间的数字经济鸿沟持续显现，制约了电商产业高质量发展与区域协调发展目标的实现。在此背景下，精准刻画我国省域电子商务发展的空间格局，系统识别其核心影响因素与空间作用机制，破解区域电商发展不均衡难题，成为当前学术研究 with 政策制定的重要议题。

现有关于电子商务发展的研究已形成丰富的学术成果，如：刘欣煜等[1]基于销售渠道选择视角，探究了电子商务对农户销售和生产行为的影响；李宏兵等[2]证实了农村电商对农户创业的正向驱动作用；李富昌等[3]测度了西南地区电子商务与乡村产业高质量发展的耦合协调水平；马述忠等[4]基于市域层面数据探究了跨境电商的普惠逻辑与区域协调发展效应；王宝顺等[5]分析了电子商务发展对农村家庭消费结构升级的赋能作用；张鹿鹿等[6]验证了电子商务对全国统一大市场建设的正向推动效应；李琪等[7]探究了电子商务发展的空间溢出效应与农民收入增长之间的联系等。上述研究从多个维度揭示了电子商务的经济社会赋能效应，但现有研究仍存在明显的拓展空间。一方面，多数研究聚焦于电商发展的经济效应检验，对我国省域电子商务发展的空间格局刻画仍以描述性分析为主，对省际间电商发展的空间互动机制、空间效应的作用方向与强度的系统性识别不足；另一方面，现有实证分析普遍采用传统最小二乘估计、极大似然估计等频率学派方法，在小样本研究场景中易出现有限样本估计偏差，且无法有效融入电商发展的历史先验信息，对模型参数不确定性的刻画存在固有局限，难以精准、稳健地识别我国省域电商发展的核心影响因素。贝叶斯估计方法凭借其可融合先验信息、提升小样本下估计精度、完整刻画参数后验分布的优势，已在空间计量经济学领域得到广泛应用[8]-[10]。

综上所述，现有电商发展相关研究鲜有文献构建空间计量模型的贝叶斯分析框架来探究省域电商发展的空间效应与影响因素，本文将基于空间自回归模型[11]，构建我国省域电商发展空间效应的贝叶斯分析框架，探究我国省域电子商务发展的空间格局及影响因素。

2. 相关理论基础

2.1. 模型及其假设

空间自回归模型的一般形式如下：

$$y_i = \rho \sum_{j=1}^n \omega_{ij} y_j + \beta_1 x_{1i} + \beta_2 x_{2i} + \cdots + \beta_p x_{pi} + \varepsilon_i, \quad i=1, 2, \cdots, n, \quad (1)$$

其中, y_i 是第 i 个被解释变量观测值, ρ 是空间相关系数, 反映近邻单位之间的空间紧密程度, ω_{ij} 是 $n \times n$ 的空间权重矩阵 ω 的第 i 行 j 列的元素, 且对 $\forall i = j = 1, 2, \cdots, n$, 空间权重矩阵 $\omega = (\omega_{ij})_{n \times n}$ 满足假设: (i) $\omega_{ij} \geq 0, i \neq j$; (ii) $\omega_{ij} = 0, i = j$; (iii) $\sum_{j=1}^n \omega_{ij} = 1$. $\beta_1, \beta_2, \cdots, \beta_p$ 是待估的回归系数参数, $x_i^T = (x_{1i}, x_{2i}, \cdots, x_{pi})^T$ 是第 i 个 $p \times 1$ 的解释变量向量, 上标 T 表示进行转置, ε_i 为随机误差项, 且假设服从均值为 0, 方差为 σ^2 的正态分布, 即 $\varepsilon_i \sim N(0, \sigma^2)$ 。

记 $\mathbf{y} = (y_1, y_2, \cdots, y_n)^T$, $\mathbf{x} = (x_1, x_2, \cdots, x_n)^T$, $\boldsymbol{\beta} = (\beta_1, \beta_2, \cdots, \beta_p)^T$, $\boldsymbol{\varepsilon} = (\varepsilon_1, \varepsilon_2, \cdots, \varepsilon_n)^T$, 模型(1)的矩阵形式可表示为

$$\begin{cases} \mathbf{y} = \rho \omega \mathbf{y} + \mathbf{x} \boldsymbol{\beta} + \boldsymbol{\varepsilon}, \\ \boldsymbol{\varepsilon} \sim N(\mathbf{0}_n, \sigma^2 \mathbf{I}_n). \end{cases} \quad (2)$$

这里 $\mathbf{0}_n$ 表示 $n \times 1$ 的零向量, $\mathbf{I}_n$ 是 $n \times n$ 的单位矩阵。

2.2. 似然函数与参数的先验分布假设

记 $A = \mathbf{I}_n - \rho \omega$, 基于模型(2), 易得 $\mathbf{y} \sim N(A^{-1} \mathbf{x} \boldsymbol{\beta}, \sigma^2 A^{-1} A^{-T})$, 这里 A^{-1} 表示 A 的逆矩阵, A^{-T} 为 A^{-1} 的转置。故在给定数据集 $D = \{\mathbf{y}, \mathbf{x}\}$ 的条件下, 模型似然函数为

$$\begin{aligned} L(\rho, \boldsymbol{\beta}, \sigma^2 | D) &= (2\pi\sigma^2)^{-\frac{n}{2}} |A| \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n \left(y_i - \rho \sum_{j=1}^n \omega_{ij} y_j - x_i^T \boldsymbol{\beta} \right)^2 \right\} \\ &= (2\pi\sigma^2)^{-\frac{n}{2}} |A| \exp \left\{ -\frac{(\mathbf{A}\mathbf{y} - \mathbf{x}\boldsymbol{\beta})^T (\mathbf{A}\mathbf{y} - \mathbf{x}\boldsymbol{\beta})}{2\sigma^2} \right\}, \end{aligned} \quad (3)$$

其中 $|A|$ 表示对 A 求行列式。进一步的, 本文分别假设参数 ρ 、 $\boldsymbol{\beta}$ 和 σ^2 的先验分布为 $\rho \sim U(\rho_{\min}, \rho_{\max})$ 、 $\pi(\boldsymbol{\beta}) \sim N(\boldsymbol{\beta}_0, \mathbf{H}_0)$ 和 $\sigma^2 \sim IG(a, b)$, 这里 $U(\rho_{\min}, \rho_{\max})$ 表示区间 $[\rho_{\min}, \rho_{\max}]$ 的均匀分布, $IG(a, b)$ 表示服从参数为 a 、 b 的逆伽马分布。记 $\boldsymbol{\theta} = \{\rho, \boldsymbol{\beta}, \sigma^2\}$, 并假设

$$\pi(\boldsymbol{\theta}) = \pi(\rho, \boldsymbol{\beta}, \sigma^2) = \pi(\rho) \pi(\boldsymbol{\beta}) \pi(\sigma^2), \quad (4)$$

参数 ρ 、 $\boldsymbol{\beta}$ 和 σ^2 的概率密度函数分别为

$$\pi(\rho) = \frac{1}{\rho_{\max} - \rho_{\min}} \mathbf{I}(\rho_{\min} < \rho < \rho_{\max}), \quad (5)$$

$$\pi(\boldsymbol{\beta}) = (2\pi)^{-\frac{p}{2}} |\mathbf{H}_0|^{-\frac{1}{2}} \exp \left\{ -\frac{1}{2} (\boldsymbol{\beta} - \boldsymbol{\beta}_0)^T \mathbf{H}_0^{-1} (\boldsymbol{\beta} - \boldsymbol{\beta}_0) \right\}, \quad (6)$$

$$\pi(\sigma^2) = \frac{b^a}{\Gamma(a)} (\sigma^2)^{-(a+1)} \exp \left\{ -\frac{b}{\sigma^2} \right\}, \quad (7)$$

其中 $\mathbf{I}(\cdot)$ 表示示性函数, $\rho_{\min}$, $\rho_{\max}$, β_0 , $\mathbf{H}_0$, a , b 为已知超参数。

2.3. 未知参数条件后验分布与 Gibbs 抽样

基于上述似然函数及其参数先验分布假设, 由贝叶斯定理, 参数 θ 的后验分布为

$$\begin{aligned}\pi(\theta | D) &= \frac{L(\theta | D)\pi(\theta)}{p(D)} \propto L(\theta | D)\pi(\theta) \\ &\propto (\sigma^2)^{-\frac{n}{2}} |A| \exp \left\{ -\frac{(\mathbf{A}\mathbf{y} - \mathbf{x}\beta)^T (\mathbf{A}\mathbf{y} - \mathbf{x}\beta)}{2\sigma^2} \right\} \\ &\quad \cdot \exp \left\{ -\frac{1}{2} (\beta - \beta_0)^T \mathbf{H}_0^{-1} (\beta - \beta_0) \right\} \cdot (\sigma^2)^{-(a+1)} \exp \left\{ -\frac{b}{\sigma^2} \right\},\end{aligned}\quad (8)$$

其中 $p(D) = \int_{\Theta} L(\theta)\pi(\theta)d\theta$ 是数据 D 的边缘密度函数, 不含参数 θ 的任何信息, 符号 “ $\propto$ ” 表示 “正比与”。基于式(8), 下面将分别导出未知参数 ρ 、 β 和 σ^2 的条件后验分布。对 ρ 的条件后验分布, 有

$$\pi(\rho | D, \beta, \sigma^2) \propto |A| \exp \left\{ -\frac{(\mathbf{A}\mathbf{y} - \mathbf{x}\beta)^T (\mathbf{A}\mathbf{y} - \mathbf{x}\beta)}{2\sigma^2} \right\} \cdot \mathbf{I}(\rho_{\min} < \rho < \rho_{\max}); \quad (9)$$

对 β 的条件后验分布, 有

$$\pi(\beta | D, \rho, \sigma^2) \propto \exp \left\{ -\frac{1}{2\sigma^2} (\beta - \beta^*)^T (\mathbf{H}_\beta^*)^{-1} (\beta - \beta^*) \right\},$$

其中, $\beta^* = \mathbf{H}_\beta^* \left(\frac{\mathbf{x}^T \mathbf{A}\mathbf{y}}{\sigma^2} + \mathbf{H}_0^{-1} \beta_0 \right)$, $\mathbf{H}_\beta^* = \left(\frac{\mathbf{x}^T \mathbf{x}}{\sigma^2} + \mathbf{H}_0^{-1} \right)^{-1}$ 。故

$$\pi(\beta | D, \rho, \sigma^2) \sim N(\beta^*, \mathbf{H}_\beta^*); \quad (10)$$

对 σ^2 的条件后验分布, 有

$$\pi(\sigma^2 | D, \rho, \beta) \propto (\sigma^2)^{-(a^*+1)} \exp \left\{ -\frac{b^*}{\sigma^2} \right\},$$

其中, $a^* = \frac{n}{2} + a$, $b^* = \frac{1}{2} (\mathbf{A}\mathbf{y} - \mathbf{x}\beta)^T (\mathbf{A}\mathbf{y} - \mathbf{x}\beta) + b$ 。故

$$\pi(\sigma^2 | D, \rho, \beta) \sim IG(a^*, b^*). \quad (11)$$

基于上述未知参数的后验推导, 不难发现, 参数 β 和 σ^2 的后验分布均是标准形式分布, 可直接从后验分布式(10)和(11)中获取后验样本, 而参数 ρ 的后验分布是非标准形式分布, 无法直接获取其后验样本, 为此, 本文采用 Metropolis-Hastings (MH)算法[12][13]来克服这个问题, 具体操作细节详见附录。

Gibbs 抽样算法[14]是马尔可夫链蒙特卡洛(MCMC)法的核心算法之一, 能有效从多变量概率分布中获取样本序列。本文采用 Gibbs 抽样算法从未知参数的后验分布中进行后验采样, 并实现未知参数 θ 的贝叶斯估计。算法具体步骤如下:

输入: 参数的初始值为 $\rho^{(0)}$, $\beta^{(0)}$ 和 $\sigma^{(0)}$ 。

Step 1. 令 $t = 0$;

Step 2. 从条件分布 $\pi(\beta | D, \rho^{(t)}, \sigma^{2(t)})$ 中抽取 $\beta^{(t+1)}$;

Step 3. 从条件分布 $\pi(\sigma^2 | D, \rho^{(t)}, \beta^{(t+1)})$ 中抽取 $\sigma^{2(t+1)}$;

Step 4. 从条件分布 $\pi(\rho | D, \beta^{(t+1)}, \sigma^{2(t+1)})$ 中抽取 $\rho^{(t+1)}$;

Step 5. 循环执行 Step2-Step4, 直至 $t = T$ 结束。

输出: 一组后验样本序列 $\{\rho^{(t)}, \beta^{(t)}, \sigma^{2(t)} : t = 1, 2, \dots, T\}$ 。

通过上述 Gibbs 抽样算法获得的后验样本序列, 舍弃一定的预热期样本, 收集收敛后验样本序列 $\{\rho^{(m)}, \beta^{(m)}, \sigma^{2(m)} : m = 1, 2, \dots, M\}$ 。获得未知参数 θ 的联合贝叶斯估计为

$$\hat{\rho} = \frac{1}{M} \sum_{m=1}^M \rho^{(m)}, \hat{\beta} = \frac{1}{M} \sum_{m=1}^M \beta^{(m)}, \hat{\sigma}^2 = \frac{1}{M} \sum_{m=1}^M \sigma^{2(m)}. \quad (12)$$

3. 模拟仿真研究

令数据 y 模型(2)产生, 回归系数参数的真值设置为 $\beta = (\beta_1, \beta_2, \beta_3)^T = (1, \sqrt{2}, -1)^T$, 对 $\forall i = 1, \dots, n$, 假设解释变量 $x_i = (x_{i1}, x_{i2}, x_{i3})^T$ 的每一分量均独立同分布于标准正态分布 $N(0, 1)$, 与李澳归等[15]相同, 空间权重矩阵 ω 被设置为: (i) $\omega_{1,2} = \omega_{n,n-1} = 1$; (ii) 对 $\forall i = 2, 3, \dots, n-1$, $\omega_{i,i-1} = \omega_{i,i+1} = 0.5$; (iii) 除上述两种情况外, ω 的其余元素为 0; 空间相关参数考虑 $\rho = 0.2$ 、 $\rho = -0.6$ 和 $\rho = 0.9$ 这 3 种真值情形, 代表近邻单位之间的较弱正相关、一般负相关和较强正相关; 参数 σ^2 的真值设置为 $\sigma^2 = 1$ 。样本量设置为 $n = 80$ 和 $n = 160$, 同时考虑下面两种类型的先验信息(超参数)对贝叶斯估计性能的影响:

Type1 (良好的先验): $\rho_{\min} = -1$, $\rho_{\max} = 1$, β_0 取 β 的真值, $H_\beta = 0.01I_3$, $a = b = 0.001$;

Type2 (无信息先验): $\rho_{\min} = -1$, $\rho_{\max} = 1$, $\beta_0 = 0_3$, $H_\beta = 1000I_3$, $a = b = 0.001$ 。

基于上述设置, 在每种场景下独立产生数据 100 次, 每次产生数据的 MCMC 迭代中去除 2000 个预热期样本, 收集后 3000 个样本进行未知参数的联合贝叶斯估计。同时, 本文还给出如下指标来反映参数的估计效果: 对 $\forall j = 1, \dots, 100$, 记 $\hat{\theta}_j$ 表示基于第 j 次实验数据得到的参数估计, θ^{true} 表示 θ 的真值,

$$\text{MEAN} = \frac{1}{100} \sum_{j=1}^{100} \hat{\theta}_j, \text{Bias} = |\text{MEAN} - \theta^{true}|, \text{STD} = \sqrt{\frac{1}{100-1} \sum_{j=1}^{100} (\hat{\theta}_j - \text{MEAN})^2}, \text{RMSE} = \sqrt{\frac{1}{100} \sum_{j=1}^{100} (\hat{\theta}_j - \theta^{true})^2},$$

Med、5%th 和 95%th 分别表示基于 100 次重复抽样数据得到的估计的中位数、5%分位数和 95%分位数。模拟结果如表 1, 表 2 所示, 可以发现: (1) 所有场景设置下所得到的参数 Bias 均很小(不超过 0.05), 表明本文所提出的贝叶斯估计方法具有较高的估计精度; (2) 先验类型 Type1 下所有参数的总均方根误差 (SUM (RMSE))均小于先验类型 Type2, 表明 Type1 先验下的估计性能更优, 即在具有先验信息下的场景下可以获取更高的估计精度; (3) 随着样本量的增加, 贝叶斯的估计性能更好。

Table 1. Numerical results of simulation (based on Type1)

表 1. 模拟仿真的数值结果(基于 Type1)

ρ	参数	$n = 80$						$n = 160$					
		Bias	Med	5%th	95%th	STD	RMSE	Bias	Med	5%th	95%th	STD	RMSE
0.2	β_1	0.006	0.930	1.003	1.105	0.052	0.052	0.001	0.916	0.995	1.090	0.058	0.057
	β_2	0.002	1.349	1.411	1.503	0.046	0.046	0.008	1.340	1.426	1.497	0.048	0.048
	β_3	0.001	-1.088	-1.000	-0.916	0.054	0.054	0.004	-1.065	-0.996	-0.914	0.048	0.048
	ρ	0.000	0.083	0.208	0.293	0.064	0.063	0.002	0.128	0.201	0.265	0.042	0.042
	σ^2	0.021	0.796	1.023	1.236	0.147	0.148	0.001	0.778	1.009	1.216	0.119	0.119
sum (RMSE)							0.362						

续表

-0.6	β_1	0.005	0.932	1.003	1.085	0.044	0.044	0.006	0.897	0.996	1.086	0.053	0.053
	β_2	0.003	1.345	1.412	1.494	0.045	0.045	0.002	1.348	1.413	1.509	0.049	0.048
	β_3	0.007	-1.082	-1.009	-0.934	0.045	0.045	0.005	-1.077	-0.996	-0.911	0.048	0.048
	ρ	0.008	-0.655	-0.595	-0.524	0.039	0.039	0.006	-0.645	-0.595	-0.537	0.032	0.033
	σ^2	0.016	0.781	1.022	1.226	0.145	0.145	0.005	0.813	1.005	1.202	0.114	0.114
	sum (RMSE)						0.320						0.296
0.9	β_1	0.004	0.899	1.001	1.088	0.057	0.057	0.001	0.919	1.000	1.087	0.054	0.054
	β_2	0.005	1.330	1.416	1.506	0.049	0.049	0.003	1.348	1.413	1.475	0.041	0.041
	β_3	0.005	-1.095	-0.996	-0.921	0.052	0.052	0.007	-1.092	-1.009	-0.906	0.054	0.054
	ρ	0.002	0.863	0.899	0.923	0.017	0.017	0.001	0.878	0.899	0.914	0.011	0.011
	σ^2	0.034	0.784	1.016	1.352	0.188	0.190	0.005	0.843	1.006	1.191	0.108	0.107
	sum (RMSE)						0.365						0.266

Table 2. Numerical results of simulation (based on Type2)**表 2.** 模拟仿真的数值结果(基于 Type2)

ρ	参数	$n=80$						$n=160$					
		Bias	Med	5%th	95%th	STD	RMSE	Bias	Med	5%th	95%th	STD	RMSE
0.2	β_1	0.014	0.804	0.991	1.173	0.107	0.107	0.000	0.873	0.991	1.143	0.096	0.095
	β_2	0.001	1.212	1.413	1.610	0.111	0.110	0.013	1.293	1.433	1.551	0.080	0.080
	β_3	0.004	-1.199	-0.993	-0.834	0.115	0.115	0.006	-1.112	-0.997	-0.861	0.080	0.079
	ρ	0.006	0.099	0.210	0.300	0.057	0.057	0.001	0.126	0.201	0.270	0.042	0.042
	σ^2	0.022	0.753	1.014	1.348	0.187	0.188	0.003	0.781	1.015	1.224	0.120	0.119
	sum (RMSE)						0.577						0.417
-0.6	β_1	0.002	0.816	0.984	1.203	0.114	0.113	0.003	0.844	1.006	1.135	0.085	0.085
	β_2	0.008	1.265	1.420	1.618	0.107	0.107	0.002	1.275	1.414	1.540	0.080	0.079
	β_3	0.006	-1.177	-0.992	-0.820	0.109	0.109	0.010	-1.116	-0.995	-0.836	0.080	0.080
	ρ	0.001	-0.670	-0.605	-0.526	0.044	0.043	0.005	-0.649	-0.594	-0.537	0.033	0.033
	σ^2	0.048	0.796	1.046	1.312	0.151	0.158	0.008	0.820	1.004	1.198	0.118	0.118
	sum (RMSE)						0.530						0.395
0.9	β_1	0.001	0.795	0.988	1.180	0.112	0.112	0.003	0.876	0.998	1.124	0.078	0.077
	β_2	0.003	1.243	1.415	1.599	0.111	0.110	0.006	1.278	1.408	1.569	0.089	0.088
	β_3	0.002	-1.200	-1.003	-0.829	0.116	0.116	0.001	-1.142	-0.999	-0.876	0.087	0.086
	ρ	0.009	0.860	0.892	0.918	0.017	0.019	0.002	0.877	0.898	0.915	0.011	0.011
	σ^2	0.016	0.756	1.009	1.239	0.157	0.157	0.029	0.843	1.019	1.252	0.128	0.131
	sum (RMSE)						0.514						0.393

4. 实证分析

利用本文提出的贝叶斯估计方法探究中国电子商务发展的空间格局及影响因素，数据选取的是 2023 年中国省级部分数字经贸数据(由于数据的可得性原因，本文研究不包含我国港澳台地区的样本数据)，数据来源于 2023 年《中国统计年鉴》。借鉴张卫华等[16]指标选取方法，构建如下的中国电子商务发展水平指标体系(表 3)，具体指标详细解释可参考文献[16]。

Table 3. Indicators and explanations of e-commerce development level in China

表 3. 中国电子商务发展水平指标及解释

指标	指标对应解释	单位
emp	信息传输、软件和信息技术服务业从业人数	万人
rdx	研究和开发经费投入	万元
tel	电信业务总量	亿元
inv	信息传输、软件和信息技术服务业固定资产投资总额	亿元
ecs	电子商务销售额	亿元
gdp	人均 GDP	元
opn	市场开放度	%

4.1. 描述性分析

选取电子商务销售额作为被解释变量，用于衡量省域电商规模及其电商发展水平，其余变量作为解释变量。图 1 给出了全国 31 个省级单位电子商务销售额的条形统计图。可以发现我国省域电子商务发展呈现出极强的非均衡性与头部集聚特征，省际间电商规模的绝对差距极为悬殊，若将电子商务销售额进行划分区间，可将 31 个省级单位划分为三大发展梯队：第一梯队为销售额突破 20,000 亿元，仅包含广东、上海、北京、山东、江苏 5 个东部沿海省级行政区，该梯队合计电商销售额占 31 个样本省级行政区总额的 62.47%，形成了极强的产业集聚效应；将销售额处于 5000 亿至 20,000 亿元之间的划分为第二梯队，涵盖浙江、福建、四川、湖北等 16 个省级行政区，主要以中部地区和西部经济强省为主；其余省份则划分到第三梯队，以西部欠发达省份和东北部分省份为主，电商发展仍处于相对滞后的状态。整体电商发展水平呈现出显著的“东高西低、沿海强内陆弱”的空间分异特征，与区域经济发展水平存在高度的空间耦合性。

4.2. 贝叶斯分析

由于省域电商发展的显著空间分异与非均衡特征，下面将利用空间自回归模型进一步检验各解释变量对省域电商发展水平的边际影响，并对其作用机制与异质性特征进行分析。其中，空间权重矩阵采用德劳内三角剖分函数对 31 个省级单位进行划分，即

$$\omega_{ij}^* = \begin{cases} 1, & \text{若单位 } i \text{ 与单位 } j \text{ 共享边,} \\ 0, & \text{单位 } i \text{ 与单位 } j \text{ 不共享边.} \end{cases}$$

随后对 ω_{ij}^* 进行行标准化处理，即 $\omega_{ij} = \frac{\omega_{ij}^*}{\sum_{j=1}^{31} \omega_{ij}^*}$ ，得到最终的空间权重矩阵 $\omega = (\omega_{ij})_{31 \times 31}$ 。基于上述处理与

设置， $\forall i = 1, 2, \dots, 31$ ，构建如下空间自回归方程：




Figure 1. E-commerce sales volume of each provincial administrative unit in 2023
图 1. 2023 年各省级行政单位电子商务销售额

$$ecs_i = \rho \sum_{j=1}^n \omega_{ij} ecs_j + \beta_0 + \beta_1 emp_i + \beta_2 rdx_i + \beta_3 tel_i + \beta_4 inv_i + \beta_5 gdp_i + \beta_6 opn_i.$$

因电子商务发展水平存在众多的历史数据，因此可根据历史信息获得一定的先验信息，故结合历史信息下，超参数设置为： $\rho_{\min} = -1$ ， $\rho_{\max} = 1$ ， $\beta_0 = \mathbf{0.1}_{7 \times 1}$ ， $\mathbf{H}_0 = 0.04 \mathbf{I}_7$ ， $a = 3$ ， $b = 0.4$ ，其中 $\mathbf{0.1}_{7 \times 1}$ 表示元素全为 0.1 的 7×1 列向量。运用空间自回归模型对上述数据进行拟合，迭代次数为 8000 次，同时去除预热期 5000 个样本，所获得的参数的估计结果如表 4 所示(其中 MH 算法的步长为 0.3，所得的接受

Table 4. Bayesian estimation of e-commerce development level in China
表 4. 中国电子商务发展水平的贝叶斯估计

参数	EST	SD
β_0	0.1008	0.2007
β_1	0.1047	0.1989
β_2	0.0010	0.0002
β_3	0.1023	0.1978
β_4	0.0914	0.1967
β_5	0.1412	0.0230
β_6	0.0956	0.1988
ρ	-0.4890	0.1408
σ^2	4.4807	1.1171

率为 0.31), 可以发现: (1) 空间自回归系数 ρ 的估计值为 -0.4890, 对应标准差为 0.1408, 表明我国省域电子商务发展各省域之间存在显著的负相关关系, 同时省域电商发展也存在显著的空间虹吸效应, 即电商发展领先省份会对邻近省份的电商发展产生抑制作用, 印证了“东高西低、沿海强内陆弱”的极化空间分异特征; (2) 人均 GDP 的回归系数估计值为 0.1412, 是所有解释变量中显著性最强、边际拉动效应最突出的核心变量, 表明区域经济发展水平是驱动我国省域电商发展的基础性核心动力, 人均 GDP 提升可通过扩大消费市场容量、完善产业配套体系、提升居民消费能力等多重路径, 直接带动省域电子商务销售额增长; (3) 变量信息传输、软件和信息技术服务业从业人数和电信业务总量的回归系数的估计值分别为 0.1047 和 0.1023, 同样作为对被解释变量的显著变量。从经济来看, 信息传输服务业从业人数与电信业务总量是数字经济发展的核心基础要素, 是带动电商产业发展的关键影响因素; (4) 市场开放度和信息传输、软件和信息技术服务业固定资产投资总额的回归系数分别为 0.0956 和 0.0914, 其系数相对较小, 但这两个变量对电商发展的核心驱动作用仍具备明确的经济意义; (5) 变量研究和开发经费投入的回归系数仅为 0.0010, 表明科创研发投入对省域电子商务发展的实际拉动效应极为微弱。

5. 结论与展望

5.1. 结论

本文基于空间计量框架, 采用贝叶斯估计方法对我国省域电子商务发展水平及其影响因素展开实证分析, 研究发现, 我国电商发展具有明显的非均衡与头部集聚特征, 整体呈现“东高西低、沿海强内陆弱”的空间分异格局, 与区域经济发展水平高度耦合, 区域分化与极化现象突出。同时, 省域电商发展存在统计显著的负向空间关联, 空间虹吸效应突出, 电商发展领先省份会对邻近省份的数字要素、市场资源与产业配套形成吸纳作用, 省际间电商产业协同联动机制尚未建立。驱动因素呈现显著异质性, 人均 GDP、电信业务总量和信息传输、软件和信息技术服务业从业人数、市场开放度以及信息传输、软件和信息技术服务业固定资产投资总额是推动电商发展的核心动力, 其中人均 GDP 的边际拉动效应最为显著, 是省域电商发展的基础性支撑; 研发经费投入虽在统计层面显著为正, 但对电商发展的实际边际拉动效应极为微弱, 科创投入对电商产业高质量发展的赋能作用远未得到有效发挥。

5.2. 展望

基于上述研究结论, 未来可围绕我国电子商务高质量发展的现实需求, 一方面聚焦省域电商空间联动不足的核心问题, 深入探究跨区域电子商务的实现路径, 激活电商产业的空间溢出效应, 构建东中西部协同、上下游联动的电商发展新格局; 另一方面针对数字人才、科创投入、数字基建等要素赋能效率不足的问题, 细分不同区域、不同发展阶段的异质性特征, 优化政策精准度; 同时可进一步拓展研究视角, 纳入绿色发展、乡村振兴、跨境电商融合等新维度, 结合机器学习、动态空间面板模型等方法优化实证体系, 为我国电商产业高质量发展提供更具针对性的理论支撑与实践参考。

参考文献

- [1] 刘欣煜, 李松泽, 黄季焜. 电子商务对农户销售和生产的影响: 基于销售渠道选择视角[J]. 中国农村观察, 2026, 47(2): 24-44.
- [2] 李宏兵, 王爽, 赵春明. 农村电子商务发展的收入分配效应研究——来自“淘宝村”的经验证据[J]. 经济经纬, 2021, 38(1): 37-47.
- [3] 李富昌, 唐茜, 陈太静. 西南地区电子商务与乡村产业高质量发展耦合协调研究[J]. 林产工业, 2026, 63(2): 101-108.
- [4] 马述忠, 张道涵, 陈逸凡. 跨境电子商务与市域协调发展——兼论跨境电商的普惠逻辑[J]. 经济学动态, 2024(3): 77-95.

- [5] 王宝顺, 蒋飞, 刘刚. 电子商务发展与农村家庭消费结构升级[J]. 贵州财经大学学报, 2025(5): 81-89.
- [6] 张鹿鹿, 刘颖. 电子商务发展对统一大市场建设的赋能效应研究[J]. 商业经济研究, 2024(18): 107-110.
- [7] 李琪, 唐跃桓, 任小静. 电子商务发展、空间溢出与农民收入增长[J]. 农业技术经济, 2019(4): 119-131.
- [8] 王君婕, 张宁. 基于空间计量经济学的外商直接投资与碳排放分析[J]. 科技与管理, 2014, 16(5): 94-99, 105.
- [9] 方大春. 中国省域农民纯收入特征的空间计量经济学分析[J]. 石家庄经济学院学报, 2011, 34(6): 1-7.
- [10] 任晓怡. 中部地区金融发展与产业发展互动关系的实证研究——基于空间计量经济学的分析方法[J]. 金融与经济, 2015(5): 18-23, 56.
- [11] Lesage, J. and Pace, R.K. (2009) Introduction to Spatial Econometrics. Chapman and Hall/CRC.
- [12] Metropolis, N., Rosenbluth, A.W., Rosenbluth, M.N., Teller, A.H. and Teller, E. (1953) Equation of State Calculations by Fast Computing Machines. *The Journal of Chemical Physics*, **21**, 1087-1092. <https://doi.org/10.1063/1.1699114>
- [13] Hastings, W.K. (1970) Monte Carlo Sampling Methods Using Markov Chains and Their Applications. *Biometrika*, **57**, 97-109. <https://doi.org/10.1093/biomet/57.1.97>
- [14] Geman, S. and Geman, D. (1984) Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **6**, 721-741. <https://doi.org/10.1109/tpami.1984.4767596>
- [15] 李澳归, 赵远英. 基于切片 Gibbs 抽样算法的空间误差模型的贝叶斯参数估计[J]. 山东大学学报(理学版), 2025, 60(3): 116-126.
- [16] 张卫华, 梁运文. 中国数字贸易发展水平省域分异与空间效应[J]. 贵州社会科学, 2020(12): 129-138.

附 录

Metropolis-Hastings (MH)抽样算法[7][8]无需目标分布具有显式共轭分布形式,可直接针对任意复杂的后验分布进行抽样。根据 LeSage 等[6],可借助 MH 算法从条件分布(9)中随机采样,具体算法为:假设参数 ρ 在当前的迭代值为 $\rho^{(t)}$,从建议分布 $q(\rho^* | \rho^{(t)}) \sim N(\rho^{(t)}, c^2)$ 中随机产生一个样本 ρ^* 作为 $\rho^{(t+1)}$ 的候选样本, c 是建议分布的标准差,同时也作为 MH 抽样方法的调优参数。若 $\rho^* \notin (-1, 1)$,则直接令 $\rho^{(t+1)} = \rho^{(t)}$; 否则从均匀分布 $U(0, 1)$ 中随机产生一个随机数 η , 若

$$\eta \leq \min \left\{ \frac{\pi(\rho^* | D, \boldsymbol{\beta}^{(t+1)}, \sigma^{2(t+1)})}{\pi(\rho^{(t)} | D, \boldsymbol{\beta}^{(t+1)}, \sigma^{2(t+1)})}, 1 \right\},$$

令 $\rho^{(t+1)} = \rho^*$; 否则 $\rho^{(t+1)} = \rho^{(t)}$ 。选择合适的调优参数 c ,使得接受候选样本 ρ^* 的概率位于区间[0.25, 0.45]。