Advances in Applied Mathematics 应用数学进展, 2026, 15(11), 176-186
Published Online November 2026 in Hans. https://www.hanspub.org/journal/aam
https://doi.org/10.12677/aam.2026.1511441

Hans汉斯

一种融合Kaya恒等式约束的深度学习碳排放预测模型及其应用

邓淇元

成都理工大学数学科学学院，四川 成都

收稿日期：2026年10月17日；录用日期：2026年11月12日；发布日期：2026年11月17日

摘　要

在“双碳”目标背景下，服务业低碳转型成为区域绿色发展的重要方向。由于服务业碳排放受到人口规模、经济发展水平、产业结构、能源利用效率等多因素共同影响，传统预测方法难以有效刻画其复杂非线性变化规律。本文提出一种融合Kaya恒等式理论约束与Attention-LSTM网络的组合预测模型。首先，依据IPCC能源活动碳排放核算方法计算四川省服务业碳排放量，并利用地级市服务业增加值比例实现省级碳排放数据向市域尺度分解。其次，引入扩展型Kaya恒等式，将碳排放分解为人口规模、经济发展水平、产业结构、能源强度和能源消费碳强度等驱动因素，构建理论约束项；进一步利用LSTM网络提取时间序列非线性特征，并结合注意力机制增强关键历史信息提取能力。最后，通过可学习融合参数实现Kaya理论结果与深度学习预测结果的动态融合，并构建联合优化目标函数提升模型预测性能。以2005~2022年四川省服务业碳排放数据为研究对象，采用R^2、MAE和RMSE对模型进行评价。结果表明，所提出模型能够有效提升碳排放预测精度，为区域服务业低碳发展提供理论依据。

关键词

碳排放预测，Kaya恒等式，LSTM，服务业，四川省

A Deep Learning Carbon Emission Forecasting Model Integrating Kaya Identity Constraints and Its Application

Qiyuan Deng

School of Mathematical Science, Chengdu University of Technology, Chengdu Sichuan

Received: October 17, 2026; accepted: November 12, 2026; published: November 17, 2026

文章引用: 邓淇元. 一种融合 Kaya 恒等式约束的深度学习碳排放预测模型及其应用[J]. 应用数学进展, 2026, 15(11): 176-186. DOI: 10.12677/aam.2026.1511441

Abstract

Against the backdrop of the "Dual Carbon" goals, the low-carbon transition of the service industry has become an important direction for regional green development. Since carbon emissions of the service industry are jointly affected by multiple factors including population size, economic development level, industrial structure and energy utilization efficiency, traditional prediction methods can hardly characterize its complex nonlinear variation law effectively. This paper proposes a hybrid prediction model integrating theoretical constraints of the Kaya Identity and the Attention-LSTM network. First, carbon emissions of the service industry in Sichuan Province are calculated based on the IPCC accounting method for carbon emissions from energy activities, and the proportion of service-added value at the prefectural city level is adopted to decompose provincial carbon emission data down to the municipal scale. Second, an extended Kaya Identity is introduced to decompose carbon emissions into driving factors such as population size, economic development level, industrial structure, energy intensity and carbon intensity of energy consumption, so as to construct a theoretical constraint term. Furthermore, the LSTM network is used to extract nonlinear features of time series, and the attention mechanism is combined to strengthen the capability of capturing critical historical information. Finally, learnable fusion parameters are applied to dynamically integrate the theoretical results from Kaya decomposition and deep learning prediction outputs, and a joint optimization objective function is established to improve the model's prediction performance. Taking the service industry carbon emission dataset of Sichuan Province during 2005~2022 as the research case, R^2, MAE and RMSE are adopted to evaluate the model. The results demonstrate that the proposed model can effectively improve the prediction accuracy of carbon emissions, which provides a theoretical basis for the low-carbon development of regional service industries.

Keywords

Carbon Emission Prediction, Kaya Identity, LSTM, Service Industry, Sichuan Province

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

近年来，全球气候变化问题不断加剧，减少温室气体排放、推动能源系统绿色转型已经成为国际社会共同关注的重要议题。《巴黎协定》提出将全球平均气温升高控制在较低水平以内，各国逐渐加强碳减排政策制定。IPCC 在气候变化评估报告中指出，人类活动产生的能源消费是二氧化碳排放增长的重要来源，因此建立科学有效的碳排放核算和预测方法对于制定减排措施具有重要意义[1]。

中国作为全球最大的能源消费国之一，近年来积极推进能源结构调整和绿色低碳发展，并提出 2030 年前实现碳达峰、2060 年前实现碳中和的发展目标[2]。在这一背景下，准确预测不同区域、不同行业未来碳排放趋势，对于优化能源配置、推动产业结构调整以及实现减排目标具有重要作用。

随着我国经济发展模式逐渐由工业驱动向服务经济转型，服务业在国民经济中的比重不断提高。与传统工业部门相比，服务业能源消费来源更加复杂，涉及交通运输、商业建筑、信息服务、金融等多个领域，其碳排放变化受到经济规模、人口增长、能源利用效率以及产业结构变化等多因素影响[3]。因此，建立适用于服务业特点的碳排放预测模型具有重要研究价值。

目前，碳排放预测方法主要包括因素分解模型、统计预测模型以及人工智能预测模型。其中，因素分解方法能够揭示碳排放变化的内在驱动机制。Kaya 恒等式由日本学者 Yoichi Kaya 提出，该方法将二氧化碳排放表示为人口规模、人均 GDP、能源强度以及能源碳强度四个因素的乘积形式，为分析碳排放变化原因提供了有效理论框架[4]。由于其结构清晰、变量具有明确经济含义，Kaya 恒等式被广泛应用于全球及区域碳排放影响因素分析研究中[5] [6]。

然而，Kaya 恒等式本质上属于因素分解方法，主要用于解释碳排放变化规律，对未来复杂时间序列预测能力有限。随着人工智能技术的发展，机器学习和深度学习方法逐渐应用于能源消耗和碳排放预测领域。其中，长短期记忆网络(Long Short-Term Memory, LSTM)作为循环神经网络的重要改进形式，通过引入门控机制有效解决了传统循环神经网络长期依赖问题，在时间序列预测领域表现出较好的应用效果[7] [8]。

近年来，已有研究尝试将因素分解模型与机器学习方法结合。例如，一些研究利用 STIRPAT 模型分析碳排放驱动因素，并结合机器学习方法提高预测能力[9] [10]；部分研究表明，将具有明确经济意义的影响因素输入深度学习模型，可以提升预测模型的解释能力和稳定性[11]。因此，将 Kaya 恒等式提供的机理信息与 LSTM 网络的非线性学习能力结合，能够充分发挥两类方法的优势。

四川省位于我国西部地区，是我国重要的经济和人口大省。近年来，随着产业结构调整和城镇化进程推进，服务业发展速度不断提高，服务业增加值占地区生产总值比例持续提升。同时，服务业能源消费规模逐渐扩大，其碳排放问题逐渐受到关注。然而，由于地级市服务业能源消费数据存在一定缺失，直接获取市域服务业碳排放数据存在困难。因此，本文首先依据 IPCC 能源消费排放核算方法计算四川省服务业碳排放总量，再结合各地级市服务业增加值比例进行空间分解，从而获得四川省各地区服务业碳排放数据。

基于上述背景，本文构建一种基于 Kaya-LSTM 的四川省服务业碳排放预测模型。首先利用 IPCC 方法计算服务业碳排放量；其次通过 Kaya 恒等式提取影响碳排放变化的关键因素；最后建立 LSTM 预测模型，实现未来服务业碳排放趋势预测。本文主要贡献如下：基于 IPCC 能源消费核算方法构建四川省服务业碳排放数据体系；利用服务业增加值比例实现省级碳排放向地级市尺度分解；构建 Kaya-LSTM 组合预测模型，提高服务业碳排放预测的准确性。

2. 数据来源与指标体系

2.1. 数据来源

本文选取四川省 2005~2022 年作为研究周期。数据主要来源于：《四川统计年鉴》[1]。

碳排放量采用 IPCC 能源消费计算方法：

$$C=\sum_{i=1}^{n}E_i\times \mathrm{EF}_i$$

其中：C 表示碳排放总量；E_i 表示第 i 类能源消费量；EF_i 表示对应能源排放因子。

由于地级市服务业能源消费数据存在缺失，本文采用服务业增加值比例进行空间分解。

第 j 个城市服务业碳排放：

$$C_j=C\times\frac{\mathrm{SI}_j}{\mathrm{SI}}$$

其中：C_j：第 j 个城市服务业碳排放量；SI_j：第 j 个城市服务业增加值；SI：四川省服务业增加值。

[1]https://tjj.sc.gov.cn/scstjj/c105855/nj.shtml

该方法能够保证省级服务业碳排放总量与市级加总结果一致。

2.2. 指标体系构建

结合下文中改进型 Kaya 恒等式将碳排放影响因素分解为五个变量。因此，文章使用这五个变量为碳排放影响因素——人口、经济、产业结构、能源强度和碳强度，详细见表 1。

Table 1. Sichuan province carbon emissions forecast indicator system
表 1. 四川省碳排放预测指标体系

类别	指标	符号	单位
人口因素	常住人口	P	万人
经济因素	人均 GDP	PCG	万元/人
产业结构因素	服务业百分比	PSI	%
能源强度因素	能源强度	EI	TCE/万元
碳强度因素	碳强度	CIE	吨/TCE

3. 方法

3.1. Kaya 恒等式

Kaya 恒等式是碳排放驱动因素解析领域的基础性分析工具，具备多因素系统研判、灵活性强且可拓展性高的显著优势，被广泛应用于碳排放驱动机制相关研究。基于上述特性，本文以 Kaya 恒等式的等式守恒原理为核心依据，开展服务业碳排放驱动效应分析。传统 Kaya 恒等式适用于全产业碳排放测算，无法直接适配本文以服务业为研究主体的研究场景。为此，本文对传统 Kaya 恒等式进行优化改进，引入服务业产值占比变量，实现服务业碳排放的有效分解：

$$C_{i,t} = P_{i,t} \times \frac{\mathrm{GDP}_{i,t}}{P_{i,t}} \times \frac{\mathrm{SI}_{i,t}}{\mathrm{GDP}_{i,t}} \times \frac{\mathrm{EC}_{i,t}}{\mathrm{SI}_{i,t}} \times \frac{C_{i,t}}{\mathrm{EC}_{i,t}}$$
$$= P_{i,t} \times \mathrm{PCG}_{i,t} \times \mathrm{PSI}_{i,t} \times \mathrm{EI}_{i,t} \times \mathrm{CIE}_{i,t}$$

以城市(i)和年份(t)为分析维度。$C_{i,t}, P_{i,t}, \mathrm{GDP}_{i,t}, \mathrm{SI}_{i,t}$ 和 $\mathrm{EC}_{i,t}$ 分别表示城市在年的碳排放量，常住人口，区域 GDP，服务业产出和能源消费量。

3.2. LSTM 预测模型

长短期记忆网络(Long Short-Term Memory, LSTM)是一种改进型循环神经网络(Recurrent Neural Network, RNN)，通过引入门控机制解决传统 RNN 在长期序列学习过程中存在的梯度消失问题。LSTM 主要由遗忘门、输入门、候选记忆状态、细胞状态以及输出门组成。

(1) 遗忘门

遗忘门用于决定上一时刻细胞状态中需要保留的信息，其计算公式为：

$$f_t = \sigma\left(W_f\left[h_{t-1}, x_t\right] + b_f\right)$$

其中：f_t：遗忘门输出结果；$\sigma(\cdot)$：Sigmoid 激活函数；W_f：遗忘门权重矩阵；h_{t-1}：上一时刻隐藏状态；x_t：当前时刻输入变量；b_f：遗忘门偏置项。

遗忘门的作用是控制历史信息的保留程度。

(2) 输入门：

输入门用于控制当前输入信息对细胞状态的影响：

$$i_t = \sigma\left(W_i\left[h_{t-1}, x_t\right] + b_i\right)$$

其中：i_t：输入门输出；W_i：输入门权重矩阵；b_i：输入门偏置项。

同时，LSTM 计算当前候选记忆信息：

$$\tilde{C}_t = \tanh\left(W_c\left[h_{t-1}, x_t\right] + b_c\right)$$

其中：$\tilde{C}_t$：候选细胞状态；W_c：候选状态权重；b_c：候选状态偏置；$\tanh(\cdot)$：双曲正切激活函数。

(3) 细胞状态更新：

LSTM 通过遗忘门和输入门共同更新长期记忆：

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

其中：C_t：当前时刻细胞状态；C_{t-1}：上一时刻细胞状态；$*$：对应元素乘法。

该公式表示：

第一部分：

$$f_t * C_{t-1}$$

表示保留历史信息。

第二部分：

$$i_t * \tilde{C}_t$$

表示加入新的输入信息。

(4) 输出门：

输出门决定当前时刻隐藏状态输出：

$$o_t = \sigma\left(W_o\left[h_{t-1}, x_t\right] + b_o\right)$$

其中：o_t：输出门状态；W_o：输出权重矩阵；b_o：输出偏置项。

隐藏状态：

$$h_t = o_t * \tanh\left(C_t\right)$$

其中：h_t：当前时刻隐藏状态；C_t：当前细胞状态。

隐藏状态包含 LSTM 提取的时间序列特征。

(5) 碳排放输出：

最终通过全连接层得到碳排放预测值：

$$\hat{Y}_t = W_y h_t + b_y$$

其中：$\hat{Y}_t$：模型预测的碳排放量；W_y：输出层权重；h_t：LSTM 隐藏层输出；b_y：输出层偏置。

4. Kaya-LSTM 组合预测模型

与其他模型相比，LSTM 模型具有能缓解梯度消失、捕捉长距离依赖、拟合非线性模式且计算复杂度较低的优势。但存在参数多易过拟合、全局结构建模弱、解释性差等不足。引入 Kaya 恒等式约束，可嵌入先验因果关系，弥补其对结构化信息利用不足，提升合理性与可解释性。

模型整体结构包括三个核心模块：

(1) LSTM 时间特征提取模块。利用 LSTM 网络对四川省服务业碳排放相关指标的历史演化规律进行学习，捕获经济变量与碳排放之间复杂的长期依赖关系。

(2) 注意力机制增强模块。通过计算不同时间步隐藏状态的重要性权重，使模型能够自动识别影响未来碳排放预测的关键历史阶段，提高模型对重要信息的关注能力。

(3) 改进 Kaya 理论融合模块。基于扩展 Kaya 恒等式计算理论预测值，并通过可学习权重机制将 Kaya 理论输出与 LSTM 数据驱动预测结果进行动态融合，使模型兼具理论解释能力和预测精度。

整体模型结构如下：

$$X_t \to \text{LSTM} \to h_t$$

$$h_t \to \text{Attention} \to H$$

$$\text{Kaya}\left(X_t\right) \to C_K$$

$$\left(C_K, H\right) \to \text{FusionLayer} \to \hat{C}_t$$

其中，X_t 表示第 t 时期输入变量，h_t 表示 LSTM 隐藏状态，H 表示经过注意力加权后的时间特征表示，C_K 表示 Kaya 恒等式计算得到的理论碳排放值，$\hat{C}_t$ 表示最终预测结果。

(1) Attention 注意力机制

为了提高模型对关键时间信息的识别能力，引入注意力机制。

首先计算隐藏状态与编码输出之间的相关程度：

$$e_t = v^{\mathrm{T}} \tanh\left(W_a\left[h_t, H_t\right]\right)$$

然后采用 Softmax 函数获得注意力权重：

$$a_t = \frac{\exp\left(e_t\right)}{\sum_{i=1}^{T} \exp\left(e_i\right)}$$

最终得到加权时间特征：

$$H = \sum_{t=1}^{T} a_t h_t$$

其中：a_t 表示第 t 个时间步的重要程度。

该过程使模型能够自动选择对未来碳排放变化贡献较大的历史阶段。

(2) Kaya 约束融合预测模型

传统 LSTM 预测：

$$\hat{C}_{\text{LSTM}} = W_h H + b_h$$

本文提出 Kaya-LSTM 融合预测：

$$\hat{C}_t = W_h H_t + b_h + \lambda f_K\left(Z_t\right)$$

即：

$$\hat{C}_t = \hat{C}_{\text{LSTM},t} + \lambda C_{\text{Kaya},t}$$

其中：$\hat{C}_{\text{LSTM},t}$：数据驱动预测结果；$C_{\text{Kaya},t}$：理论约束结果；λ：可学习融合系数。

与固定权重模型不同，本文令：

$$\lambda \in R$$

并通过梯度下降自动优化：

$$\lambda^{k+1} = \lambda^k - \eta \frac{\partial \text{Loss}}{\partial \lambda}$$

因此模型能够根据历史数据自动调整理论模型和数据模型之间的贡献比例。

(3) 理论约束联合优化目标函数

为了同时保证预测精度和 Kaya 理论一致性，建立联合优化函数：

$$\mathrm{Loss}(\Theta)=\mathrm{Loss}_{\mathrm{data}}+\beta\mathrm{Loss}_{\mathrm{Kaya}}$$

其中：

数据拟合误差采用均方误差：

$$\mathrm{Loss}_{\mathrm{data}}=\frac{1}{N}\sum_{i=1}^{N}(y_i-\hat{y}_i)^2$$

Kaya 一致性约束定义：

$$\mathrm{Loss}_{\mathrm{Kaya}}=\frac{1}{N}\sum_{i=1}^{N}\rho(\hat{y}_i-C_{\mathrm{Kaya},i})$$

其中：

$$\rho(x)=\begin{cases}\frac{1}{2}x^2, |x|\le\delta\\ \delta\left(|x|-\frac{1}{2}\delta\right), |x|>\delta\end{cases}$$

为 Huber 损失函数。

因此最终优化问题为：

$$\min_{\Theta}\left[\frac{1}{N}\sum_{i=1}^{N}(y_i-\hat{y}_i)^2+\beta\frac{1}{N}\sum_{i=1}^{N}\rho(\hat{y}_i-C_{\mathrm{Kaya},i})\right]$$

其中：

$$\Theta=\{W,b,\lambda\}$$

表示模型全部待优化参数。

5. 实验分析

5.1. 模型评价指标

为了评价不同模型对四川省碳排放的预测性能，本文选取决定系数(R^2)、平均绝对误差(MAE)和均方根误差(RMSE)作为模型评价指标。

(1) 决定系数 R^2

决定系数用于衡量模型预测值与真实值之间的拟合程度，其表达式为：

$$R^2=1-\frac{\sum_{t=1}^{m}(y_t-\hat{y}_t)^2}{\sum_{t=1}^{m}(y_t-\bar{y})^2}$$

其中： y_t 表示实际碳排放值； $\hat{y}_t$ 表示模型预测值； $\bar{y}$ 表示实际值平均值。

R^2 越接近 1，说明模型拟合效果越好。

(2) 平均绝对误差 MAE

MAE 用于描述预测值与真实值之间的平均偏差：

$$\mathrm{MAE}=\frac{1}{m}\sum_{t=1}^{m}|y_t-\hat{y}_t|$$

MAE 值越小，说明模型预测误差越低。

(3) 均方根误差 RMSE

RMSE 能够反映预测误差的整体波动情况：

$$\mathrm{RMSE}=\sqrt{\frac{1}{m}\sum_{t=1}^{m}\left(y_t-\hat{y}_t\right)^2}$$

RMSE 越小，表示模型预测精度越高。

5.2. 不同模型预测性能比较

本研究将四川省 2005~2022 年的服务业碳排放量数据设为输出变量，影响碳排放因素的数据设为输入变量；并从所选数据中按照时间序列的前 80%作为训练集，后 20%用于检验模型的准确性及回归预测性能。选取 ARIMA、BP 神经网络、LSTM 以及 Kaya-LSTM 模型进行对比实验，结果比较见图 1。

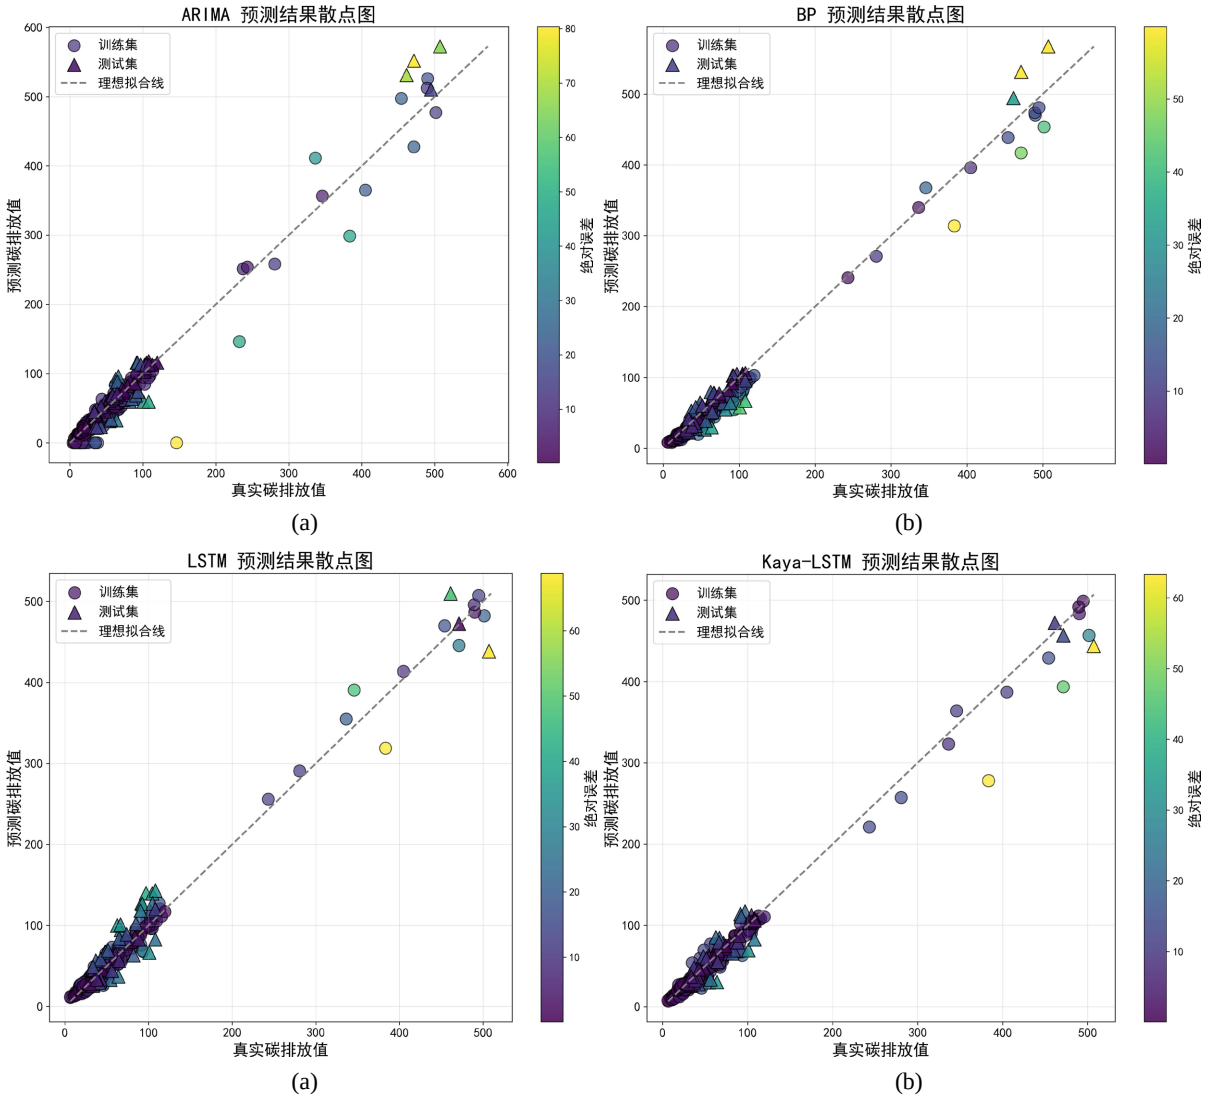


Figure 1. Comparison of results from point prediction models

图 1. 点预测模型结果比较

Table 2. Comparison of prediction results from different models
表 2. 不同模型预测结果比较

模型	R^2	MAE	RMSE
ARIMA	0.9565	12.43	19.39
BP	0.9642	11.35	17.37
LSTM	0.9488	15.81	20.78
Kaya-LSTM	**0.9778**	**9.31**	**13.42**

为评价不同模型的预测性能，本文采用决定系数(R^2)、平均绝对误差(MAE)和均方根误差(RMSE)作为模型评价指标，详细结果见表 2。由评价结果可知，ARIMA、BP、LSTM 和 Kaya-LSTM 四种模型均具有较好的预测能力，R^2 均达到 0.94 以上，说明各模型均能够较好地拟合真实值变化趋势。其中，ARIMA 模型的 R^2 为 0.9565，MAE 和 RMSE 分别为 12.43 和 19.39，表明传统时间序列模型能够有效反映数据变化规律，但对于复杂非线性特征的刻画能力仍存在一定不足。BP 模型的 R^2 达到 0.9642，MAE 和 RMSE 分别降低至 11.35 和 17.37，相较 ARIMA 模型预测精度有所提升，说明神经网络模型在处理非线性关系方面具有一定优势。

LSTM 模型的 R^2 为 0.9488，MAE 和 RMSE 分别为 15.81 和 20.78，整体预测效果低于其他模型。虽然 LSTM 具有较强的时间序列特征学习能力，但单一深度学习模型在样本特征提取方面存在一定局限，导致部分预测结果偏离真实值。相比之下，Kaya-LSTM 模型表现出最优的预测性能，其中 R^2 达到 0.9778，MAE 和 RMSE 分别降低至 9.31 和 13.42，均优于其他三种模型，表明该模型具有更高的拟合精度和更强的预测稳定性。

从预测结果散点图可以看出，各模型预测值总体均分布于理想拟合线附近，能够较好地反映真实值变化趋势。其中，Kaya-LSTM 模型的预测点与参考线重合度最高，在高值区间和低值密集区域均保持较小偏差，表现出更强的泛化能力。这主要得益于 Kaya 因素分解方法能够有效提取关键驱动因素，并结合 LSTM 网络对时间序列动态特征的学习能力，提高了模型对复杂变化规律的识别能力。因此，Kaya-LSTM 模型在预测精度和稳定性方面均具有明显优势，更适合作为后续预测分析模型。

5.3. 预测结果分析

基于构建的 Kaya-LSTM 预测模型，进一步对 2023~2035 年四川省服务业碳排放变化趋势进行了预测，结果见图 2。

由预测结果可知，未来服务业碳排放整体呈现出先增长后下降的倒“U”型变化趋势，表现出明显的碳达峰特征。2023 年服务业碳排放预测值为 1714.34 万吨，随后随着经济发展和服务业规模扩张，碳排放量继续保持增长态势，到 2031 年达到峰值 1965.40 万吨，随后逐渐下降，2035 年降低至 1885.64 万吨。预测期内碳排放峰值约出现在 2031 年前后，表明服务业将在经济增长与低碳转型共同作用下逐步实现碳排放达峰。

具体来看，2023~2030 年服务业碳排放量呈持续上升趋势，由 1714.34 万吨增加至 1956.74 万吨，累计增长约 14.14%。这一阶段主要受到经济持续发展、服务业规模扩大以及消费需求增长等因素影响，服务业能源消费需求仍处于扩张阶段，因此碳排放水平保持增长。同时，随着产业结构不断优化和服务业占比提升，碳排放增长速度逐渐趋缓，表明能源效率提升和低碳技术应用开始发挥抑制作用。

2031 年达到预测峰值后，服务业碳排放开始进入下降阶段。2031~2035 年碳排放量由 1965.40 万吨下降至 1885.64 万吨，减少约 4.06%。虽然下降幅度相对平缓，但反映出随着能源结构调整、能源利用效

率提高以及能源消费碳强度持续降低，服务业发展逐渐由高能耗增长模式向低碳发展模式转变。特别是在产业结构持续升级背景下，服务业对能源消耗的依赖程度逐步降低，推动碳排放进入稳定下降通道。

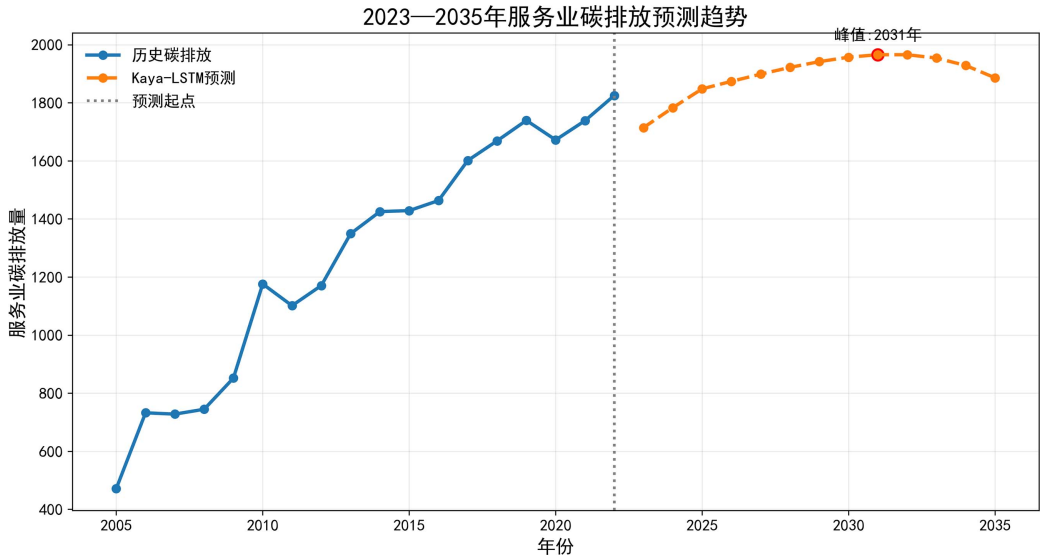


Figure 2. Prediction results of carbon emissions in the service industry
图 2. 服务业碳排放预测结果

从整体趋势来看，Kaya-LSTM 模型预测结果与服务业碳排放演变规律具有较好一致性。模型充分考虑了人口规模、经济发展水平、产业结构、能源强度以及能源消费碳强度等因素的综合影响，能够较好反映未来服务业碳排放变化过程。预测结果表明，未来服务业碳减排并非依靠限制产业发展实现，而是在经济增长、产业升级和能源效率提升协同作用下实现排放峰值后的逐步下降。因此，应进一步推动服务业绿色转型，加强清洁能源利用，提高能源利用效率，以促进服务业低碳发展目标的实现。

6. 结论

本文围绕四川省服务业碳排放预测问题，提出一种融合 Kaya 理论约束、注意力机制和 LSTM 网络的混合预测模型，通过构建理论约束项和联合优化目标函数，实现机理模型与数据驱动模型的协同预测。首先，依据 IPCC 能源活动碳排放核算方法测算 2005~2022 年四川省服务业碳排放量，并利用服务业增加值比例实现省级数据向地级市尺度的分解；随后通过扩展 Kaya 恒等式提取人口规模、经济发展水平、产业结构、能源强度和碳排放强度等关键影响因素，将其作为 LSTM 模型的输入变量，以提高模型对复杂非线性变化规律的刻画能力。

参考文献

[1] IPCC (2006) 2006 IPCC Guidelines for National Greenhouse Gas Inventories. Intergovernmental Panel on Climate Change.

[2] Zhang, X.P. and Cheng, X.M. (2009) Energy Consumption, Carbon Emissions, and Economic Growth in China. *Ecological Economics*, **68**, 2706-2712. https://doi.org/10.1016/j.ecolecon.2009.05.011

[3] Pao, H.T., Fu, H.C. and Tseng, C.L. (2012) Forecasting of CO_2 Emissions, Energy Consumption and Economic Growth in China Using an Improved Grey Model. *Energy*, **40**, 400-409. https://doi.org/10.1016/j.energy.2012.01.037

[4] Kaya, Y. and Yokobori, K. (1997) Environment, Energy, and Economy: Strategies for Sustainability. United Nations University Press.

[5] Raupach, M.R., Marland, G., Ciais, P., Le Quéré, C., Canadell, J.G., Klepper, G., *et al*. (2007) Global and Regional Drivers of Accelerating CO_2 Emissions. *Proceedings of the National Academy of Sciences*, **104**, 10288-10293. https://doi.org/10.1073/pnas.0700609104

[6] Štreimikienė, D. and Balezentis, T. (2016) Kaya Identity for Analysis of the Main Drivers of GHG Emissions and Feasibility to Implement EU "20-20-20" Targets in the Baltic States. *Renewable and Sustainable Energy Reviews*, **58**, 1108-1113. https://doi.org/10.1016/j.rser.2015.12.311

[7] Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation*, **9**, 1735-1780. https://doi.org/10.1162/neco.1997.9.8.1735

[8] Graves, A. and Schmidhuber, J. (2005) Framewise Phoneme Classification with Bidirectional LSTM and Other Neural Network Architectures. *Neural Networks*, **18**, 602-610. https://doi.org/10.1016/j.neunet.2005.06.042

[9] York, R., Rosa, E.A. and Dietz, T. (2003) STIRPAT, IPAT and Impact: Analytic Tools for Unpacking the Driving Forces of Environmental Impacts. *Ecological Economics*, **46**, 351-365. https://doi.org/10.1016/s0921-8009(03)00188-5

[10] Wang, C., Wang, F., Zhang, X., Yang, Y., Su, Y., Ye, Y., *et al*. (2017) Examining the Driving Factors of Energy Related Carbon Emissions Using the Extended STIRPAT Model Based on IPAT Identity in Xinjiang. *Renewable and Sustainable Energy Reviews*, **67**, 51-61. https://doi.org/10.1016/j.rser.2016.09.006

[11] Goodfellow, I., Bengio, Y. and Courville, A. (2016) Deep Learning. MIT Press.