

城市等级划分的交通碳排放影响因素分析

刘博威^{1,2}, 刘晓佳^{1,2}, 张亦弛^{1,2}

(1. 集美大学航海学院, 福建 厦门 361021; 2. 集美大学海上交通安全研究所, 福建 厦门 361021)

[摘要] 为分析城市交通碳排放规律, 基于拓展 STIRPAT 模型并结合随机森林特征, 选取新能源汽车销量占比、PGDP、公共充电桩数量、第三产业总值、公共汽车(电)营运数量、城市道路货运量6个指标作为城市交通碳排放的影响因素。通过发布的碳排放系数对130个市的城市交通碳排放量进行测算, 并利用划分城市交通碳排放等级的方式, 根据测算的碳排放量进行等级划分。利用2017—2022年各城市指标数据, 建立 RF-GS 分类预测模型并对碳排放城市等级数量进行预测, 同时通过调整交通运输维度影响因素年增长率的方式对城市交通碳排放因素进行分析。结果表明: 当新能源汽车占比的年增长率由50%上升到70%时, 交通碳排放低等级的城市数量增多8.99%; 当公共充电桩建设的年增长率由55%下降到40%时, 交通碳排放低等级的城市数量减少14.61%; 当公路货运量的年增长率由5%下降到3%时, 交通碳排放低等级的城市数量增加3.37%。

[关键词] 城市交通碳排放; STIRPAT 模型; 分类预测; 随机森林

[中图分类号] U 491

Analysis of Factors Influencing Carbon Emissions from Transportation Considering City Classification

LIU Bowei^{1,2}, LIU Xiaojia^{1,2}, ZHANG Yichi^{1,2}

(1. Navigation College, Jimei University, Xiamen 361021, China;

2. Marine Traffic Safety Institute, Jimei University, Xiamen 361021, China)

Abstract: In order to analyze the carbon emission pattern of urban transportation, this paper selects six indicators based on the expanded STIRPAT model combined with random forest feature screening as influencing factors on carbon emissions from urban transportation: the percentage of new energy vehicle sales, PGDP, the number of public charging posts, the total value of tertiary industry, the number of public bus (electric) operations, and the amount of urban road freight. The carbon emissions from urban transportation of 130 cities are measured by the published carbon emission factors, and the carbon emission ranking of urban transportation is classified according to the measured carbon emissions using the classification of carbon emissions from urban transportation. The RF-GS classification prediction model was used to forecast the number of carbon emission city classes using the index data of each city from 2017-2022, while the influencing factors were analyzed by adjusting the annual growth rate of the influencing factors of transportation dimension. The results show that: the number of cities in low classes of carbon emissions from urban transportation increases 8.99% when the annual growth rate of the

[收稿日期] 2023-04-25

[基金项目] 福建省教育厅基金项目 (JAT210248)

[作者简介] 第一作者: 刘博威, 从事交通规划与管理研究。通信作者: 刘晓佳, 副教授, 博士, 从事交通运输与管理、海上交通安全保障技术研究。E-mail: happyxj1314@163.com

percentage of new energy vehicles increases from 50% to 70%; when the annual growth rate of public charging pile construction decreases from 55% to 40%, the number of cities in low classes of carbon emissions from urban transportation decreases by 14.61%; when the annual growth rate of road freight volume decreases from 5% to 3%, the number of cities in the same classes increases by 3.37%.

Keywords: carbon emissions from urban transportation; STIRPAT model; classification prediction; random forest

0 引言

全球气候变化的严重影响已经成为当前人类社会面临的重要挑战之一,而且这种影响正在不断加剧。温室气体排放是导致全球变暖的主要原因,IPCC 第六次评估报告中指出,人类活动产生的温室气体排放已经导致全球气温升高约 1.1℃^[1]。因此,如何减少温室气体排放已经成为 21 世纪人类必须共同面对的难题。温室气体中有超过 60% 排放量属于 CO₂^[2],因此降低碳排放水平是解决问题的关键所在。据国际能源署(IEA)数据统计^[3],交通运输所产生的碳排放量占全球碳排放总量的 26%。而在中国,交通领域的碳排放约占总碳排放量的 10%,其中城市交通是主要的碳排放来源。随着中国经济的稳步发展和城镇化进程的深入推进,城市的交通排放压力也将继续加大。因此,减少城市交通的碳排放,促进城市的低碳发展对于实现碳达峰和碳中和目标至关重要。

目前,有许多学者针对交通运输业低碳减排进行了深入研究,研究内容主要包括交通运输业碳排放影响因素的分析和交通碳排放量的预测研究。在交通碳排放影响因素分析方面,Gonzalez 等^[4]通过收集欧盟各国相关碳排放影响因素数据,针对人口、PGDP、燃料组合方式、碳化率和能源强度 5 种因素进行分解,采用 LMDI 分解法计算出影响欧盟碳排放量的主要因素;高标等^[5]运用 STIRPAT 模型,以人口总数、PGDP、交通运输产业投资额、城市化率、私家车数量等为切入点进行了分析;胡那^[6]对北京市交通运输业的经济发展与碳排放量建立了脱钩和复钩的概念模型,为碳生产率的影响因素研究提供了基础支撑;武翠芳等^[7]通过建立 STIRPAT 模型,对甘肃省交通运输业的碳排放数据进行测算,结果显示,影响该地区交通碳排放的主要因素为城市化水平;Timilsina 等^[8]分析了亚洲 1980—2005 年 12 个国家的交通运输业碳排放数据,结果显示,PGDP、人口年增长率和交通运输业的能源强度是影响交通运输业碳排放增长的关键因素。在交通碳排放量的预测方面,Shabbir 等^[9]收集了巴基斯坦各城市的碳排放影响因素数据,并对收集到的不同交通方式减排效果进行模拟计算,结果显示,减少私家车保有量是减少交通碳排放量的有效途径;Liimatainen 等^[10]通过 Delphi 方法对 2030 年芬兰公路货运碳排放情景进行预测;陈露露等^[11]利用 GM(1,1)模型分别预测了天津、江苏两地的交通运输碳排放总量,并结合影响因素提出符合当地经济发展的交通发展模式。

综上所述,虽然国内外很多学者对交通碳排放做了大量的研究和探索,但是,由于行业碳核算结果存在差异,学者们对交通运输业碳排放的测算结果也存在差异,而且,目前的大部分低碳交通相关研究都是针对具体的省或者市区来进行实证分析,结果可能会存在偶然性和特殊性。针对以上问题,本文从城市多样性的角度考虑,利用多个城市碳排放量划分城市碳排放等级,对城市交通碳排放量进行核算,并根据核算结果进行等级划分,最后利用交通碳排放相关影响因素的动态变化,综合分析不同城市交通碳排放等级的变化规律。

1 研究方法和数据来源

1.1 交通碳排放的测算

交通运输业 CO₂排放量是根据相关收集的数据并使用特定的方法计算得出的,目前,大多采用《IPCC2006 国家温室气体清单指南》^[12]中的碳排放系数法,它分为“自上而下”法和“自下而上”法^[13]。由于“自上而下”法是基于终端能源消耗的方法,它通过各类能源消耗量与相应的碳排放系

数相乘来计算碳排放量，这种方法在测算城市交通的碳排放量方面具有实用性，因此本文采用“自上而下”法来计算城市交通的碳排放量。具体计算公式为

$$C = \sum_i^n E_i \times F_i。$$

(1)

其中： C 为交通碳排放量； i 为能源种类； E_i 为第 i 种能源消耗量； F_i 为第 i 种能源的碳排放系数。

各城市能源消耗数据来源于《中国能源统计年鉴（2022 年）》^[14] 中交通运输、仓储和邮政业类别。交通运输业能源消耗种类分别为煤炭、焦炭、煤油、汽油、柴油、电力、天然气和燃料油，其能源碳排放系数^[12] 依次为 1.900 3，2.864 0，3.017 9，2.925 1，3.095 9，1.246 0，2.162 2，3.095 9。

人均碳排放量 C_p 即碳排放总量与人口数的比值，是反映地区碳排放情况和人口之间关系的参数指标，其计算公式为

$$C_p = \frac{C}{P}。$$

(2)

其中： C 为城市交通碳排放量； P 为城市人口总数。

利用式（1）和式（2）对 2017—2022 年 130 个市的城市交通碳排放量进行测算，部分城市的测算结果如图 1 所示。

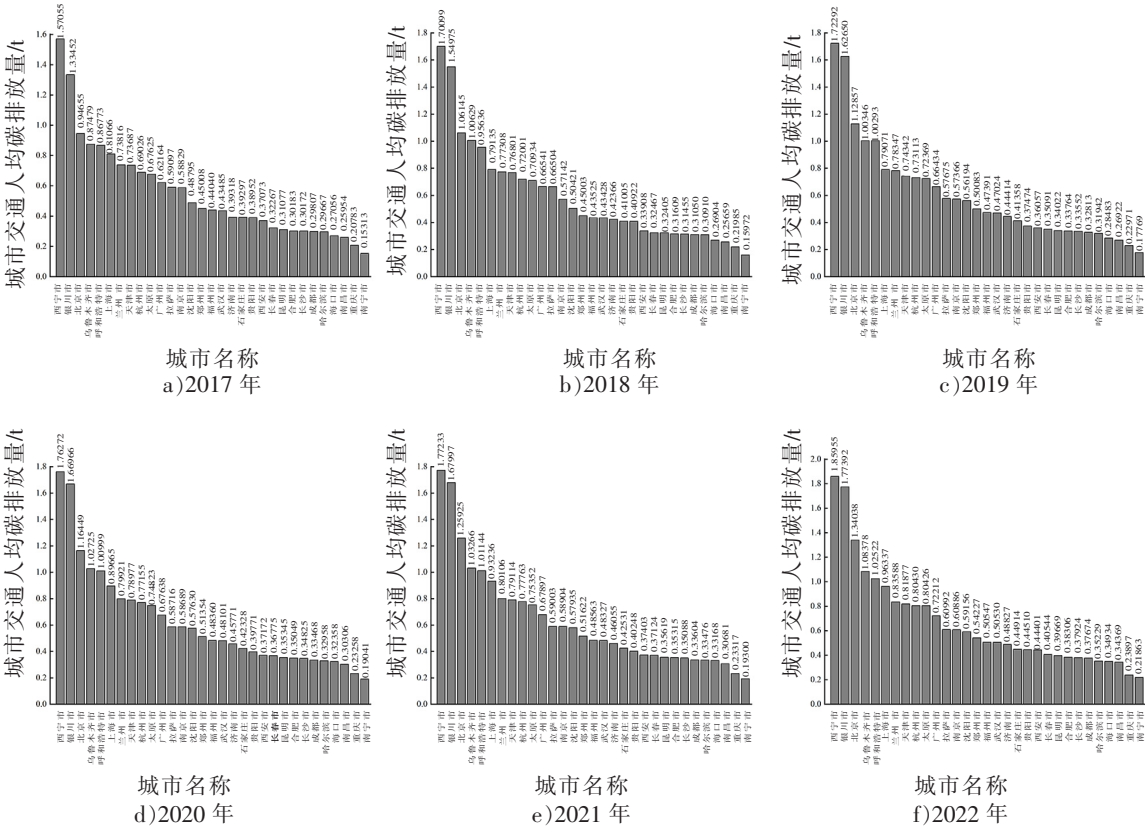


图 1 2017—2022 年部分市交通碳排放量测算结果
Fig.1 Calculation results of transportation carbon emissions in some cities from 2017 to 2022

1.2 碳排放等级划分

为了合理评估出我国城市交通碳排在达成碳达峰目标方面的表现，以碳达峰时期的人均交通碳排放量作为标准来进行等级划分。据中国工程院发布的《中国碳达峰碳中和战略及路径》估计，中国可能在 2027 年实现碳达峰，碳排放峰值可达 122 亿 t。而 2027 年中国人口总数预计可达 14.17 亿人，由式（2）可知，碳达峰时期人均碳排放量为 8.61 t。考虑到交通碳排放约占我国总排放量的 10%^[3]，将碳达峰时期人均交通碳排放量设定为 0.861 t，并以此为基准线，将各城市的人均交通碳排

放量与碳达峰时期的人均碳排放量(基准线)进行比较,并进行城市等级划分,等级划分为1、2、3、4、5共5个等级,对应的基准线的对比情况分别为70%及以下、70%~90%、90%~110%、110%~150%、150%以上,划分标准参考《居民生活领域碳排放等级评定规范》(DB3306T052—2023)。

1.3 影响因素选取

对交通业CO₂排放的影响因素进行科学辨识,并在此基础上进行合理筛选,对于城市交通CO₂排放的分析具有重要意义。然而,目前学术界尚未形成公认的标准化、通用的城市交通CO₂排放影响因素。为此,本文首先采用文献研究法,梳理已有文献并识别出城市交通CO₂排放的影响因素。其次,建立了随机森林特征选择模型,通过该模型对各影响因素进行排序,并基于重要度对这些因素进行二次筛选,进而得到城市交通CO₂排放合理的、关键的影响因素。

1.3.1 影响因素初步选取

通过阅读大量文献得知,目前大多数学者使用扩展的STIRPAT模型^[12]来选择各行业CO₂排放的影响因素。STIRPAT模型是在IPAT模型的基础上拓展而来的,其中 I 、 P 、 A 、 T 分别代表环境、人口、经济和技术因素。本文对当前研究中的影响因素包括按照IPAT恒等式中人口因素、经济因素、技术因素及交通运输四大维度类别进行分类整理,具体如下表1所示。

1.3.2 利用随机森林的指标筛选

利用随机森林进行指标筛选可以通过特征重要性排序,快速识别哪些指标对模型的预测能力有较大的贡献。常规的特征重要性度量方法有2类:一类是基于Gini指数^[15],它利用Gini增益最大化的原理进行筛选来衡量特征的重要性;另一类是利用袋外数据作为集成算法的测试集来测试模型分类的正确率^[16]。本文采用第二类方法进行特征重要性的度量,其主要思想是:对于加入噪声值的特征变量,如果随机森林的预测精度有明显的降低,说明该特征变量较为重要,反之不重要。

随机森林是采用有回放的随机抽样技术的集成算法^[17],在有 n 个样本的原始训练集中进行有范围的随机采样,每次采样1个样本,并在抽取下一个样本之前将该样本放回原始训练集,一些样本可能在自助集中重复多次,也有一些样本可能会被忽略,被忽略的数据即为袋外数据。通过袋外数据,随机给某一个指标加入一个噪声来测试结果的好坏,具体的步骤为:1)使用袋外数据集来测试已生成的随机森林的性能,并获得预测精度;2)在袋外数据中给某特征变量 X 加入噪声值;3)使用加入噪声后的袋外数据集来测试随机森林的性能,并获得新的预测精度;4)将步骤1获得的原始预测精度与加入噪声后的预测精度之差作为相应特征变量 X 的重要性度量。

通过Matlab 2021b软件建立随机森林影响因素重要度模型,获取每个影响因素的重要性得分。为了使结果更加直观,将重要性得分归一化到[0,1]区间内,得到城市交通碳排放各影响因素重要性排序,结果如图2所示。由图2可以看出,新能源汽车、城市PGDP和新能源充电站对于城市交通碳排放的影响比较重要,而城市人口、城镇化率重要度排名相对较低。这说明,基于人口维度的因素对城市交通碳排放影响程度较小。由于城市交通碳排放影响因素较多,为了防止输入的影响因素变量冗余导致模型精度偏低,选择排名前50%的因素作为城市交通碳排放的影响因素。

表1 基于拓展STIRPAT的城市交通碳排放影响因素
Tab.1 Factors influencing urban transport carbon emissions based on expanding STIRPAT

类别	影响因素	单位	简写
人口因素	总人口	万人	P
	城镇化率	%	Urb
经济因素	人均国内生产总值	亿元	PGDP
	居民消费价格指数(生活水平)		CPI
	第三产业生产总值	万亿	TIGDP
技术因素	能源排放强度	万t/亿元	I_E
交通运输因素	充电站数量	个	N_{CS}
	新能源汽车占比	%	P_{EV}
	公共汽车(电)营运数量	辆	N_{OB}
	巡游出租车营运数量	辆	N_{OT}
	公路货运量(交通需求)	万t	R_{FT}
	公路客运量(交通需求)	万人	R_{PT}

1.4 研究区域和数据来源

本文以分布于中国的直辖市和各省的地级市作为研究对象，包括 4 个直辖市和 126 个地级市。数据来源：各城市新能源汽车销量比重来自《节能与新能源汽车年鉴（2023 年）》中城市汽车销量和新能源汽车销量计算所得；能源强度来源于《中国能源统计年鉴（2022 年）》；居民消费价格指数（CPI）来源于各市统计局官网查询数据；各市总人口数、各市人均 GDP、第三产业生产总值、公共汽车（电）运营数量、巡游出租车营运数量、公路货运量、公路客运量来源于《中国城市统计年鉴（2021 年）》；公共充电桩数量来源于充电吧数据。




图 2 城市交通碳排放影响因素重要度
Fig.2 Importance of factors affecting carbon emissions from municipal transport

2 基于机器学习的城市交通碳排放分类预测模型

2.1 数据处理

由于统计年鉴中部分城市的少量数据存在空缺，利用 SPSS 软件，对缺失值所属数据条选择分段三次样条插值的方法，对缺失点的值进行预测，并对缺失值进行替换。

2.2 模型选择

2.2.1 模型初步筛选

对指标数据进行初步的模型筛选，利用 Matlab 2021b 软件中的分类学习器，对 2017—2022 年 130 个市 6 个影响因素的 780 条数据进行并行计算，在衡量模型的泛化能力上选择 10 折交叉验证，最终 5 种模型 Naive Bayes、Medium neural network、Bagged trees、Medium Gaussian SVM、RUSBoost trees 的准确度分别为 75.3%，72.7%，83.1%，81.4%，78.3%。

考虑到分类样本数据存在不平衡的情况，这会导致分类结果出现偏差，因此选择分类准确率最高的 Bagged trees（升级版装袋树，随机森林）和 Medium Gaussian SVM（中等高斯支持向量机）进行分类指标计算，对模型进行二次筛选。

2.2.2 分类指标计算

在机器学习中，分类预测结果的好坏可根据模型的混淆矩阵计算所需衡量的指标来衡量。通常衡量模型准确率的指标有 F_1 分数、ROC 曲线和 AUC 值。

1) F_1 分数。在多分类问题中， F_1 分数一般分为 2 种，一种是 F_{1Macro} 分数，另一种是 F_{1Micro} 分数。考虑到城市交通碳排放的影响因素偏多，且不同城市样本数据存在不平衡的情况，本文采用 F_{1Micro} 分数。 F_{1Micro} 分数会考虑各种类别的数量，更适用于数据不平衡的情况。其计算公式为

$$P_{micro} = \sum_{i=1}^n TP_i / [\sum_{i=1}^n TP_i + \sum_{i=1}^n FP_i], \tag{4}$$

$$R_{micro} = \sum_{i=1}^n TP_i / [\sum_{i=1}^n TP_i + \sum_{i=1}^n FN_i], \tag{5}$$

$$F_{1micro} = 2 \times P_{micro} \times R_{micro} / (P_{micro} + R_{micro}). \tag{6}$$

其中： P 为准确率（预测为正类的样本中预测正确的比例）； R 为召回率（实际为正类的样本中预测正确的比例）；TP 为将正类预测为正类的数量；FP 为将负类预测为正类的数量；FN 为将正类预测为负类的数量。经计算，城市交通碳排放的随机森林和高斯核支持向量机的 F_1 分数分别为 0.823 2，0.816 3。

2) ROC 曲线和 AUC 值。ROC 曲线即选定模型分类所需阈值，将阈值筛选出的结果以点的形式串联起来得到一条以真正类率为纵坐标轴、假正类率为横坐标轴的曲线。其判别标准是，靠近左上角

的曲线代表模型分类效果最好。AUC 值是 ROC 曲线与下方坐标轴围成的面积, 该值越大, 代表模型的分类效果越好。

随机森林和高斯核支持向量机分类预测模型的 ROC 曲线和 AUC 值结果如图 3 所示。通过 $F_{1\text{Micro}}$ 分数、ROC 曲线、AUC 值模型准确度指标的比较, 结果显示, 随机森林均优于高等高斯支持向量机, 因此, 本文选择随机森林分类预测模型对城市交通碳排放进行分析。

2.3 超参数调优

随机森林是装袋树的升级版, 其运行的主要参数是最大分类树数量和决策树弱分类器个数, 其工作流程如图 4 所示。通常参数调优的方法是贝叶斯调参和网格搜索, 贝叶斯调参的特点是调参过程利用到历史信息进行搜索, 这使得超参数调优更加高效, 适合多参数调优; 网格搜索^[19]的特点是很大概率能找到参数最优模型, 但需要消耗较多的计算资源和时间。而本文对随机森林分类预测模型寻优的参数只有 2 个, 所以选择网格搜索对模型进行调参。

将待搜索参数 MaxNumSplits 和 NumlearningCycles 在一定的空间范围内划分长短相同的网格, 同时遍历网格内所有的点进行取值, 最优参数为使得整个随机森林分类模型的系统性能最优。在寻找最优参数时, 如果设置的参数网格范围较大且步长较小, 那么搜索过程将会非常耗时。为了减少搜索范围, 将步长设置偏大。随机森林分类预测模型参数网格寻优步骤如下:

- 1) 确定参数选择范围。令 MaxNumSplits = [100, 250, 400, 550, 779], NumlearningCycles = [10, 400], 选取步长为 20。
- 2) 利用 k 折交叉验证的方式对每个测试子集做预测, 并统计在该组参数下的 $F_{1\text{Micro}}$ 分数。
- 3) 对最后所有决策树的结果进行投票, 选取 $F_{1\text{Micro}}$ 分数最高的一组作为网格寻优的最优参数组合。

随机森林分类预测模型参数的筛选热力图如图 5 所示, 可见, 当决策树个数为 390、最大分裂数为 250 时, $F_{1\text{Micro}}$ 分数最大, 为 0.867 2。




图 3 模型 ROC 曲线及 AUC 值
Fig.3 Model ROC curve and AUC values

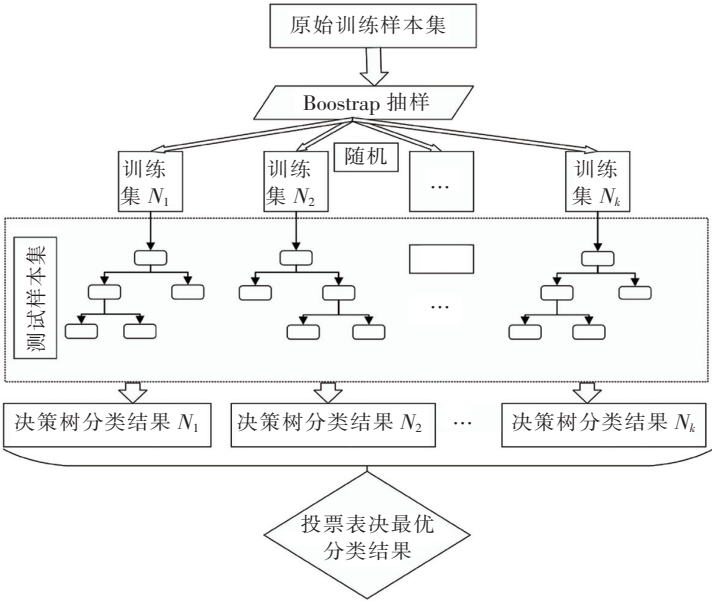


图 4 随机森林建模流程图
Fig.4 Stochastic deep forest modelling flowchart




图 5 网格搜索热力图
Fig.5 Grid search heat map

3 研究结果与分析

3.1 交通碳排放影响因素年增长率

对节 1.3.2 中分析的重要程度较高的 6 个影响因素进行年增长率分析，考虑到城市发展水平不统一，将城市交通碳排放各影响因素的年增长率统一化为全国范围内的各因素增长率。同时，为方便计算，将预测各影响因素的基准年增长率根据实际情况进行取整处理，结果如下：

- 1) 全国人均 GDP 的变化趋势如图 6a 所示，可见，近 6 年人均 GDP 平均年增长率为 5.19%。考虑到疫情、经济发展及十四五规划等因素影响，设置预测城市人均 GDP 的基准年增长率为 5%。
- 2) 我国新能源汽车销量呈持续爆发式增长，占比也不断增加，其变化趋势如图 6b 所示，可见，近 6 年新能源汽车销量占比年增长率平均为 49.2%。鉴于我国不断推动汽车产业的电动化发展，设置预测新能源汽车销量占比的基准年增长率为 50%。
- 3) 根据中国充电联盟所统计的公共充电桩数量变化趋势如图 6c 所示，可见，近 6 年公共充电桩数量的年增长率平均为 52.82%，设置预测公共充电桩数量的基准年增长率为 55%。
- 4) 交通运输产业属于国民经济中的第三产业，对历年第三产业总值进行统计，其变化趋势如图 6d 所示，近 6 年第三产业总值的年增长率平均为 7.72%，设置预测第三产业总值的基准年增长率为 7%。
- 5) 电动公共汽车对减少碳排放、降低温室气体排放的意义重大。对电动公共汽车营运数量进行统计，变化趋势如图 6e 所示，可见，近 6 年电动公共汽车营运数量的年增长率平均为 8.3%。考虑到我国不断推进公共领域车辆电动化的发展，设置预测电动公共汽车营运数量的基准年增长率为 10%。
- 6) 对我国公路货运量进行统计，其变化趋势如图 6f 所示，可见，近 6 年公路货运量的年增长率平均为 0.82%。由于疫情影响，公路货运量在 2020 年发生大幅变化，所以为了排除异常因素，只对 2016—2019 年的公路货运量进行计算，其年增长率为 3.47%。考虑到公路运输几乎涵盖了现代社会生活各方面，公路运输量还会继续增长，所以设置预测公路货运量的基准年增长率为 5%。

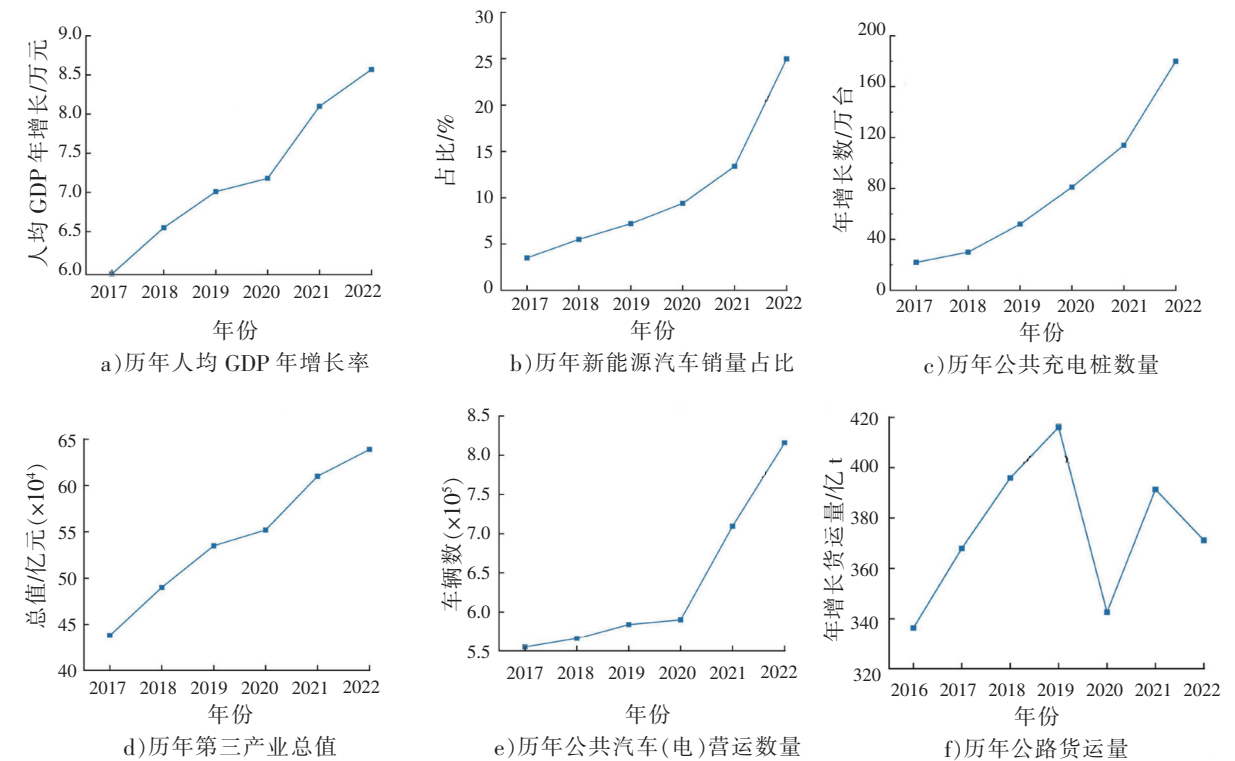


图 6 各影响因素年增长率趋势图
Fig.6 Trends in annual growth rates of impact factors

3.2 交通碳排放预测

使用经参数调优后的 RF-GS 分类预测模型, 并根据节 3.1 中各影响因素设置的年增长率, 对 2023—2024 年的城市交通碳排放等级分布情况进行预测, 结果如图 7 所示, 可见, 2023—2024 年, 等级 1 和等级 2 的城市数量相较于 2021 年分别减少了 11% 和 14%。这说明城市交通碳排放量还在持续上升, 急需各城市进行政策调整来减缓城市交通碳排放的上升趋势。

为研究城市交通对碳排放的影响, 对交通运输维度的 4 个影响因素设置不同年增长率进行预测分析。为了研究不同交通维度情境下的碳排放城市等级变化, 对每个影响因素的年增长率进行增高和降低, 其中: 新能源汽车销量的年增长率设为 30%, 50%, 70%; 公共充电桩数量的年增长率设为 40%, 55%, 70%; 公共汽车(电)营运数量的年增长率设为 5%, 10%, 15%; 公路货运量的年增长率设为 3%, 5%, 7%。分别对交通运输维度的 4 个影响因素预测分析不同增速下的城市交通碳排放等级分布情况, 情境分析的年限为 2023 年, 结果如图 8 所示。由图 8 可得到以下 4 点结论。

1) 除新能源汽车销量因素外, 其他 5 个影响因素在同一增速的情况下, 新能源汽车销量年增长率越高, 处于交通碳排放低等级的城市数就越多。增速为 70% 的等级 1 和等级 2 的城市数量比增速为 50% 的多 8.99%, 增速为 30% 的等级 1 和等级 2 的城市数量比增速为 50% 的少 7.87%。这表明, 新能源汽车的增加可有效缓解城市交通碳排放的压力。

2) 除公共充电桩建设数量因素外, 其他 5 个影响因素在同一增速下, 随着公共充电桩建设数量年增长率的增加, 交通碳排放低等级的城市数量也随之增多。增速为 70% 的等级 1 和等级 2 的城市数量比增速为 55% 的多 4.49%, 增速为 40% 的等级 1 和等级 2 的城市数量比增速为 55% 的少 14.61%。这表明, 公共充电桩的建设推动了交通低碳化的发展, 但建设增速较低可能会对城市交通带来更多减排压力。

3) 除电动公共汽车营运数量因素外, 其他 5 个影响因素在同一增速下, 随着电动公共汽车营运数量年增长率的增加, 交通碳排放低等级的城市数量也会增多。其年增长率为 15% 的等级 1 和等级 2 的城市数量比年增长率为 10% 的多 2.25%, 年增长率为 5% 的等级 1 和等级 2 的城市数量比年增长率为 10% 的少 5.62%。然而, 相较于新能源汽车和公共充电桩建设, 电动公共汽车的碳减排效果并不明显。这表明, 在减少城市交通碳排放的过程中, 不仅要支持电动公共汽车的营运, 更要积极推动私家车、出租车等燃油汽车向新能源转型。






图 7 城市交通碳排放等级分布预测
Fig.7 Projected carbon class distribution of urban transport



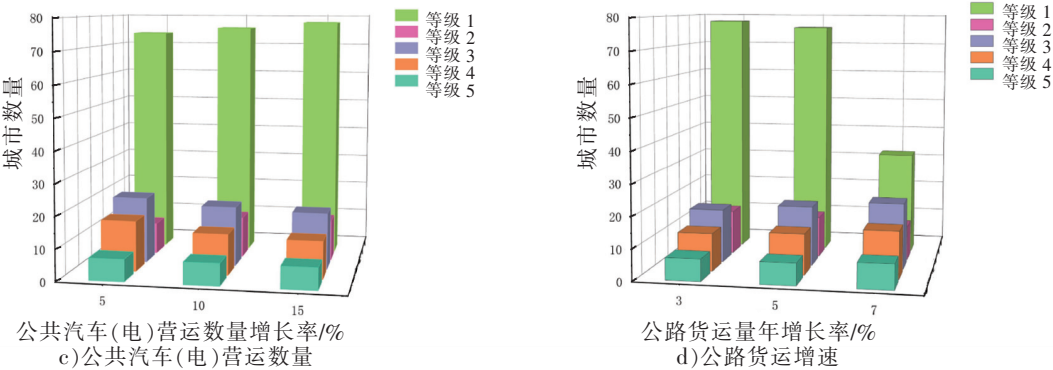


图 8 2023 年不同影响因素增速下的城市交通碳排放等级分布

Fig.8 Carbon emission class distribution of urban transport under different growth rates of influencing factors in 2023

4) 除公路货运量因素外,其他 5 个影响因素在同一增速下,公路货运量的年增长率越高,处于交通碳排放低等级的城市数量越少。增速为 7% 的等级 1 和等级 2 的城市数量比增速为 5% 的少 5.62%,增速为 3% 的等级 1 和等级 2 的城市数量比增速为 5% 的多 3.37%。这表明,减少公路货运量或调整公路货运模式,可以对城市交通的碳减排起积极作用,因此,有必要合理控制公路货运碳排放,通过优化运输结构和转换运输车辆类型来降低城市交通的碳减排压力。

综上所述,随着时间的推移,若各城市交通碳排放影响因素的年增长率增速提高,则新能源汽车的占比对于减少交通碳排放尤为重要;若增速减缓,则充电桩建设的数量对交通碳排放的影响最大。这表明,如果各城市交通碳排放影响因素的年增长率保持较高水平,则新能源汽车的占比对于减少交通碳排放的重要性将进一步凸显。应加大对新能源汽车的推广力度,通过政策支持和技术创新,提高其在交通系统中的占比,从而有效降低整体碳排放水平。然而,如果新能源汽车增速减缓,特别是新能源汽车在市场增长趋缓的情况下,充电桩建设的数量将成为关键的影响因素。此时,建议加强对充电桩基础设施的投资和建设,以确保充电设施数量的充足和充电的便捷性。可以通过制定政策激励措施,提高其覆盖范围,促使更多人选择使用电动汽车,从而为城市交通碳排放的降低做出更为持续和全面的贡献。

4 结论

本文通过“自上而下”的碳排放系数法对不同层级的城市交通人均碳排放进行测算,鉴于各市的不同实际条件可能会导致测算精度的偏差,故对测算结果进行了等级划分。通过拓展 STIRPAT 模型和随机森林评价指标重要性的特性对影响因素进行筛选;利用 RF-GS 模型对各市城市交通人均碳排放进行预测,并通过调整交通运输维度 4 个影响因素年增长率的方式,对城市碳排放等级数量进行预测分析。结果表明,新能源汽车占比的年增长率增加更能减缓城市交通碳排放的上升趋势,而减少公共充电桩建设的年增长率则会加剧城市交通碳排放的上升趋势;同时,减少公路货运量的年增长率将减缓城市交通碳排放的上升趋势。

本文提出的城市碳排放划分等级的思想,可以有效地对各城市碳排放量及影响因素进行预测分析,为我国城市交通碳减排体系建设提供了一定的借鉴意义。此外,考虑到每个城市交通碳排放数据的可获取性,本文仅使用了 130 个市的数据构建模型分析,可能会导致分析结果存在偶然性和特殊性。更综合地考虑城市交通碳排放影响因素,是今后进一步探索的方向。

[参考文献]

[1]姜克隽. IPCC AR6:长期减排路径[J]. 气候变化研究进展,2023,19(2):133-138.
[2]BERNSTEIN L,BOSCH P,CANZIANI O,et al. summary for policy makers[C]//IPCC Fourth Assessment Report. Bangkok, <http://xuebaobangong.jmu.edu.cn/zkb>

Thailand;IPCC,2007.

[3] 汽车维修. 2022 年新能源车百人会[EB/OL]. (2022-03-27)[2023-03-27]. <https://www.hfyili.cn/a/122386/>. 2022-03-27.

[4] GONZALEZ P F, LANDAJO M. Tracking European Union CO₂ emissions through LMDI(logarithmic mean divisia index decomposition;the activity revaluation approach[J]. Energy Policy,2009(8):3259-3267.

[5] 高标,房骄,李玉波. 基于 STIRPAT 模型的区域农业碳排放影响因素分析[J]. 环境科学与技术,2016,39(10):190-197.

[6] 胡那. 北京市交通运输业碳生产率及其影响因素研究[D]. 北京:北京工业大学,2014.

[7] 武翠芳,熊金辉,吴万才,等. 基于 STIRPAT 模型的甘肃省交通碳排放测算及影响因素分析[J]. 冰川冻土,2015,37(3):826-834.

[8] TIMILSINA G R, SHRESTHA A. Transport sector CO₂ emissions growth in Asia;underlying factors andpolicy options[J]. Energy Policy,2009,37(11):4523-4539.

[9] SHABBIR R, AHMAD S S. Monitoring urban transport air pollution and energy demand in Rawalpindiand Islamabad using leap model[J]. Energy,2010,35(5):2323-2332.

[10] LIIMATAINEN H, KALLIONPAEAE E, POELLAENEN M, et al. Decarbonizing road freight in the future;detailed scenarios of the carbon emissions of finnish road freight transport in 2030 using a delphimethod approach[J]. Technological Forecasting & Social Change,2014,81(1):177-191.

[11] 陈露露,赵小风,赖力. 江苏省交通运输业碳排放预测及减排情景分析研究[J]. 环境科学与管理,2015,40(10):13-17.

[12] EGGLESTON S, BUENDIA L, MIWA K, et al. 2006 IPCC guidelines for national greenhouse gas inventories[R]. Cambridge;Cambridge University Press,2006.

[13] 方晓丽,骆勇. 城市交通碳排放计算方法比较研究[J]. 交通节能与环保,2017,13(4):81-83.

[14] 国家统计局. 中国能源统计年鉴(2022 年)[M]. 北京:中国统计出版社,2022.

[15] ALTMANN A, TOLOSI L, SANDER O, et al. Permutation importance;a corrected feature importance measure[J]. Bioinformatics,2010,26(10):1340-1347.

[16] CAROLIN S, ANNE-LAURE B, THOMAS K, et al. Conditional variable importance for random forests[J]. BMC Bioinformatics,2008,9(1):307-307.

[17] BREIMAN L. Random forests[J]. Machine Learning,2001,45(1):5-32.

[18] BREIMAN L. Bagging predictors[J]. Machine Learning,1996,24(2):123-140.

(责任编辑 马建华 英文审校 郑青榕)