恢复信息驱动的预测策略改进

Feng Li[a,*], Taozhu Ruan[b]

[a]北京大学光华管理学院，中国北京，*100871*[b]富国基金管理量化投资部，中国上海，*200122*

arXiv:2603.01085v1 [stat.AP] 1 Mar 2026

摘要

我们提出一个名为恢复信息驱动的策略改进（RISE）的三阶段框架，用于预测2019冠状病毒病疫情后中国出境旅游的复苏。该框架将预测分解为三个部分：初始预测、终端预测，以及连接这两个点的复苏曲线预测。我们整合多种信息来源，并在所有阶段采用预测组合技术，以提高复苏预测的准确性和稳健性。与传统预测方法相比，我们的框架提供了一套结构化、透明的流程，可在结构突变和高度不确定性的情况下，将基于模型的预测与专家判断相结合。研究结果证实了该框架的有效性，为后危机情境下的复苏轨迹预测提供了一种适应性工具。

关键词： 复苏预测、旅游预测、结构突变、预测组合、预测协调、专家判断。

1. 引言

旅游业是推动全球经济增长的关键力量。在新冠肺炎疫情暴发前，旅游业约占世界国内生产总值的10%，并为全球数亿人提供就业机会（联合国旅游组织，2019年）。旅游业与宏观经济、社会及环境系统存在复杂的相互联系，进一步凸显了其作为增长引擎和全球相互依存纽带的作用。国际旅游促进资本、文化和劳动力跨境流动，从而影响国际收支动态和区域发展。中国是最大的客源市场之一，在国际旅游中发挥着日益重要的作用，2019年出境游客人次超过1.5亿。旅游预测是指预测未来游客到访量和出境游客人次趋势的过程，对旅游业有效规划和决策至关重要，使利益相关者能够预判需求波动并高效配置资源。研究人员已提出多种预测方法，包括传统时间序列模型、深度学习模型和计量经济学方法，以提高预测准确性（Goh和Law，2011年；Song和Li，2008年）。

*Feng Li（ORCiD：0000-0002-4248-9778）为通讯作者。电话（传真）： +86 (0)10 62747602。作者按字母顺序排列。电子邮箱： feng.li@gsm.pku.edu.cn （Feng Li）， rtz12365784@outlook.com （Taozhu Ruan）

旅游业高度开放且依赖人员流动，因此尤其容易受到经济危机、自然灾害和公共卫生突发事件等全球冲击的影响。2019冠状病毒病（COVID-19）严重冲击了全球经济，导致多个行业普遍陷入停滞，其中旅游业受到的影响最为严重。国际和国内旅行大幅减少，迫使航空公司、酒店和旅游运营商关闭或以最低运力运营（Sigala，2020年）。大流行病还重塑了旅游需求结构，加快了数字化进程，改变了旅行者偏好，使其转向短途旅行，并加剧了旅行行为的不确定性。在中国大陆，受严格的边境管控措施、航班停飞和隔离要求影响，出境旅游几乎陷于停顿。随着世界迈入后疫情阶段，旅游业复苏已成为衡量更广泛的经济正常化和社会韧性的重要指标。因此，本文旨在构建一个结构化预测框架，系统整合基于定量模型的预测与定性人类判断，以支持在结构突变和高度不确定性背景下开展旅游业复苏预测，从而及时配置资源、制定营销策略并作出投资决策，推动受影响行业重建。

尽管如此，后疫情时期的旅游业复苏预测仍面临诸多相互交织的挑战。大流行病造成了深刻的结构突变，使历史数据部分失去时效性，并削弱了传统预测模型的假设。图1 显示，新冠肺炎疫情暴发导致旅游时间序列发生结构突变，使得无法直接依据历史模式预测未来。在这种情况下，复苏轨迹具有高度的不确定性和波动性，并受到不断变化的卫生政策、旅行者情绪和宏观经济状况的影响。不同地区和细分市场之间不存在普遍适用的复苏模式。其次，尽管一些研究承认在不确定性下专家判断的重要性，但很少有研究建立系统方法，将定量预测与人的判断相结合，尽管实证研究已表明，混合方法的表现优于纯统计预测或主观预测（Fildes等人，2009年；Petropoulos等人，2018年）。

我们提出了一种称为复苏信息引导的策略增强（RISE）的三阶段预测框架，用于预测COVID-19后中国出境旅游的复苏。在该框架中，我们将预测分为三个组成部分：初始预测、终端预测，以及连接初始预测和终端预测的复苏曲线预测。这种分解使我们能够针对预测的不同组成部分采用适当的假设和模型，同时通过将预测限制在初始预测和终端预测的范围内，增强整体稳健性。

通过将专家判断 嵌入系统化的定量框架，RISE 方法弥合了统计精度与情境适应性之间的鸿沟。这里的“专家判断”是指通过透明的评分规则和复苏系数融入框架的结构化分析师判断，而非直接征询外部专家的意见。这一方法创新提升了复苏预测的稳健性和可解释性，并为在结构突变和不确定性情境下进行预测提供了灵活的范本。

我们为2023年举办的新冠疫情期间旅游预测竞赛第二轮开发了这一框架。在竞赛中，参赛者必须利用截至2023年2月的历史数据，预测2023年8月至2024年7月中国前往20个指定目的地的出境游客人数。竞赛设有点—

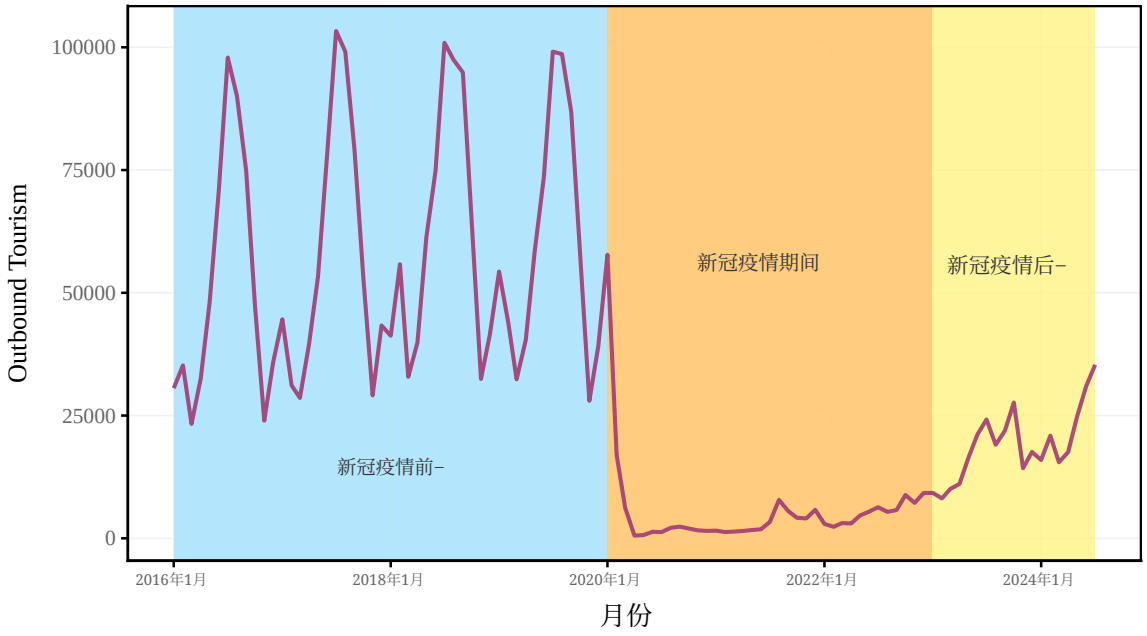

图1：中国出境旅游赴加拿大情况的三个时期。

预测和区间预测赛道。点预测根据平均绝对缩放误差进行评估。我们的成绩在新冠疫情期间旅游预测竞赛第二轮的点预测赛道中排名第一，在区间预测赛道中排名第三。其他参赛方案可参见Li等（2026）和Zhang等（2026）。

本研究的贡献主要体现在三个方面。理论上，本研究提出了一个统一框架，将定量建模与专家判断相结合，以应对结构突变和不确定性，从而拓展了危机后旅游预测领域的文献。RISE框架弥合了统计严谨性与情境适应性之间的差距，为将人类洞见纳入基于模型的预测提供了系统方法。方法上，本研究开发了一套三阶段预测系统，可动态整合历史模式、实时信号和启发式调整，显著提升预测稳健性和可解释性。实践上，该框架在预测 COVID-19 后中国出境旅游的复苏方面展现出卓越的预测表现，在旅游预测竞赛第二届的点预测赛道中排名第一，在区间预测赛道中排名第三。该框架还为政策制定者和行业从业者提供了一种实用且灵活的工具，用于评估旅游业复苏路径和资源配置策略，并可扩展应用于面临危机后复苏挑战的其他领域。

本文其余部分安排如下：第2 节回顾旅游预测方面的既有研究；第3 节详细介绍复苏信息驱动的策略增强框架，并阐述其三个阶段。第4 节展示评估结果，并在竞赛结束后进一步开展事后分析。最后，第5 节总结全文，着重强调本研究的方法论贡献及研究发现的政策含义。

2. 文献综述

随着全球旅游系统规模不断扩大、复杂性日益增加，旅游需求预测已成为政策制定者、从业者和研究人员面临的关键问题。在COVID-19疫情背景下，旅游业遭遇了前所未有的挑战；由于出现结构突变且宏观经济状况高度波动，预测国际旅游的复苏轨迹极其困难。在稳定条件下表现良好的传统模型方法，在危机后往往表现不佳。因此，文献综述部分将主要聚焦两个方面：（i）一般旅游预测方法；（ii）危机后旅游预测方法。

2.1. 旅游预测方法

在经济和制度条件相对稳定的情况下，旅游预测中应用最广泛的方法包括时间序列模型，如朴素方法、自回归模型、指数平滑模型、移动平均模型和历史平均模型。朴素方法是最容易采用、也最受旅游预测文献青睐的方法（Song & Li, 2008）。自回归积分滑动平均模型（ARIMA）及其季节性变体长期以来一直被视为旅游需求预测中的基准方法，因为它们能够同时对季节性和非季节性动态进行建模（Gunter & Önder, 2015; Lim & McAleer, 2001）。与之密切相关的指数平滑法——包括简单指数平滑、Holt线性趋势模型和Holt–Winters季节模型——提供了灵活且计算效率高的工具，可用于捕捉不断演变的趋势和季节性模式，并且在各种旅游需求时间序列中均表现出优异的预测性能（Athanasopoulos & Hyndman, 2008）。

随着旅游数据的数量不断增加、复杂性日益提高，非线性模型和数据驱动模型越来越多地应用于旅游预测，尤其是神经网络方法。其中，人工神经网络模型因能够适应数据缺陷，并在无需严格函数假设的情况下捕捉复杂的非线性关系而广受认可。这些特点使其在预测研究中得到广泛应用，尤其适用于需求动态呈现非线性和不稳定模式的情境（Palmer 等，2006）。与此同时，神经网络自回归模型通过允许非线性关系，拓展了传统自回归结构；当需求呈现复杂动态时，这类模型具有更强的灵活性（Salinas 等，2020）。

从数据来源的角度来看，有研究指出，社交媒体和搜索查询生成的变量能够有效预测旅游需求（Hu 等，2024；Li等，2023；Yang 等，2022）。风险稳定性也是影响旅游偏好的一个重要因素（Baláž 等，2024）。

鉴于模型结构和假设的多样性，越来越多的研究强调预测组合策略的价值。与依赖单一最佳模型不同，研究表明，综合多个单一模型的预测能够提高稳健性和准确性，尤其是在需求动态随时间变化时。在旅游预测领域，与单一模型相比，预测组合方法始终表现出更优或至少更稳定的性能，尤其是在跨目的地和跨市场情境下 (Andrawis 等，2011年)。

2.2. 危机后旅游预测方法

在金融冲击、流行病或大流行病等重大危机之后，由于结构突变、不确定性加剧以及复苏动态迅速演变，旅游需求预测变得更具挑战性(Perron，2006)。通常会采用针对这类时期精心设计的基于模型的方法。近年来，判断式预测和专家调整预测也广泛应用于旅游预测。这些方法与定量模型相结合，以提供更准确且更有依据的结果。

基于模型的方法依托成熟的统计框架进行危机后旅游预测，以刻画时间序列数据中的结构转变和动态模式。Goh and Law（2002）将季节性 ARIMA 模型与干预分析相结合，用于入境旅客预测，并考察冲击对旅游需求的影响，包括放宽出境游客签证签发限制、亚洲金融危机、政权交接和禽流感疫情。Chu（2008）在亚洲金融危机和九一一事件之后，将分数阶积分 ARMA 模型应用于旅游预测，并发现该方法在危机期间的表现优于其他方法。季节性 ARIMA 模型和干预模型也被用于估计危机的即时和短期影响。他们发现，严重急性呼吸综合征疫情后的旅游业复苏并非线性过程，而是具有阈值效应和滞后效应。由于风险感知存在差异，不同客源市场的复苏速度显著不同。时变参数模型也被用于模拟旅游预测中宏观经济环境的结构转变（Smeral，2017）。Wang and Li（2025）采用分段组合外生变量向量自回归模型，有效预测中国出境旅游，并纳入外生因素的时变效应。

Song and Lin（2010）采用自回归分布滞后法，研究了2008年金融经济危机期间亚洲的旅游流。通过纳入短期和长期动态，该模型能够细致分析国际游客到访量如何应对危机。研究结果显示，危机在短期内显著抑制了亚洲各地的旅游需求，但长期影响较为有限。Liu 等（2021）比较了自回归分布滞后法、结构时变参数回归及其他模型在模拟 COVID-19 后旅游需求复苏时的预测误差，发现结合多个模型能显著提升预测的稳健性和准确性。

近年来，深度学习方法也被应用于危机后旅游需求预测。Saayman and Botha（2017）指出，在旅游数据出现结构突变时，非线性方法优于其他方法。相关文献表明，深度学习方法能更有效地捕捉先急剧下降、再逐步复苏的非线性模式，为制定大流行后多情景预测提供支持。其他创新方法，如概率预测（Athanasopoulos 等，2023年）以及混合数据频率学习，也已被用于捕捉 COVID-19 时代前所未有的不确定性。

与基于模型的方法相比，判断式预测是指将人类专业知识、直觉和情境知识纳入预测过程的方法，既可以作为基于模型的预测的补充，也可以对其进行调整。大量预测研究表明，判断性输入能够提高预测准确度，尤其是在与定量模型结合时：统计模型提供基准预测，专家则根据相关的情境信息对其进行调整——

情境信息。许多研究表明，这种方法能够产生更准确的预测（Fildes等人，2009；van Dijk & Franses，2019）。

判断方法与专家调整在危机后旅游需求预测中发挥了关键作用，尤其是在应对COVID-19疫情时。例如，对旅游人数的统计预测所作的基于德尔菲法的判断调整提高了准确性（Lin 等，2014）。在应用中，Liu 等（2021）针对20个国家的入境旅游需求提出了一个两阶段、三情景预测框架。他们运用德尔菲法构建了COVID-19 恢复指数，用以衡量大流行病对各目的地的影响，并据此调整基准预测。Kourentzes 等（2021）通过对基准预测进行判断调整，预测了20个目的地的国际入境游客人数，其中纳入了专家对政策限制、疫苗研发、季节性及宏观经济状况的评估。Athana- sopoulos 等（2023年）进一步提出了一种以大规模专家调查为基础的基于情景的概率预测方法，用以刻画复苏路径中的不确定性。

尽管如此，上述文献仅聚焦于旅游预测挑战的单一层面。诸如COVID-19疫情之类的危机具有突发、不确定性和波动性等特征，使传统预测方法难以有效捕捉复苏动态。目前仍缺乏一个能够整合定量建模、实时外部指标及调整措施以预测复苏的系统性框架。

3. 预测框架

我们不依赖单一方法或一组方法，而是提出了一个三阶段框架，利用历史出境旅游时间序列以及当前外部信息，探索旅游业复苏的潜在路径。

RISE框架的主要特征是将旅游业复苏预测划分为三个不同部分：2023年6月之前的初始预测、2024年7月的终端预测，以及连接初始预测与终端预测、覆盖2023年7月至2024年6月的复苏曲线预测。术语定义列于表1中。不同于传统的旅游预测方法，RISE在时间和结构上分解了预测任务，使不同的假设和信息集能够在不同阶段发挥作用。重要的是，我们的方法在时间序列建模框架中融入了干预分析的要素(Box & Tiao, 1975)，旨在衡量外部或结构性变化（干预）对时间序列的影响。

RISE框架由三个依次衔接的阶段组成，旨在应对结构突变并预测旅游业复苏。第一阶段使用2020年之前的出境旅游数据构建基础预测，以表示在没有COVID-19情况下的反事实轨迹，并据此提取2024年7月的终端预测，再通过目的地特定的复苏系数进行调整，以考虑大流行病持续影响。第二阶段通过纳入高频外部信号（包括百度搜索指数和航班数据）获得初始预测，从而改善复苏早期的短期估计。最后一个阶段采用不同的函数形式——线性、二次和逻辑斯蒂——连接初始预测与终端预测，生成复苏曲线预测，以捕捉不同的复苏动态。总体而言，这些阶段将历史模式、实时信息和结构化判断整合到一个连贯的预测系统中，从而在高度不确定性下增强稳健性和可解释性。用于复现这些结果的计算机代码及相关数据可从作者的GitHub代码仓库获取，地址为 https://github.com/feng-li/RISE-Forecasting。

表1：三阶段预测框架和术语定义。

Name	定义	时间段
基础预测	假设不存在结构性断点时出境旅游的预期轨迹	2023年 –
	结构性突变。	1月
		2024年7月
参考预测	一条可及时验证的短期预测曲线	2023年2月 –
	方式。由 COVID-19 之后的预测组成，但时间早于	2023年6月
	复苏阶段。 我们采用截止日期之前的这段时间	
	来提交竞赛的预测值。	
初始预测	所有目的地参考预测曲线中的最后一个预测点	2023年6月
	曲线。	
终端预测	所有目的地预测时域的终点。	2024年7月
恢复系数	用于调整基础预测最后一个值的收缩因子，	
	从而得出终端预测。	
复苏曲线	连接初始预测点与终端	2023年6月—7月
	预测点的曲线。	2024

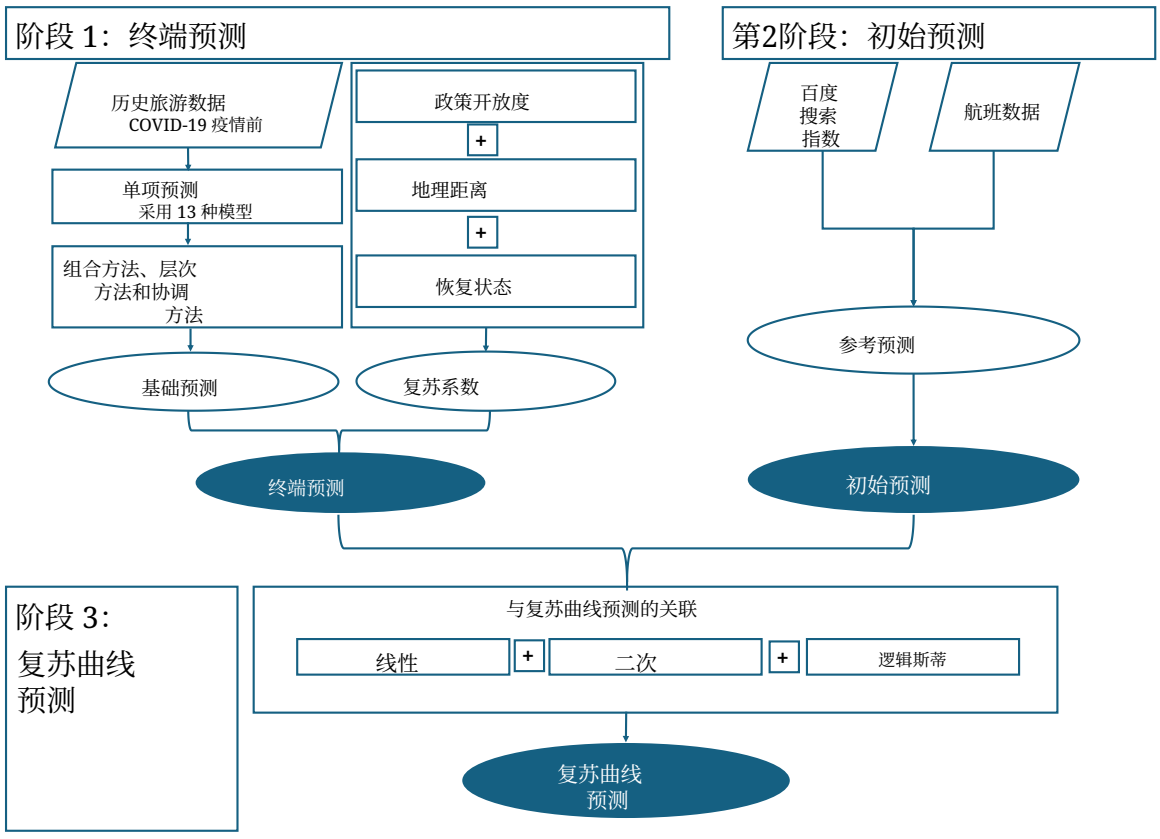

图2：恢复信息策略增强（RISE）框架流程图 .

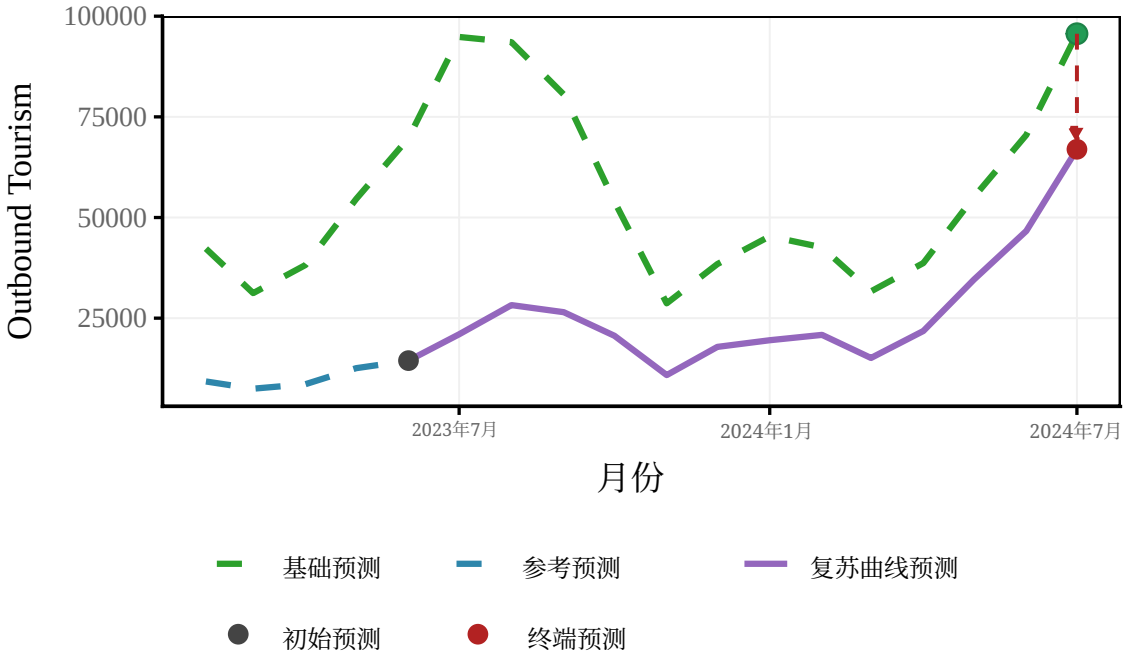

图3：恢复信息策略增强（RISE）框架示意图 .

3.1. 第一阶段——终端预测

在RISE框架中，终端预测代表预测期的终点，也就是出境旅游可能复苏至的水平。因此，为模拟不受COVID-19影响时中国大陆国际旅游的潜在情景，我们采用13种不同的预测模型以及三种预测组合方法，生成2023年至2024年的旅游基准预测，汇总见表2。2018年之前的时间序列数据用作训练集，2018年至2019年的数据则用作验证集。我们使用训练集构建各个模型，并根据验证集评估模型，以确定预测组合的最优参数。随后，将训练集和验证集合并，用于重新训练所有模型，从而预测接下来的两年，即在没有COVID-19影响的情境下，对2020年至2021年国际旅游情况进行预测。由此，这些预测可调整为中国出境旅游市场后疫情时期复苏的基准预测，具体涵盖2023年至2024年。

本文中使用的所有单个模型及其参数设置均列于表2中。15 种算法的训练过程均在R中执行。各方法通过R 程序包forecast (Hyndman 等人，2023年)中的相应函数进行估计。所有层次预测方法均使用R 程序包hts(Hyndman 等人，2024)中的函数执行。时间序列中的缺失值使用 `na_kalman()` 中的函数，采用卡尔曼平滑法进行插补。R 程序包imputeTS (Moritz 和 Bartz-Beielstein，2017)。

3.1.1. 单变量预测方法

我们的模型集合涵盖了多种预测方法，包括自回归技术、指数平滑方法、分解策略和神经网络

表2：个体预测模型和层次预测方法的描述 s.

模型	规格	参数设置
季节性朴素法	forecast 等于最近观测到的 同一季节 .	`snaive()`
自回归 Inte- 积分移动平均值	滞后项（p、 d、 q）由以下方法自动确定：Hyn- dman 和 Khandakar（2008）。	`auto.arima()`
带漂移的随机游走	相当于一个 ARIMA(0,1,0) 模型，并带有可选的 漂移系数。	`rwf(drift=True)`
指数平滑 状态空间模型	状态空间模型族，见Hyndman 等人（2002）	`ets(alpha=NULL,` `beta=NULL)`
Holt线性趋势	带趋势的指数平滑（Holt，1957）。	`holt(alpha=NULL,` `beta=NULL)`
Holt-Winters季节性方法	Holt方法的扩展，用于捕捉季节性（Holt， 1957；Winters，1960）	`hw(alpha=NULL,` `beta=NULL)`
季节性与趋势分- 使用局部加权回归进行分解	趋势分量通过ARIMA模型估计 而季节分量则通过以下方式估计 (A) 最近三年的季节分量平均值， (B) 去年的季节分量，以及 (C) 通过ARIMA估计。	`mstl(iterate=2,s.window=NULL)`
状态 空间 趋势– 季节性 ARMA 模型	带有 Box-Cox 变换、ARMA 的状态空间模型 误差、趋势和季节分量 （De Livera等人， 2011年）。	`tbats(use.trend=NULL,` `seasonal.periods=NULL)`
神经网络自回归 回归	采用一个隐藏层的前馈神经网络， 并将时间序列的滞后值用作输入。	`nnetar(p=12,P=1,size=7)`

层次方法	TopDown 层次化预测 将.....分配的
	将顶层预测向下分配到各层次中（Gross
	& Sohl，1990）。在方法名称中，字母 A/B 表
	示所确定的比例分配方法
	通过（A）单项预测和（B）历史出境
	旅游。
		`forecast(method="tdfp",`
		`fmethod="arima")`
		`forecast(method="tdfp",`
		`fmethod="ets")`
		`forecast(method="tdgsa",`
		`fmethod="arima")`
		`forecast(method="tdgsa",`
		`fmethod="ets")`

协调方法	可最小化
	总预测误差，同时确保聚合一致
	性。
	
	为其分配权重的加权最小二乘法
	层级结构的不同级别，以最小化调和-
	预测误差
		`forecast(method =`
		`"comb", weights =`
		
		`"mint")`
		
		`forecast(method =`
		`"comb", weights =`
		
		`"wls")`

以及层级预测模型。在所有模型中，有两种作为朴素基准方法：季节性朴素法和带漂移的随机游走模型。此外，我们还纳入了常用的自回归积分滑动平均（ARIMA）模型，以及三种指数平滑模型：简单指数平滑、Holt线性趋势模型和霍尔特-温特斯季节性模型。

为有效捕捉复杂季节性模式和趋势，我们纳入了三种模型：一种基于局部加权回归的季节性与趋势分解法（Cleveland 等人，1990），另一种采用结合 Box-Cox 变换、自回归移动平均误差以及趋势和季节性成分的指数平滑状态空间模型。此外，我们还纳入了神经网络自回归模型，该模型以时间序列滞后值作为输入来预测未来值，从而提升模型识别复杂时间依赖关系的能力。

3.1.2. 预测协调方法

上述独立预测未考虑空间相关性。来自20个目的地的旅游数据自然形成三级地理层次-

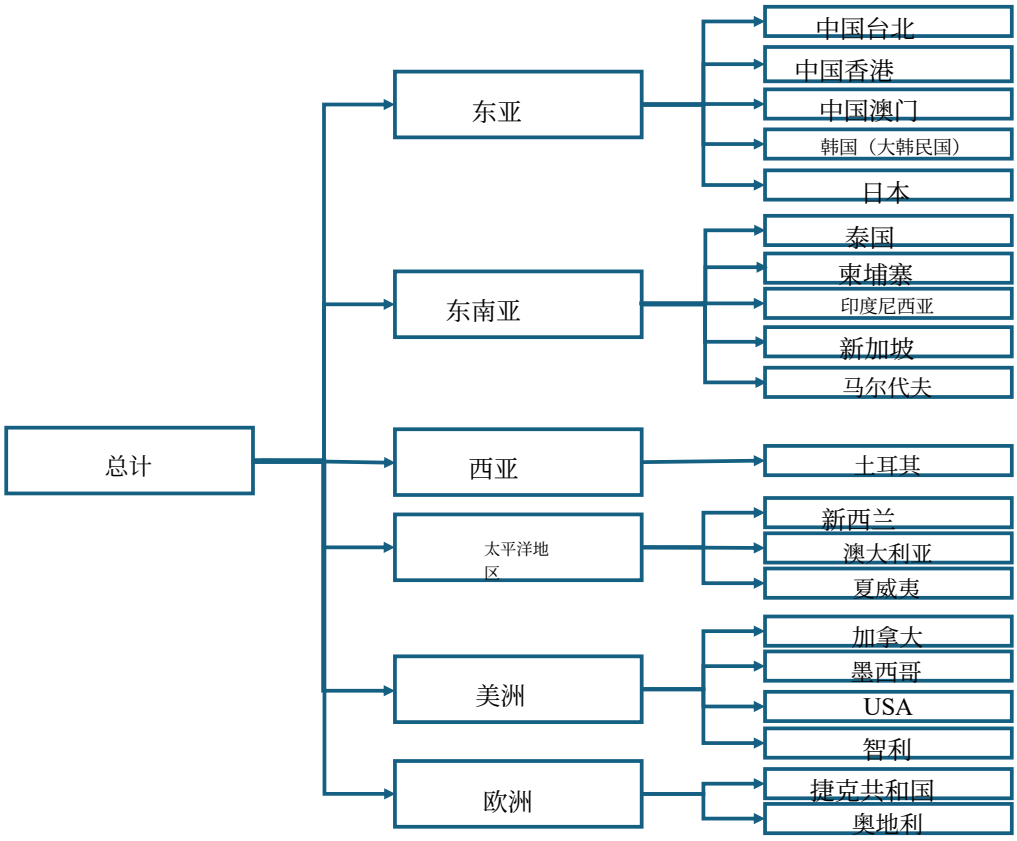

图4：按地区划分的层级结构。

结构，该结构基于地区，可提高预测的准确性。我们将20个目的地分为六个组别：东亚、东南亚、西亚、太平洋地区、美洲和欧洲，如图4所示。我们采用层次化预测方法，该方法在预测领域广受认可，例如参见M5预测竞赛(Anderer&Li, 2022) 以及旅游预测应用(Wen等人, 2026)；全面综述参见Athanasopoulos 等 (2024)。我们的方法包含层次化预测中的两种主要策略：自上而下和最优协调。

预测协调是一种用于确保层级结构中不同层级（例如地区、部门或产品）所作预测保持一致的方法——也就是说，它们能够正确相加。设 $\mathbf{y}_t$ 为时间 t 时所有时间序列（包括聚合层级和底层）的向量，$\hat{}\mathbf{y}_t$ 为基础预测（可能不一致），$\hat{}\mathbf{y}_t^{\text{rec}}$为协调后的（一致性）预测。协调后的预测表示为

$$\widehat{\mathbf{y}}_t^{\text{rec}} = \mathbf{S}\mathbf{G}\widehat{\mathbf{y}}_t \tag{1}$$

其中 S 是表示图中层级结构的求和矩阵 4 如下

$$\mathbf{S} = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 0 \\ 40 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 \; \mathbf{I}_m \end{bmatrix} \tag{2}$$

其中 $\mathbf{I}_m$ 为单位矩阵，G 是一个将基础预测映射为一致性预测的矩阵。不同的方法（如广义最小二乘和最小迹）会估计出不同的 G。

假设 $\widehat{y}_{\text{total},\ t}$ 是总序列的预测。总量按照比例 $\mathbf{p} = [p_1, p_2, \ldots, p_m]^T$分配到底层序列 m，其中 $\sum p_i = 1$。假设有 n个总序列（包括聚合序列），以及 m 个底层序列。自上而下方法先在层级结构的最高层进行预测，然后使用根据历史信息或单项预测估算出的比例，将预测分配到较低层级。然后，G 是 $m \times n$ 矩阵

$$\mathbf{G} = \begin{bmatrix} p_1 & 0 & \cdots & 0 \\ p_2 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ p_m & 0 & \cdots & 0 \end{bmatrix} \tag{3}$$

其中 n 是整个层级结构中的节点数。在我们的案例中，$n = 27$。

最优协调方法 (Wickramasuriya 等，2019) 采用协调步骤，使用加权最小二乘或最小迹等统计技术，对单项预测进行最优调整。最小迹（最小迹）方法将 G 设定为使协调误差协方差矩阵的迹最小。其解为

$$\mathbf{G} = \left(\mathbf{S}^\top \mathbf{W}^{-1} \mathbf{S}\right)^{-1} \mathbf{S}^\top \mathbf{W}^{-1} \tag{4}$$

其中，W 是基础预测误差的协方差矩阵。在协调后的预测位于由 S 定义的一致子空间这一约束下，可得到广义最小二乘解。

3.1.3. 预测组合方法

采用三种不同的预测组合方法来汇总各个基础预测：等权平均、基于误差的加权平均和堆叠模型。大量研究表明，基础预测的简单算术平均可达到与更复杂的预测组合方法相当的性能（Wang 等，2023）。在基于误差的加权平均方法中，2018年以前的数据用作训练集，而2018年和2019年的数据用作验证集。每个基础模型的权重按验证集平均绝对百分比误差的倒数计算。对于堆叠方法，选用 Lasso 和岭回归作为元模型。在这两种方法中，回归系数均被限制为严格正值，且不包含截距。正则化参数设为1 ，适用于这两个模型。

我们根据准确度选取排名前 80% 的模型，参与生成基础预测的预测组合流程。因此，与其他模型相比，17 个模型中有 4 个因在验证集中的预测误差显著较高而被排除

。因此，13 个单独模型被纳入预测组合步骤。基础预测的误差和模型的详细信息见表5。月份 t 的基础预测记为 $\widehat{BF}_i^t$。

3.1.4. 恢复系数

尽管中国于2022年底取消了出境旅行限制，但大流行病对旅游市场的影响并未立即消除。历史数据已无法准确反映后疫情时代的旅游需求，仅依赖传统时间序列模型仍可能导致显著的预测偏差。由于各国的旅游业复苏速度会因疫情政策、航班可用性和旅行成本等因素而有所不同，我们为每个目的地引入恢复系数 r_i where $0 <= r_i <= 1$，并将终端预测定义为 $\widehat{BF}_i^{202407} * r_i$

Škare等（2021）指出，COVID-19疫情期间，全球旅游业的复苏所需时间将超过平均预期的10个月。鉴于中国实施的旅行限制比大多数其他目的地更严格，且出境航班数量尚未恢复至疫情前水平，旅行者可能需要较长时间才能重新燃起对国际旅行的热情并恢复出行习惯。因此，截至2024年8月，也就是旅游限制解除18个月后，中国出境旅游不太可能完全摆脱COVID-19的影响，2024年8月的基础预测必须进行调整，以考虑这种影响。

估算恢复系数的理想方法是从数据中学习该系数。然而，在预测竞赛中，实际值 F 未知。因此，我们将恢复系数视为一个超参数，其取值依据先验知识确定。 Li等（2021）指出，后新冠疫情时期，旅行者偏好已转向邻近且低风险的目的地。COVID-19疫情过后，由于健康担忧、旅行限制和经济不确定性，旅行者可能更倾向于较短途的旅行。旅游政策也是影响旅游出发的关键因素 （Neumayer，2010）。

因此，我们将政策信息、距离和恢复状况作为设定恢复系数的主要先验参考。对于每个目的地，政策、距离和恢复评分均按1至5分进行赋值。表3 中的政策评分和恢复评分，是根据反映各目的地边境管控、签证政策和旅游业重新开放进程的可观测指标确定的。根据Zhang等（2021），地理距离较近且跨境联系紧密的目的地，例如香港和澳门，往往比美国等长途市场恢复得更快。自2022年12月以来，大多数东亚和东南亚目的地已逐步向中国游客重新开放，恢复直航并放宽入境限制。它们较高的政策评分和恢复评分，反映了航空服务较早恢复、旅行成本相对较低，以及政府对入境旅游持支持态度。中国台北的政策评分最低，因为2019年7月暂停来自中国大陆的个人旅行许可至今仍然有效，尽管区域重新开放，出境旅游复苏仍因此受到限制。欧洲目的地和美国的政策评分与恢复评分较低，原因是签证要求较严格、航班运力恢复正常的速度较慢，且旅行距离较远，这些因素均不利于短期复苏。智利的恢复评分适中，考虑到了双边贸易和航线扩张方面的新进展。对于澳大利亚、夏威夷和土耳其等太平洋目的地，适度的政策开放度和航班部分恢复支撑了中等水平的恢复

评分；新西兰的评分略低，因为其边境管理较为保守，长途航线连通性的恢复也较慢。

距离评分取决于北京和上海到目的地首都的平均距离。恢复评分根据旅游游客到访量预测和最新航班数据确定。政策评分根据目的地的旅行限制政策、签证申请难度以及各国政府对中国游客的态度进行评估。各项评分列于表3 ，更多详细信息请参阅GitHub代码仓库中的补充材料。

表3：各目的地的评估分数和复苏系数。

地区	目的地	政策	距离	复苏	平均值	恢复系数
美洲	加拿大	3	1	2	**2.0**	**0.65**
	智利	3	1	3	2.3	0.7
	墨西哥	5	1	5	**3.7**	**1.0**
	USA	2	1	3	2.0	0.65
东亚	中国台北	1	5	1	2.3	0.6
	中国香港	5	5	3	**4.3**	**0.85**
	澳门，中国	5	5	3	4.3	0.85
	韩国（大韩民国）	4	5	2	3.7	0.8
	日本	4	5	2	3.7	0.8
东南亚	泰国	5	3	4	4.0	0.8
	柬埔寨	5	3	3	3.7	0.8
	印度尼西亚	4	3	4	3.7	0.8
	新加坡	4	3	3	3.3	0.8
	马尔代夫	4	3	5	3.7	0.8
太平洋地区	新西兰	3	1	3	2.3	0.7
	澳大利亚	4	2	3	3.0	0.75
	夏威夷	3	2	4	3.0	0.75
西亚	土耳其	4	2	3	3.0	0.75
欧洲	奥地利	2	2	2	2.0	0.65
	捷克共和国	2	2	2	2.0	0.65

各目的地的恢复系数（r_i）如表3 所示，由政策开放度、地理距离和恢复状态这三项标准化指标的平均值确定。这些指标分别刻画了旅游业复苏所受到的制度性、空间性及市场驱动型约束。我们假设 r_i 随平均得分线性增加，这反映出政策更开放、距离更短且复苏信号更强的目的地，其旅游流往往更快恢复常态。为校准这一映射，我们将三个复苏模式记录较为充分的目的地，即加拿大（$r = 0.65$）、墨西哥（$r = 1.0$）和中国香港（$r = 0.85$）的复苏系数指定为锚点。加拿大的系数被赋为0.65，主要由于其对中国公民的签证政策较为严格、航班运力恢复不完全以及旅行距离较长。墨西哥的恢复系数被赋为1.0，主要因为其来自中国的旅游业增长显著。截至2022年12月，中国出境旅游赴墨西哥已回升至疫情前水平的85%。香港的恢复系数设定为0.85，反映出其与中国大陆联系紧密，且中国居民的入境安排较为便利。基于这些参考值的最小二乘回归得到 $r_i = 0.45 + 0.10 \times$ 平均值$_i$。其余系数随后利用该拟合模型生成。这一程序确保了各目的地之间的内部一致性，并将所赋系数直接与可衡量的复苏决定因素联系起来，而非

主观判断。

通过将定量评分体系与专家评估相结合，我们在确保不同目的地之间一致性的同时，也纳入了政策动态和市场状况等本质上难以通过统计方法建模的因素。在恢复系数的估计中，我们明确嵌入了人为判断，使该框架能够整合仅凭历史数据无法提供的情境性和前瞻性见解。这种混合设计提升了复苏预测的现实性和适应性，尤其适用于具有高度不确定性和有限数据可用性的危机后环境。

3.2. 第二阶段–初始预测

预测策略的第二阶段侧重于通过纳入外部因素来估计参考预测，例如搜索指数数据和航班信息。这一阶段对于提高初始预测的准确性至关重要。

竞赛的预测期为2023年8月至2024年7月，而最新可获得的历史旅游数据仅延伸至2023年1月。利用相关外部指标对2023年2月至7月这一间隔期的出境旅游进行短期预测，可以显著提升长期预测的准确性。根据提交截止日期，我们仅预测2023年2月至2023年6月的数据，在后文中称为参考预测。这种方法使我们能够将最新的外部信息（复苏信息）整合到框架中。本阶段考虑的外部因素包括百度综合搜索指数，以及中国大陆与20个主要旅游目的地之间的直飞航班数量。

3.2.1. 百度搜索指数

百度指数网站自2010年起提供各种关键词的每日搜索指数数据。由于能够快速提供信息，该网站被广泛用于旅游预测 （Li等，2018年）。针对每个目的地，我们汇总多个与游客到访量相关的关键词，构建百度综合搜索指数，这些关键词包括旅行、购物、餐饮、酒店、签证，以及主要城市和景点的名称。由于数据可用性和区域条件存在差异，用于构建百度综合搜索指数的具体关键词因目的地而异。关键词的完整列表见表 4。我们计算每个关键词的搜索指数与相应出境旅游数据之间的相关性，并将相关系数低于0.6的关键词排除在百度综合搜索指数的构建之外。

出境旅游的主要数据来源是一个按月统计的横截面数据集，由新冠肺炎疫情期间旅游预测竞赛第二轮组委会提供。我们收集了搜索数据，并按月汇总，使其与出境旅游数据保持一致。我们使用滞后一个月的百度搜索指数作为当前出境旅游的预测变量，这反映了游客倾向于提前搜索旅行信息的特点。图5 展示了出境旅游与不同滞后期百度搜索指数之间的平均相关系数，其中最高相关性（0.826）出现在滞后一个月时。此外，我们还计算了各个关键词与出境旅游之间的相关系数，并将系数低于0.6的关键词排除在综合搜索指数的构建之外。随后，将剩余关键词的指数相加，得到百度综合搜索指数。如图6所示，构建的综合搜索指数与出境旅游呈现出较强的相关性。

T表 4：按目的地划分的百度搜索指数关键词　　地。

目的地	关键词
加拿大	加拿大旅游　, 加拿大签证 , 加拿大航空 , 温哥华
智利	智利旅行，智利签证，圣地亚哥
墨西哥	墨西哥旅行　, 墨西哥签证
USA	美国旅行，美国旅行指南，美国航空公司，美国签证，洛杉矶，旧金山
中国台北	中华台北旅行，中华台北旅行指南，中国台北酒店、中华台北签证、中华台北美食、中华台北小吃、中华台北购物
中国香港	香港旅游指南、香港航空公司、香港酒店、香港签证、香港美食、香港小吃、香港购物、香港旅游地图、香港旅游景点、港澳通行证
中国澳门	澳门旅游、澳门旅游指南，　　澳门航空公司，澳门酒店，澳门美食、港澳通行证
韩国（大韩民国）	韩国旅游、韩国旅游指南、韩国酒店、韩国签证、韩国美食，　韩国购物、韩国旅游景点、首尔、济州岛-land
日本	日本旅游，　　日本旅游指南，　　日本航空公司，日本签证，日本料理、日本购物、日本旅游地图、日本旅游景点、大阪、名古屋
泰国	泰国旅游　　, 泰国航空公司　, 泰国酒店　　, 泰国签证　　, 曼谷、清迈、苏梅岛、普吉岛
柬埔寨	柬埔寨旅行，柬埔寨签证，吴哥窟
印度尼西亚	印度尼西亚旅行 , 印度尼西亚签证 , Bali
新加坡	新加坡旅游，新加坡旅游指南，新加坡航空，Singa-
马尔代夫	波尔签证 马尔代夫旅游、马尔代夫旅游指南、马尔代夫签证
新西兰	新西兰旅游、新西兰旅游指南、新西兰航空公司 , 新西兰签证
澳大利亚	澳大利亚旅游指南，澳大利亚签证，悉尼，墨尔本
夏威夷	夏威夷旅行，夏威夷旅游指南
土耳其	土耳其旅行、土耳其旅行指南、土耳其航空、土耳其酒店，土耳其签证
奥地利	奥地利旅行　, 奥地利航空　　, 奥地利签证
捷克共和国	捷克共和国旅行，捷克共和国签证

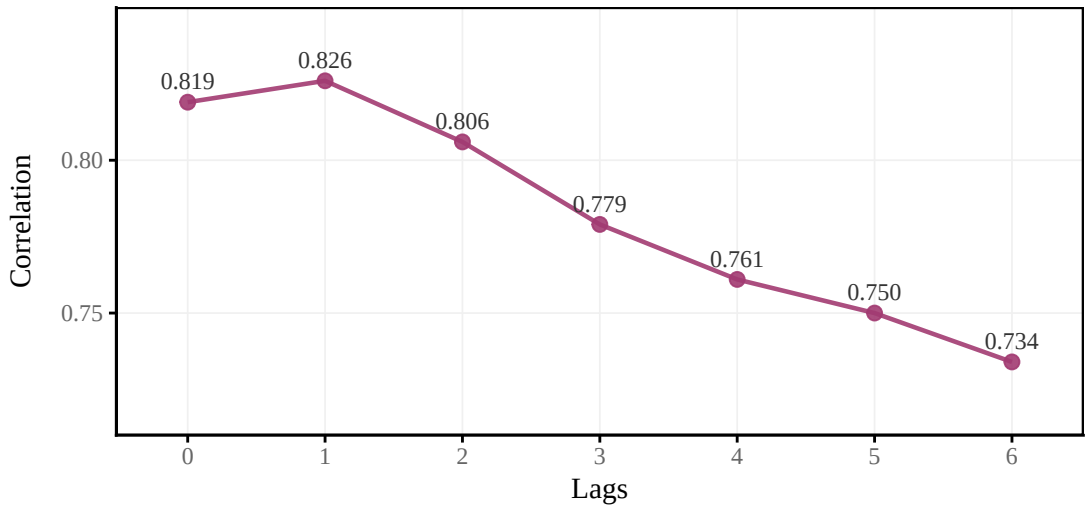

Fig图 5：不同时间滞后下百度搜索指数与出境旅游之间的相关性 .

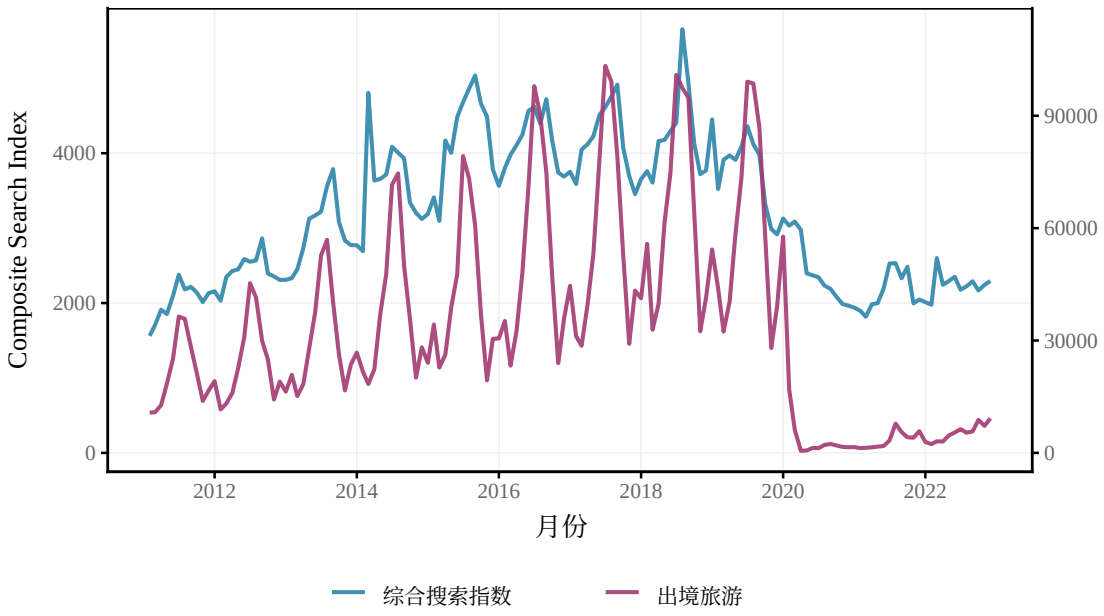

图 6：综合搜索指数（蓝色，左轴）与前往加拿大的出境旅游（红色，右轴）之间的关系。

我们采用两种主要策略，利用百度综合搜索指数估算参考预测。第一种策略是在两种多变量时间序列模型中将百度综合搜索指数作为外部变量：带外生变量的 ARIMA 和 Facebook Prophet 模型(Taylor & Letham, 2018)。第二种策略是计算出境旅游与百度综合搜索指数的比值，并应用多种单变量时间序列模型，包括指数平滑法(Hyndman 等，2002)，霍尔特-温特斯法和状态空间趋势-季节性 ARMA 模型(De Livera 等，2011)，以预测该比值。此策略下，参考预测值的估计方法是将预测比值乘以百度综合搜索指数。最后，对上述策略得到的结果取平均值。

3.2.2. 航班信息

航班数据为估算出境旅游趋势提供了重要的补充信息。VariFlight 应用提供2019年至2023年的航班数据，详细记录了两个目的地之间的直航数量。最初，我们计划参照百度指数的方法，估算竞赛组织方提供的实际出境游客人数与直航数量之比。然而，由于过去三年实施的空中交通管制政策，该比值大幅下降，因此基于该比值进行预测并不可靠。出于类似原因，多变量时间序列模型也不切实际。因此，我们采用一种简单预测方法：以最近的出境旅游数据作为基准。然后，对于给定月份，计算航班相较于初始月份的相对增长率。将基准人数乘以该增长率，即可得到预测的出境旅游人数。

月份 t 的参考预测记为 $\widehat{RF}_i^t$，即基于百度综合搜索指数和航班数据得出的参考预测的简单平均值。同样，初始预测可从参考预测中提取，记为 $\widehat{RF}_i^{202306}$

3.3. 第三阶段——复苏曲线预测

3.3.1. 恢复曲线估计

本节采用三种不同的函数形式——线性、二次和逻辑斯蒂——估计连接初始预测（2023年6月）与终端预测（2024年7月）的复苏曲线预测，以涵盖各种可能的复苏路径，并确保在不确定性下的预测稳健性。

首先，我们将中国大陆前往目的地 i 的出境旅游月度预测定义为 F_i^t，其中 $t = 0$, 1，……，13 对应于从2023年6月至2024年7月的月份。具体而言， F_i^0表示2023年6月的预测， F_i^1表示2023年7月的预测，依此类推，而 F_i^{13}表示2024年7月的预测。

两个关键点，即初始预测和终端预测，在我们的预测框架中发挥着重要作用。如前所述，初始预测 F_i^0被设定为2023年6月的参考预测，而终端预测 F_i^{13}是恢复系数与2024年7月基础预测的乘积。它们表示为：

$$F_i^0 = \widehat{RF}_i^{202306} \tag{5}$$

$$F_i^{13} = \widehat{BF}_i^{202407} \times r_i \tag{6}$$

其中 $0 < r_i \leq 1$。

就恢复曲线估计而言，我们采用季节性与趋势分解，以其趋势与季节性的乘法形式推导最终的复苏曲线，即

$$F_i^t = \widehat{Trend}_i^t \times \widehat{Seasonal}_i^t. \tag{7}$$

下面，我们估计季节性与趋势分解中涉及的趋势分量和季节分量。

季节分量 $\widehat{Seasonal}_i^t$ 通过对2020年之前的历史出境旅游序列取对数，并对其应用乘法形式的季节性与趋势分解来估计。该对数序列便于进行更适用于复苏预测的乘法季节性调整。请注意，由于使用的是原始尺度，对数序列始终为正。虽然也有其他估计季节分量的方法，例如使用2023年8月之后的基础预测，但我们认为，历史数据中的季节效应更为稳定，依赖基础预测可能会引入不必要的噪声。

在本研究中，我们提出复苏曲线的趋势分量可采用三种函数形式之一：线性、二次或逻辑斯蒂。我们使用这些函数相应地拟合趋势分量。

对于线性趋势估计，我们建立一条连接初始预测与终端预测的直线。基于线性模型的目的地 i 在月份 t 的趋势分量估计可表示为：

$$\widehat{Trend}_i^t = \widetilde{Trend}_i^0 + \frac{t}{14} \cdot (\widetilde{Trend}_i^{13} - \widetilde{Trend}_i^0), \quad t = 0, 1, \ldots, 13, \tag{8}$$

其中

$$\widetilde{Trend}_i^0 = \frac{F_i^0}{\widehat{Seasonal}_i^0}, \quad \text{and } \widetilde{Trend}_i^{13} = \frac{F_i^{13}}{\widehat{Seasonal}_i^{13}} \tag{9}$$

是初始点和终端点的截距估计值。这与Qiu等（2021）的做法类似，他们仅假设存在线性关系来构建复苏曲线。

对于二次趋势估计，我们采用最小二乘法，对2022年1月至2023年6月的数据及终端预测拟合二次曲线。前13个月（2022年1月至2023年1月）的数据为实际值，之后5个月（2023年2月至2023年6月）的数据为参考预测。二次曲线隐含的假设是，出境旅游人数起初复苏缓慢，但经过一段时间后会迅速增长。值得注意的是，所有数据均为趋势分量，且终端预测的权重设为18，以提高曲线的拟合度。基于二次模型的趋势分量估计可表示为：

$$\widehat{Trend}_i^t = a_i(t+18)^2 + b_i(t+18) + c_i, \tag{10}$$

对于 $t = 0$，1，……，13，其中

$$a_i,\ b_i,\ c_i = \arg\min_{a_i,b_i,c_i} \Big(\sum_{t=1}^{18} \big(y_i^t - (a_i t^2 + b_i t + c)\big)^2 + 18 \times (\widehat{Trend}_i^{13} - (a_i t^2 + b_i t + c))^2 \Big) \tag{11}$$

2023年2月之前的趋势预测是从历史数据中提取的

$$y_i^1 = Trend_i^{202201},\ y_i^2 = Trend_i^{202202}, \ldots, y_i^{13} = Trend_i^{202301} \tag{12}$$

而2023年2月至2023年6月之间的趋势预测则是参考预测，

$$y_i^{14} = \frac{\widehat{RF}_i^{202302}}{\widehat{Seasonal}_i^{202302}},\ y_i^{15} = \frac{\widehat{RF}_i^{202303}}{\widehat{Seasonal}_i^{202303}},\ldots,\ y_i^{18} = \frac{\widehat{RF}_i^{202306}}{\widehat{Seasonal}_i^{202306}} \tag{13}$$

在逻辑趋势估计中，采用五个关键点的趋势分量$y_1,\ldots,y_5$来估计逻辑曲线：2022年1月的实际值，以及2023年12月、2024年7月和2024年12月的初始预测和基础预测。它们表示为

$$y_i^1 = Trend_i^{202201},\ y_i^2 = \widetilde{Trend}_i^0,\ y_i^3 = \frac{\widehat{BF}_i^{202312}}{\widehat{Seasoal}_i^{202312}},\ y_i^4 = \frac{\widehat{BF}_i^{202407}}{\widehat{Seasoal}_i^{202407}},\ y_i^5 = \frac{\widehat{BF}_i^{202412}}{\widehat{Seasoal}_i^{202412}}. \tag{14}$$

使用R包nls进行估计。基于逻辑模型的趋势分量估计可表示为

$$\widehat{Trend}_i^t = \frac{L_i}{1+\exp(-k_i(t+18-t_i))}, \tag{15}$$

其中

$$L_i,\ k_i,\ t_i = \arg\min_{L_i,k_i,t_i} \sum_{t=1}^{5} \left(y_i^t - \frac{L_i}{1+\exp(-k_i(t-t_i))} \right)^2. \tag{16}$$

我们展示了三种类型的复苏曲线，如图7 所示，图中展示的是加拿大趋势分量的预测。值得注意的是，2024年7月提交的最终预测并不完全等同于终端预测，而是与其近似。在二次方法和逻辑方法中，2024年7月的预测由拟合数据所得的特定曲线确定，其数值可能因模型参数和拟合方法而略有偏差。

最后，我们对上述三种方法生成的结果取平均，得出趋势分量估计。复苏曲线预测是趋势分量估计与相应季节分量估计的乘积，如公式（7）所示。

3.4. 区间预测

在 RISE 框架中，预测过程分为三个部分：初始预测、终端预测，以及连接两者的复苏曲线。在第3 节中描述的3.1所述13 个独立模型中，有12 个模型（不包括不生成预测区间的神经网络自回归模型）会生成区间预测。对于每个月，我们取这12 个模型的80% 上下置信界的平均值，作为终端预测对应的上下界。按照点预测的相同步骤，通过复苏曲线将这些终端预测的上界和下界与初始预测连接起来，从而构建完整的区间预测。在竞赛中，区间预测采用 Winkler 评分（Winkler, 1972），该评分同时衡量区间宽度以及对

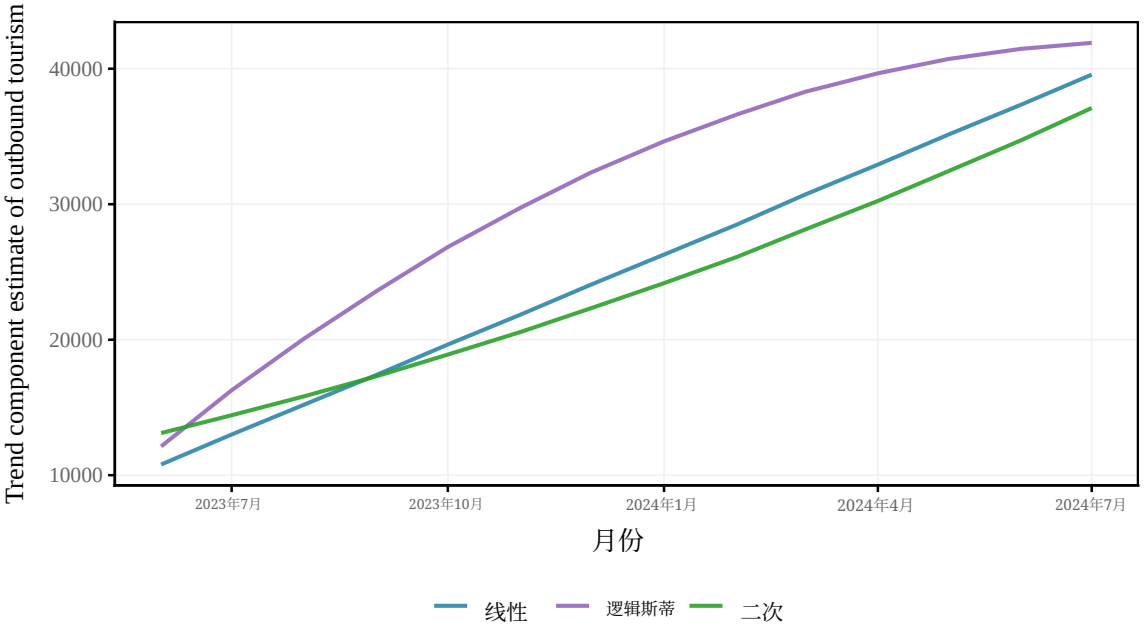

图 7: 加拿大出境旅游复苏曲线预测阶段的三个趋势分量函数。

落在区间之外的观测值所施加的惩罚 $Winkler_\alpha = \frac{1}{T}\sum_{t=1}^{T} W_{\alpha,\ t}$ 和

$$W_{\alpha,t} = \begin{cases} (u_{\alpha,t} - \ell_{\alpha,t}) + \frac{2}{\alpha}(\ell_{\alpha,t} - y_t) & \text{if } y_t < \ell_{\alpha,t}, \\ (u_{\alpha,t} - \ell_{\alpha,t}) & \text{if } \ell_{\alpha,t} \le y_t \le u_{\alpha,t}, \\ (u_{\alpha,t} - \ell_{\alpha,t}) + \frac{2}{\alpha}(y_t - u_{\alpha,t}) & \text{if } y_t > u_{\alpha,t}, \end{cases} \tag{17}$$

其中，$u_{\alpha,t}$ 和 $l_{\alpha,t}$ 分别为 100(1 − α)% 区间的相应上限和下限。为考虑各序列之间的尺度差异，还报告了 Winkler评分的标准化版本，表示为

$$StandardWinkler_\alpha = Winkler_\alpha \div \frac{\sum_{i=1}^{T} y_{\alpha,t}}{T}. \tag{18}$$

此外，还报告覆盖概率，以评估预测区间与名义置信水平的吻合程度，表示为

$$CP = \frac{1}{T}\sum_{t=1}^{T} CP_t \text{ and } CP_t = \begin{cases} 0 & \text{if } y_t < \ell_{\alpha,t}, \\ 1 & \text{if } \ell_{\alpha,t} \le y_t \le u_{\alpha,t}, \\ 0 & \text{if } y_t > u_{\alpha,t}. \end{cases} \tag{19}$$

4. 预测评估

4.1. 基础预测

表5 报告了所有预测模型在2018–2019年验证集上的基础预测的平均绝对百分比误差和平均绝对缩放误差。在所有单个模型中，采用加权最小二乘和最小迹协调方法的两个层级预测模型表现最佳之一

表5：所有模型在2018—2019年基础预测的验证集。

A部分：各模型的误差			
模型	均方根误差	平均绝对百分比误差	平均绝对缩放误差
季节性朴素法	94969	0.2679	1.4648
带漂移的随机游走	**118231**	**0.4158**	**1.8741**
自回归积分滑动平均模型	107064	0.2430	1.2175
指数平滑	107330	0.1494	0.9523
Holt线性趋势	**143351**	**0.4350**	**3.3307**
Holt-Winters季节性方法	88134	0.1851	1.1028
季节性与趋势分解基于 Loess-A 的	98743	0.1769	1.1512
季节性与趋势分解基于 Loess-B	107063	0.2249	1.2802
季节性与趋势分解基于 Loess-C	101330	0.1859	1.1830
TBATS	120628	0.2796	1.4949
神经网络自回归	103085	0.1994	1.3337
自上而下-A-ARIMA	101617	0.2220	1.2520
自上而下-A-ETS	101593	0.1550	0.9860
自上而下-B-ARIMA	**133291**	**0.4132**	**2.1673**
自上而下-B-ETS	**133271**	**0.4663**	**2.1810**
采用最小追踪	96261	0.1527	0.9861
采用加权最小二乘法	95922	0.1465	0.9961
面板B：组合方法的误差			
方法			
简单平均	84187	0.1609	0.9468
误差加权平均	85293	0.1816	1.1029
堆叠套索	79550	0.0961	0.5421
堆叠岭回归	80361	0.1051	0.5922

。指数平滑法的表现也很好。相比之下，带漂移的随机游走模型、Holt线性趋势模型、结合ARIMA的自上而下方法，以及结合ETS模型的自上而下方法（其分配比例由历史出境旅游数据确定）因验证误差异常偏高而被舍弃。因此，这些模型未纳入我们的模型列表。结果表明，在自上而下方法中，根据预测值分配比例比使用历史数据效果更好。与单个模型相比，组合方法，尤其是堆叠模型，显著降低了预测误差。堆叠Lasso法取得了最低的验证误差：平均绝对百分比误差为0.0961，平均绝对缩放误差为0.5421。结果凸显了预测组合，特别是基于堆叠的方法，在提升预测准确度方面优于单个模型的有效性。

4.2. 参考预测

在第二阶段，我们估算2023年2月至2023年6月的参考预测。由于竞赛结束后才能获得这一时期的中国出境旅游数据，因此我们将其与估算结果进行比较，以评估预测框架的准确性。我们还进一步比较搜索指数和航班量在预测出境旅游方面的效果。

表6 展示了参考预测的平均绝对缩放误差及其两个组成部分：根据航班数量估算的参考预测，以及根据综合搜索指数估算的参考预测。对于每个目的地，三组序列中平均绝对缩放误差最低的一项以粗体标出，表示表现最佳的方法。由于中国大陆飞往智利、墨西哥、夏威夷和捷克共和国的直航直至2023年6月才恢复（或从未开通直航

），这四个目的地的参考预测仅根据综合搜索指数估算。表中还列出了平均绝对缩放误差的平均值和加权平均值，其中权重为2023年2月至2023年6月期间的平均出境旅游量。

平均而言，基于综合搜索指数的参考预测取得了最低的平均平均绝对缩放误差，为 1.6233，优于基于航班数据的参考预测（2.7868）及其平均值（1.7371）。若以加权平均值为评判标准，则平均值（2.0248）的表现略优于搜索指数（2.0779）。在有基于航班数据的预测结果的 16 个目的地中，基于搜索指数的预测在其中 7 个目的地表现最佳，而基于航班数据的预测仅在 3 个目的地表现最佳。平均预测在 6 个目的地表现最佳。这表明，高频搜索行为可能是估算旅游情况时更稳定、可靠的指标。搜索数据能即时反映人们为旅行所做的准备，例如寻找目的地、查询签证政策或预订酒店，这些行为与实际旅行决策高度相关。然而，在 2023 年高度不确定的情况下，航班数据与出境旅游之间的关系并不十分稳定。旅行限制解除后，直航航班数量在短时间内迅速恢复，但座位上座率可能尚未恢复至正常水平，因此在这种情况下，我们可能会高估出境旅游规模，马尔代夫、泰国、土耳其和澳大利亚便是如此。这些目的地基于航班数据的预测误差显著高于基于搜索数据的误差。因此，我们建议使用搜索指数预测出境旅游的短期趋势。

4.3. 复苏曲线预测

在RISE框架的第三阶段，基于第一阶段得出的基础预测和第二阶段得出的参考预测，作出三项假设，用以估计2023年8月至2024年7月的复苏曲线。我们还为每个目的地设定了恢复系数，以捕捉复苏速度的潜在差异。根据竞赛后披露的最新出境旅游数据（截至2025年1月），开展回顾性分析，以评估预测表现。

表 7 列出了各目的地复苏预测的均方根误差、平均绝对百分比误差和平均绝对缩放误差。总体而言，RISE框架在大多数目的地上展现出令人满意的准确性。11个目的地的平均绝对百分比误差值保持在0.3以下。中国台北、夏威夷和柬埔寨等目的地的误差相对较大，反映了其后疫情时代旅游业的结构转变。这些结果凸显了各市场旅游业复苏的异质性，并强调了将更多目的地特定因素纳入预测模型的重要性。

表 8 列出了复苏曲线预测的三个组成部分，即基于线性、二次和逻辑斯蒂假设的恢复曲线的平均绝对缩放误差。对于每个目的地，三组数据中最低的平均绝对缩放误差以粗体标出，以表示表现最佳的方法。本表还列出了平均绝对缩放误差的简单平均值和加权平均值，其中权重为2023年8月至2024年7月期间的平均出境旅游量。在三种假设中，二次假设的表现最佳且最稳定，其平均绝对缩放误差为1.9906，显著低于另外两种方法

表6：参考预测的平均绝对缩放误差及其组成部分（2023年1月至2023年6月）。

目的地	参考	直飞航班	综合搜索指数
加拿大	**0.4708**	0.8802	0.8085
智利	1.0963	–	1.0963
墨西哥	0.6944	–	0.6944
中国台北	1.9542	**1.3703**	2.5381
中国香港	3.0323	3.8043	**3.0323**
日本	0.9430	0.9670	**0.9190**
韩国（大韩民国）	**0.2937**	1.1461	1.3760
澳门 ，中国	**0.9888**	1.0328	1.1545
马尔代夫	6.3710	11.2578	**1.4841**
柬埔寨	1.4194	**1.3805**	2.5733
印度尼西亚	**3.0946**	3.1808	4.4610
新加坡	**0.9567**	2.1413	1.1924
新西兰	**1.5182**	1.7451	1.2914
USA	1.0160	**0.7334**	1.3443
泰国	2.3467	5.5711	**1.5206**
土耳其	1.4537	3.3289	**0.8521**
澳大利亚	2.1087	4.8322	**1.2256**
夏威夷	1.6194	–	1.6194
奥地利	0.9694	1.2176	**0.8884**
捷克共和国	2.3953	–	2.3953
平均值	1.7371	2.7868	**1.6233**
加权平均值	**2.0248**	2.6610	2.0779

表7：按目的地划分的复苏曲线预测的不同预测误差（2023年8月至2024年7月）。

目的地	均方根误差	平均绝对百分比误差	平均绝对缩放误差
加拿大	7195	0.2824	1.3871
智利	878	0.3310	2.3311
墨西哥	2726	0.1654	0.7668
中国台北	28703	0.9553	8.3389
中国香港	1328443	0.4781	2.9475
日本	48990	0.1214	0.8486
韩国（大韩民国）	39274	0.1296	1.3411
澳门 ，中国	348843	0.1708	1.0657
马尔代夫	3808	0.1697	0.5389
柬埔寨	39083	0.6768	5.2619
印度尼西亚	33477	0.3557	3.4175
新加坡	43290	0.1828	0.7896
新西兰	5130	0.2388	0.8169
USA	27409	0.9146	0.6401
泰国	103227	0.2464	1.4301
土耳其	10519	0.3357	2.7209
澳大利亚	11712	0.1762	0.4904
夏威夷	2106	1.9698	5.0964
奥地利	6987	0.2355	1.4804
捷克共和国	13025	0.5624	3.2130

表8：2023年8月至2024年7月期间，三种曲线函数对应的复苏曲线预测的平均绝对缩放误差。

目的地	线性	二次	逻辑斯蒂
加拿大	1.5731	**1.3975**	1.4430
智利	**2.0116**	2.1836	2.7980
墨西哥	**0.4868**	0.5054	1.4691
中国台北	6.6705	**5.2014**	13.1448
中国香港	3.7195	4.0265	**1.1836**
日本	0.9979	**0.9479**	1.6394
韩国（大韩民国）	**0.8470**	1.6343	2.5268
澳门 ，中国	**0.9919**	1.4723	1.0298
马尔代夫	1.2788	**0.5194**	0.9948
柬埔寨	4.7207	**3.9109**	7.1542
印度尼西亚	6.4888	2.7449	**1.5641**
新加坡	**0.5813**	0.9811	0.8821
新西兰	**0.6338**	0.9715	1.2857
USA	0.7420	0.8192	**0.7203**
泰国	2.2996	1.0091	**0.9816**
土耳其	**2.1860**	2.4690	3.5079
澳大利亚	0.6411	**0.4525**	0.6395
夏威夷	3.8336	**3.3592**	8.1253
奥地利	2.4500	2.0315	**1.7284**
捷克共和国	**3.1708**	3.1744	3.4261
平均值	2.3162	**1.9906**	2.8122
加权平均值	2.1719	2.1848	**1.4904**

模型中，在20个目的地中，线性方法在8个目的地表现最佳，但在印度尼西亚表现不佳；如果不考虑该国，线性假设和二次假设的表现应该相近。不过，如果以加权平均值作为评判标准，逻辑斯蒂方法表现最佳，因为其在香港和澳门的误差相当小。

与此同时，我们还在表 4.3 中将 RISE框架的预测表现与若干基准模型进行了比较，包括朴素方法、季节性朴素法、季节性ARIMA和指数平滑状态空间模型。本文中的基准结果由旅游预测竞赛的组织方提供。如表 4.3 所示，我们的 RISE框架取得了最低的总体平均绝对缩放误差（2.1464），大幅优于所有基准方法。RISE框架在 14 个 20 个目的地中表现最佳，智利、中国台北、香港、印度尼西亚、夏威夷和捷克除外。朴素方法和季节性自回归积分滑动平均模型优于其他基准模型。总而言之，RISE框架将基准预测与基于情景的复苏调整以及通过复苏系数体现的跨国异质性相结合，使其能够适应不同的复苏模式。这种设计使RISE能够兼顾灵活性与稳健性，从而在不同目的地取得最稳定、最准确的结果。

我们采用百分比误差 ，其定义为 $(F_{Prediction} - F_{Actual})/F_{Actual}$，仅用于量化 forecast 与实际值之间的偏差相对于实际值本身的大小。

表9：RISE框架与基准方法的平均绝对缩放误差（2023年8月至2024年7月）。

目的地	朴素方法	季节性朴素法	季节性ARIMA	ETS	RISE
加拿大	1.9270	2.2533	1.5731	1.4396	**1.3857**
智利	2.0652	2.5264	**1.6759**	2.0652	2.1449
墨西哥	2.8898	3.2289	3.2209	2.4177	**0.7096**
中国台北	0.3527	0.4582	**0.3265**	0.3527	7.8455
中国香港	3.0908	4.9106	**2.5622**	7.1695	2.9527
日本	4.8940	5.0753	4.6105	4.8662	**0.8395**
韩国（大韩民国）	3.2140	3.4793	3.2424	3.1601	**1.3647**
澳门 ，中国	3.0532	4.7326	3.0607	3.2233	**1.0914**
马尔代夫	2.9887	4.8270	1.8294	4.2252	**0.4965**
柬埔寨	**0.5247**	1.9055	3.1346	0.8074	5.0514
印度尼西亚	**1.4034**	1.8393	**1.4034**	**1.4034**	3.1392
新加坡	3.7875	4.2067	2.9907	3.8484	**0.7418**
新西兰	3.0157	3.4054	1.5726	3.1423	**0.7526**
USA	2.7450	2.8772	2.7536	2.1046	**0.6695**
泰国	3.2220	4.3335	3.2220	3.2221	**1.4000**
土耳其	4.5574	4.6531	4.6880	4.5561	**2.5493**
澳大利亚	2.6870	5.4711	3.7795	4.5368	**0.4837**
夏威夷	0.5458	**0.2084**	0.2788	0.5347	4.7944
奥地利	2.1259	2.1620	1.9962	1.8185	**1.3802**
捷克	0.7876	0.9990	**0.5670**	1.4919	3.1358
平均值	2.4939	3.1776	2.4244	2.8193	**2.1464**

该指标反映预测偏差的方向和幅度，正值表示高估，负值表示低估。虽然该指标直观且易于理解，但对较小的实际值较为敏感，可能导致误差较大或无法定义，因此在实际应用中可能不够稳定。图8 展示了百分比误差在2023年8月至2024年7月期间不同目的地的分布情况，揭示了预测准确性存在显著的地域差异。值得注意的是，该模型往往低估前往香港、澳门、日本和韩国等邻近目的地的出境旅游。这可能是由于短途旅行迅速复苏，其速度超出了复苏系数中所包含的假设。相比之下，对欧洲和北美目的地的预测则显示出高估，这可能归因于持续存在的签证限制、航班恢复不充分以及长途旅行意愿低迷。在东南亚，该模型对新加坡和马尔代夫等国家和地区的预测表现良好，但高估了前往泰国和柬埔寨的需求，这可能与安全顾虑有关。太平洋地区和拉美目的地的预测误差相对较低。总体而言，图8 还表明，固定的复苏系数能够有效捕捉旅游业复苏的基本趋势，但可能无法充分反映快速或非对称的复苏轨迹。

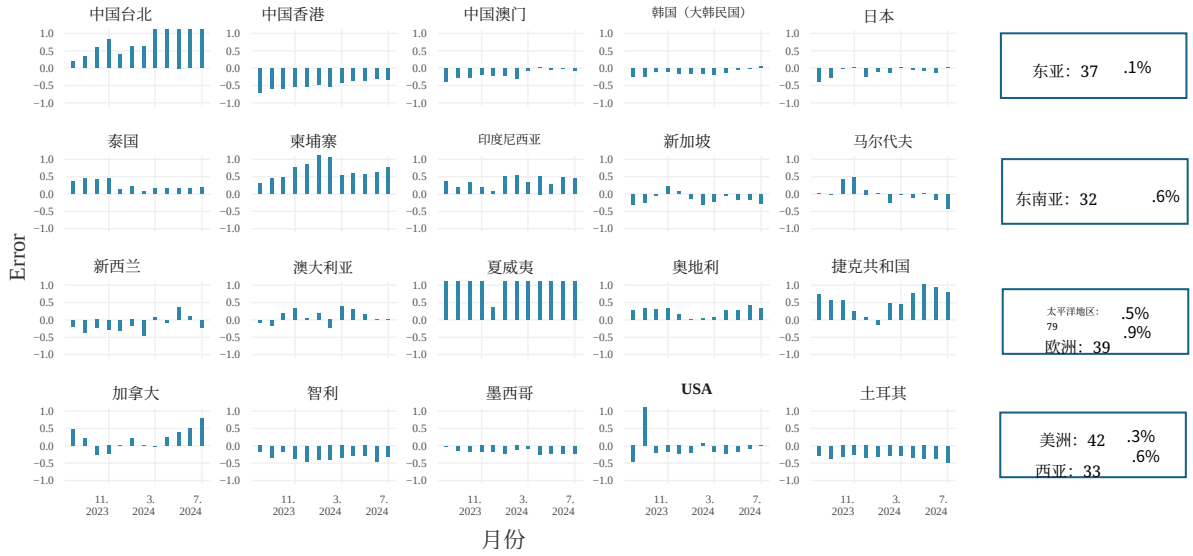

图8：2023年8月至2024年7月出境旅游预测的百分比误差。

在第三阶段，我们为每个目的地设定了一个恢复系数，以考虑 COVID-19 的长期影响。如果在我们的 forecast 框架中移除恢复系数会怎样？图 9 展示了有无恢复系数时预测的平均绝对缩放误差。移除恢复系数后，平均绝对缩放误差从 2.2461 上升至 3.6822，且 20 个国家/地区中有 15 个的平均绝对缩放误差更高，这表明引入恢复系数显著提高了预测准确度。然而，在东亚目的地，旅游业的复苏速度远远快于我们此前的估计，因此在这些目的地应用恢复系数会产生误导。

4.4. 区间预测

表 10 根据三个性能指标，对20个目的地的区间预测进行了评估：Winkler评分、标准Winkler评分和覆盖概率，具体见公式（17）–（19）。

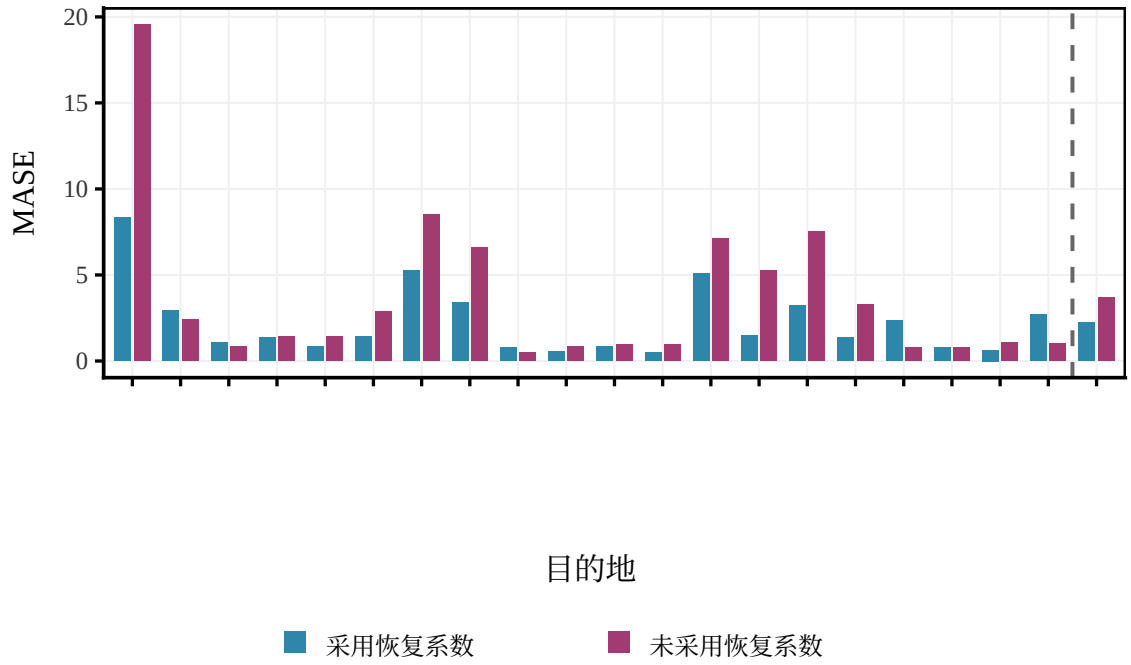

图9：采用和未采用恢复系数时的平均绝对缩放误差 s.

结果显示，不同目的地的区间预测表现存在显著差异，反映出旅游需求复苏的不确定性和可预测性均具有异质性。例如，加拿大、墨西哥和韩国（大韩民国）的Winkler评分相对较低，且覆盖概率接近名义水平，表明这些区间不仅较为集中，而且校准良好。相比之下，香港、柬埔寨和夏威夷等目的地的Winkler评分明显更高，覆盖概率也显著更低，这表明其区间可能过宽，或未能充分涵盖实际观测值。这些结果在很大程度上可归因于我们的模型对这些目的地恢复率的估计存在较大误差。COVID-19可能导致这些目的地出现系统性变化，从而使区间预测难以捕捉此类变化。

5. 结论与讨论

COVID-19疫情对全球旅行造成了深远冲击，带来了前所未有的不确定性和结构转变，给传统预测方法带来挑战。本文提出了一种融入复苏因素的三阶段预测框架，旨在预测疫情后中国出境旅游的反弹情况。该框架整合了基于疫情前数据训练的多个预测模型、实时外部指标，以及关于复苏轨迹的专家见解，为高度动荡的环境下开展预测提供了一种透明且灵活的方法。旅游预测竞赛第二轮的结果验证了所提方法的有效性，表明该方法在大多数目的地上表现稳健，并凸显了将定量模型与结构化专家判断相结合的优势。

本研究推进了关于危机后旅游需求预测的新兴文献，说明定量建模如何能够有效地与专家

表10：使用Winkler评分和覆盖概率评估区间预测 y.

目的地	Winkler评分	标准Winkler评分	覆盖概率
加拿大	26693	1.22	58%
智利	5023	1.98	17%
墨西哥	8589	0.52	92%
中国台北	153664	5.26	25%
中国香港	9881721	3.60	0%
日本	324513	0.73	75%
韩国（大韩民国）	184305	0.56	83%
中国澳门	1744672	0.90	67%
马尔代夫	20936	0.99	75%
柬埔寨	161546	2.80	8%
印度尼西亚	94423	1.03	58%
新加坡	179402	0.84	67%
新西兰	24355	1.21	58%
USA	146048	1.28	67%
泰国	359414	0.74	83%
土耳其	57454	1.89	0%
澳大利亚	43727	0.64	92%
夏威夷	13199	10.96	8%
奥地利	20042	0.76	92%
捷克	56897	2.81	25%

判断处于深刻的不确定性之中。RISE框架将基于模型的预测与实时外部数据以及经判断赋值的复苏系数综合起来，为传统时间序列方法因结构突变而受阻时的预测提供一套系统化方法。该方法在统计精度与情境适应性之间取得平衡，契合日益增强的认识，即在动荡时期，混合模型优于纯粹数据驱动或完全主观的方法。尤为关键的是，这种整合对于历史数据有限的复苏预测至关重要，使专家能够以实时洞察补充定量分析。

从实践角度来看，我们的研究结果表明，不同目的地的复苏轨迹存在显著差异。香港、澳门、日本和韩国等短途目的地的复苏速度明显快于预期，这凸显了地理邻近性和区域连通性的关键作用。相反，欧洲和北美等长途目的地的复苏则较为缓慢，这可能是由于签证限制持续存在、旅行费用高昂以及航班运力有限。这些观察结果表明，在后新冠疫情时期，距离仍是影响旅游业复苏速度的关键因素。此外，我们的预测也为旅行社和政策制定者提供了宝贵见解。对于旅行社而言，认识到不同市场的复苏模式各异，有助于更精准地开展营销工作并提高资源配置效率。在复苏较慢的市场，旅行社可以暂时缩减资源投入，例如减少营销预算和销售人员，同时密切监测搜索量趋势和航班恢复数据等指标，以确定资源重新配置的最佳时机。反之，旅行社可以通过增加营销投入、加强与本地供应商和航空公司的合作，以及打造定制旅游套餐，将更多促销活动投向复苏潜力较高的目的地，以吸引更多游客。

对于政策制定者，我们的研究结果有助于预测旅游活动波动，从而能够主动调整财政支持、基础设施建设和劳动政策，更好地适应持续变化的复苏动态。

尽管我们的研究结果提供了有价值的见解，但本研究仍存在若干值得指出的局限性。首先，复苏系数是根据地理距离、恢复状况和政策因素通过启发式方法设定的，而经济决定因素并未进行量化建模。根据经典需求理论，客源国居民的收入水平以及目的地的相对价格是旅游需求最重要的决定因素之一。然而，宏观经济变量通常比政治或地理因素更为波动，若缺乏准确估算，将其纳入分析可能并不可靠。鉴于大流行病后旅游业复苏具有不稳定且快速变化的特征，宏观经济指标与游客到访量之间的关系也可能复杂多变，难以建模。未来研究可以纳入实际GDP增长、消费者信心和相对价格指数等宏观经济指标，以更好地估算这些指标对旅游业复苏的影响。鉴于GDP或消费者价格指数等一些宏观经济变量通常按季度或年度频率提供，它们更适合用于为中期复苏情景提供参考，或用于校准复苏假设，而非作为我们框架的直接输入。

除旅游业外，我们认为，RISE框架为预测突发冲击后的行业复苏提供了一种灵活通用的方法，可应用于酒店业、航空业、能源业和零售业等领域。在这些领域，数据有限且结构波动性较大，传统方法因此面临挑战。RISE将定量建模与专家判断相结合，提供了一种灵活、透明且适应性强的预测工具，适用于不确定性较高的情境。

本研究还为未来研究开辟了若干颇具前景的方向。当前框架侧重于点预测，将RISE框架扩展为完整的概率预测，有助于更全面地量化不确定性。贝叶斯模型平均、分位数回归森林或基于模拟的集成方法等技术，可用于研究如何在高度不确定的情况下对整个预测分布进行建模。未来研究还可开发数据驱动方法，在出现新的观测数据或政策变化时动态更新复苏系数。尽管我们采用了分层预测，但当前模型在复苏调整阶段将各目的地视为相互独立。然而，国际旅游网络往往存在溢出效应——一个地区的复苏可能通过联程航班、共同需求冲击或协调政策影响其他地区。一个自然的后续方向是采用时空模型或基于图的模型来捕捉此类依赖关系。在复苏启发式方法这一概念的基础上，RISE框架还可进一步支持与特定政策或市场假设相联系的基于情景的预测。若将其与下游优化任务（例如旅游推广规划或航班调度）相结合，该框架便可逐步转向面向决策的预测范式。

致谢

Feng Li（首席研究员）、TaozhuRuan、Kexin Shi、Yuchen Xue 和 Yiming Zhong 参加了新冠疫情期间旅游预测竞赛第二轮

团队名称为$KLLAB_CN$。竞赛中提出的方法在点预测中排名第一，在区间预测中排名第三。本文在竞赛结束后撰写，由 Feng Li 和 Taozhu Ruan 主导论文准备和扩展分析。作者感谢竞赛组织者提供平台和数据，并感谢编辑和四位匿名审稿人提出的宝贵意见，这些意见改进了论文内容。本研究获得国家自然科学基金委员会（编号：72495123）资助。

参考

Anderer, M., & 李峰. (2022). 采用自上而下协调独立层级预测的层次化预测。《国际预测学杂志》, *38*(4), 1405– 1414. Andrawis, R. R., Atiya, A. F., & El-Shishiny, H. (2011). 长期与短期预测的结合及其在旅游需求预测中的应用。《国际预测学杂志》, *27*(3), 870–886. Athanasopoulos, G., & Hyndman, R. J. (2008). 澳大利亚国内旅游建模与预测。《旅游管理》, *29*(1), 19–31. Athanasopoulos, G., Hyndman, R. J., Kourentzes, N., & O'Hara-Wild, M. (2023). 利用专家判断进行概率预测：C OVID-19后的复苏之路。《旅游研究杂志》, *62*(1), 233–258. Athanasopoulos, G., Hyndman, R. J., Kourentzes, N., & Panagiotelis, A. (2024). 预测协调：综述。《国际预测学杂志》, *40*(2), 430–456. Baláž, V., Chen, J. L., Williams, A. M., & 李. (2024). 旅游业风险与不确定性偏好的稳定性。《旅游研究年刊》, *105*, 103726. Box, G. E. P., & Tiao, G. C. (1975). 干预分析及其在经济和环境问题中的应用。《美国统计协会期刊》, *70*(349), 70–79. Chu, F.-L. (2008). 一种用于旅游需求预测的分数阶积分自回归移动平均方法。《旅游管理》,*29*(1), 79–88. Cleveland, R. B., Cleveland, W. S., McRae, J. E., & Terpenning, I. (1990). STL：一种基于局部加权回归的季节性-趋势分解程序。《官方统计学杂志》, *6*(1), 3–73. De Livera, A. M., Hyndman, R. J., & Snyder, R. D. (2011). 使用指数平滑法预测具有复杂季节性模式的时间序列。《美国统计协会期刊》, *106*(496), 1513–1527. Fildes, R., Goodwin, P., Lawrence, M., & Nikolopoulos, K. (2009). 有效预测与判断调整：供应链规划改进策略的实证评估。《国际预测学杂志》, *25*(1), 3–23. Goh, C., & Law, R. (2002). 对具有随机非平稳季节性和干预因素的游客到访量进行建模与预测。《旅游管理》, *23*(5), 499–510. Goh, C., & Law, R. (2011). 旅游需求预测的方法论进展：相关文献综述。《旅游与旅行营销杂志》, *28*(3), 296– 317. Gross, C. W., & Sohl, J. E. (1990). 加快产品线预测的分解方法。《预测学杂志》, *9*(3), 233–254.

Gunter, U., & Önder, I. (2015). 巴黎国际城市旅游需求预测：采用月度数据的单变量和多变量模型的准确性。《旅游管理》, *46*, 123–135. Holt, C. C. (1957). 利用指数加权移动平均进行趋势和季节性预测。*ONR*研究备忘录，卡内基理工学院 *52*。Hu, M., Dong, N., & Hu, F. (2024). 利用短视频信息预测旅游需求。《旅游研究年刊》,*109*, 103838. Hyndman, R., Athanasopoulos, G., Bergmeir, C., Caceres, G., Chhay, L., O'Hara-Wild, M., Petropoulos, F., Razbash, S., Wang, E., & Yasmeen, F. (2023). *forecast*：用于时间序列和线性模型的预测函数。Hyndman, R., Lee, A., Wang, E., & Wickramasuriya, S. (2024). *hts*：分层与分组时间序列。Hyndman, R. J., & Khandakar, Y. (2008). 自动时间序列预测：适用于 R 的 forecast 软件包。《统计软件杂志》, *27*(3), 1–22. Hyndman, R. J., Koehler, A. B., Snyder, R. D., & Grose, S. (2002). 利用指数平滑法实现自动预测的状态空间框架。《国际预测学杂志》,*18*(3), 439–454. Kourentzes, N., Saayman, A., Jean-Pierre, P., Provenzano, D., Sahli, M., Seetaram, N., & Volo, S. (2021). COVID-19期间的游客到达量预测：来自非洲团队的观点。《旅游研究年刊》,*88*, 103197. Li, H., Gao, H., & Song, H. (2023). 基于细粒度情感分析的旅游预测。《旅游研究年刊》,*103*, 103667. Li, J., Xie, W., Wang, J., Gao, J., Zhang, L., Wang, J., & Li, S. (2026). 基于多因素洞察预测旅游业复苏——以后疫情时代中国出境旅游为例。《旅游研究年刊》, *116*, 104089. Li, S., Chen, T., Wang, L., & Ming, C. (2018). 基于主成分分析、改进的反向传播神经网络和百度指数的有效游客量预测。《旅游管理》, *68*, 116–126. Li, X., Gong, J., Gao, B., & Yuan, P.(2021). COVID-19对游客目的地偏好的影响：中国的证据。《旅游研究年刊》, *90*, 103258. Lim, C., & McAleer, M. (2001). 月度季节性变化：亚洲赴澳旅游。《旅游研究年刊》, *28*(1), 68–82. Lin, V. S., Goodwin, P., & Song, H. (2014). 专家调整后预测的准确性和偏差。《旅游研究年刊》, *48*, 156–174. Liu, A., Vici, L., Ramos, V., Giannoni, S., & Blake, A. (2021). COVID-19期间的游客到达量预测：来自欧洲团队的观点。《旅游研究年刊》,*88*, 103182. Moritz, S., & Bartz-Beielstein, T. (2017). Imputets：R中的时间序列缺失值插补。《*R*杂志》, *9*(1), 207–218. Neumayer, E. (2010). 签证限制与双边旅行。《职业地理学家》,*62*(2), 171–181. Palmer, A., José Montaño, J., & Sesé, A. (2006). 设计用于预测旅游时间序列的人工神经网络。《旅游管理》, *27*(5), 781–790. Perron, P. (2006). 应对结构突变。载于《帕尔格雷夫计量经济学手册》第*1*卷：计量经济理论 (pp. 278–352). Petropoulos, F., Kourentzes, N., Nikolopoulos, K., & Siemsen, E. (2018). 预测模型的判断性选择。《运营管理杂志》, *60*, 34–46.

Qiu, R. T. R., Wu, D. C., Dropsy, V., Petit, S., Pratt, S., & Ohe, Y.（2021）。COVID-19疫情期间的游客到达量预测：来自亚太地区团队的视角。《旅游研究年刊》，*88*，103155。Saayman, A., & Botha, I.（2017）。旅游需求预测的非线性模型。《旅游经济学》，*23*(3)，594–613。Salinas, D., Flunkert, V., Gasthaus, J., & Januschowski, T.（2020）。DeepAR：基于自回归循环网络的概率预测。《国际预测学杂志》，*36*(3)，1181–1191。Sigala, M.（2020）。旅游业与COVID-19：对产业和研究发展的影响及启示。《商业研究期刊》，*117*，312–321。Škare, M., Soriano, D. R., & Porada-Rochoń, M.（2021）。COVID-19对旅行与旅游产业的影响。《技术预测与社会变革》，*163*，120469。Smeral, E.（2017）。考虑需求弹性不稳定性的旅游预测表现。《旅游研究杂志》，*56*(7)，913–926。Song, H., & Li, G.（2008）。旅游需求建模与预测——近期研究综述。《旅游管理》，*29*(2)，203–220。Song, H., & Lin, S.（2010）。金融与经济危机对亚洲旅游业的影响。《旅游研究杂志》，*49*(1)，16–30。Taylor, S. J., & Letham, B.（2018）。大规模预测。《美国统计学家》，*72*(1)，37–45。联合国旅游组织。（2019）。*2019*年世界旅游日庆祝“旅游与就业：共创更美好的未来”。van Dijk, D., & Franses, P. H.（2019）。结合专家调整预测。《预测学杂志》，*38*(5)，415–421。Wang, W., & Li, F.（2025）。运用分段组合VARX模型预测中国出境旅游。《经济与管理季刊》，*04*(1)，255–284。Wang, X., Hyndman, R. J., Li, F., & Kang, Y.（2023）。预测组合：五十余年回顾。《国际预测学杂志》，*39*(4)，1518–1547。Wen, Q., Zeng, Y., Petropoulos, F., & Kang, Y.（2026）。基于自动化不变性约束的旅游需求一致性预测。《旅游管理》，*113*，105342。Wickramasuriya, S. L., Athanasopoulos, G., & Hyndman, R. J.（2019）。通过迹最小化实现分层与分组时间序列的最优预测协调。《美国统计协会期刊》，*114*(526)，804–819。Winkler, R. L.（1972）。一种区间估计的决策理论方法。《美国统计协会期刊》，*67*(337)，187–191。Winters, P. R.（1960）。运用指数加权移动平均预测销售额。管理科学，*6*，324–342。Yang, Y., Fan,Y., Jiang, L., & Liu, X.（2022）。疫情期间的搜索查询与旅游预测：数字足迹何时何地可作为有效预测因子？《旅游研究年刊》，*93*，103365。Zhang, H., Liu, Y., Liu, X., Liu, A., & Lin, V. S.（2026）。中国出境旅游复苏预测：三层预测组合框架。《旅游研究年刊》，*116*，104079。Zhang, H., Song, H., Wen, L., & Liu, C.（2021）。COVID-19疫情期间的旅游业复苏预测。《旅游研究年刊》，*87*，103149。