arXiv:2603.04551v1 [stat.AP] 4 Mar 2026

天气相关交通事故风险预测：一种面向异质时空数据的深度学习方法

Abimbola Ogungbire，博士[1] 和 Srinivas Pulugurtha，博士、PE[2*1]交通工程，Gresham Smith，美国佐治亚州阿尔法利塔，30009。
[2*]土木工程，密西西比大学，美国密西西比州牛津，38677。

通讯作者。电子邮箱：sp@olemiss.edu；贡献作者：abim.ogungbire@greshamsmith.com；

摘要

本研究提出一种基于深度学习的框架，利用异质时空数据预测天气相关的交通事故风险。鉴于交通事故发生与道路特征、交通状况等因素之间存在复杂的非线性关系，我们提出一种在相互重叠的空间网格上训练的 ConvLSTM 模型集成方法。该方法在处理事故模式空间异质性的同时，能够捕捉空间依赖关系和时间动态。我们选择北卡罗来纳州作为研究区域，因为该州天气状况多样；并将历史交通事故、天气和交通数据汇总至分辨率为 5 英里×5 英里的网格。我们使用均方误差（MSE）、均方根误差（RMSE）和空间交叉K分析对该框架进行评估。结果表明，集成 ConvLSTM 显著优于基准模型，包括线性回归、自回归积分滑动平均模型和标准 ConvLSTM，尤其是在高风险区域。集成方法有效融合了多个 ConvLSTM 模型的优势，使所有区域的 MSE 和 RMSE 值均有所降低，尤其是在汇总不同交通事故风险区域的数据时。值得注意的是，该模型在波动较大的高风险区域（簇1）表现出色，取得了最低的 MSE 和 RMSE；而在稳定的低风险区域（簇2），虽然仍优于较简单的模型，但由于难以捕捉细微变化，误差略高。

关键词： 事故预测、时空、长短期记忆网络、天气相关交通事故、深度学习、长短期记忆网络、集成 ConvLSTM

1 引言

美国大多数城市的快速城市化带来了安全与可持续发展方面的挑战。在北卡罗来纳州等天气状况多变的州，这些挑战更加严峻。联邦公路管理局（FHWA）报告称，所有事故中有 21% 与天气有关 [1]。2007 年至 2016 年间，近 5,400 人死于天气相关事故，这使天气成为交通事故的主要诱因之一 [1]。因此，鉴于智能交通系统（ITS）有望减少恶劣天气状况下的事故，它已成为一个活跃的研究领域[2]。作为改进智能交通系统的一项关键举措，天气相关交通事故预测旨在预测交通系统中特定地点未来的事故状况。

对交通事故数据进行空间分析正日益普及。过去几十年间，研究人员投入了大量精力，从不同空间尺度分析交通事故数据 [3–6]。在我们近期的研究 [5], [7], 中，我们率先将时空立方体理论应用于交通事故风险分析。我们详细说明了州政府机构倾向于在空间聚合尺度上考察交通事故数据，其中包括交通分析区 (TAZ) [8]和网格级空间单元 [5], [9], ，以便有效促进资源分配 [10]。本研究基于 [5] 奠定的基础，预测网格尺度上未来可能发生的天气相关交通事故事件风险。

近年来，与城市环境中人类活动相关的大型数据集日益丰富，推动了交通事件研究的显著增长 [11–13]。这些海量数据为从历史事件中学习、进一步理解和预测未来交通事件提供了前所未有的机会。近期研究已探索将大数据整合到空间聚合交通事故模型中 [11], [14]。Bao 等人 [11]的一项研究考察了如何利用源自交通传感器和社交媒体的大数据，改进空间聚合交通事故模型。他们提出了一种方法，将传统交通数据与实时社交媒体分析相结合，以预测城市地区的交通事故热点区域。

早期研究将交通事故预测视为分类问题或回归问题。例如，一些研究旨在预测特定地点 [15, 16] 或时间段 [16]发生交通事故的可能性。通过这种视角研究事故预测，研究人员能够识别事故的重要预测因子并量化其影响。相反，另一些研究则侧重于估算每个时间窗口 [14, 17–19]内特定地点的交通事故强度。随着时间推移，该领域逐渐采用更复杂的方法，包括时间序列分析 [20], [21] 以了解时间模式，以及机器学习模型 [22], [23]以捕捉变量之间复杂的非线性关系。此外，地理信息系统（GIS）也被用于对交通事故数据进行空间分析，并识别高风险区域 [24, 25]。这些方法已从简单的确定性模型发展为动态的概率模型，能够更好地考虑预测人类行为和环境相互作用时固有的不确定性。

深度学习方法在计算机视觉 [26], 自然语言处理 [27],人工智能和模式识别领域日益普及 [26], [28], 如今也开始应用于交通安全研究。这些应用包括交通冲突预测 [28], [29], 在交叉口进行险情识别，以及

交叉口 [30],估算不安全驾驶速度，以及识别信号灯交叉口的闯红灯违规行为 [31]。深度学习有别于传统统计模型和其他学习架构，其优势在于能够通过分布式和层次化特征表示对复杂的非线性关系进行建模 [32], ，在短期交通流和速度预测方面表现出色。

本文介绍了一种集成卷积长短期记忆网络（集成 ConvLSTM），这是一种旨在利用大规模异质时空数据预测交通事故的深度学习方法。我们将研究区域划分为网格单元，并收集每个网格单元的城市及环境特征详细信息，例如交通量、道路状况、交通管理数据和天气状况。利用这些数据，我们构建了一个模型，用于预测未来各时间段每个网格单元内发生的事故数量。我们的方法采用 ConvLSTM 神经网络，有助于我们更好地理解和预测数据随时间和空间变化的模式与差异。此外，我们还创建了一个集成框架，针对不同风险区域分别训练模型，并将各模型的结果组合起来，生成最终预测。据我们所知，这是首项利用深度神经网络处理交通事故预测中空间变异性的研究，也是首项将 ConvLSTM 应用于这一目的的研究。结果表明，我们的模型显著优于传统方法，在交通事故预测方面具有更高的准确性。

2 相关研究

本节首先讨论恶劣天气状况在道路交通事故中的作用。接着，我们介绍了有关使用传统模型进行交通事故预测的共识，以及采用经典方法的必要性。最后，我们对用于交通事故预测的深度学习技术进行了最新分析。

2.1 天气相关事故

事故由多种因素造成，可分为行为因素、技术因素和环境因素 [23]。缺少其中任何一项，都有可能避免事故。虽然天气并非道路交通事故的主要成因[1], [23]，但其重要性不容忽视。包括 Vickery [33]和 Downs [34], 在内的研究表明，除非天气状况严重妨碍出行，否则大多数人不会认为恶劣天气会阻止他们驾车。Bergel-Hayat 等人 [35] 等研究者证实了天气状况与道路运输之间的关联，并详细说明了恶劣天气如何造成不便，甚至迫使旅客取消旅行计划 [35]。

与其他交通方式不同，车辆通常并非为在极端天气状况下行驶而设计。这与飞机形成鲜明对比，飞机配备了应对恶劣大气状况的设备。恶劣天气对道路安全的影响错综复杂，不能简单归结为因果关系。Jackson 和 Sharif[36] 的研究表明，降雨会增加事故率，而更多人选择在湿滑路况下驾车，则进一步加剧了这一情况。然而，防抱死制动系统和牵引力控制系统等技术的引入，改变了车辆在恶劣

天气下的行驶方式，也可能导致驾驶行为变得更加冒险，因为驾驶员会因这些功能而更有信心 [37]。

有趣的是，天气相关挑战并不总会导致严重事故。在某些情况下，例如降雪时，驾驶员往往会更加谨慎，降低车速，从而减轻风险。在天气状况不佳时，取消或推迟旅行计划也能降低发生事故的可能性 [38]。

2.2 使用传统模型进行事故预测

使用传统模型进行交通事故预测的发展，体现了从线性统计模型向更动态、更复杂的计算模型转变的过程 [15–23]。不同预测技术的融合，例如将灰色模型与马尔可夫链结合，或利用神经网络分析来增强 ARIMA 对非线性成分的处理能力，体现了跨学科方法在实现更准确、更稳健的交通事件预测方面的应用。

时间序列预测方法一直是预测交通事故的基础，它们利用历史数据估计未来结果 [20]。这些方法会考察随时间收集的数据点序列，分析长期趋势、季节性和不规则因素等模式。时间序列预测的主要方法包括指数平滑法 [20], [39],，该方法强调较早数据的重要性会逐渐降低；以及 ARIMA（自回归积分滑动平均模型），这是一种将观测值差分（以消除非平稳性）与自回归和移动平均相结合的模型 [20], [39]。这些方法基于这样一个前提：交通事故数据中的过去模式可以为未来事件提供参考；其中，指数平滑和 ARIMA 等技术尤其擅长对交通事故进行建模和预测 [20], [39], [40]。

指数平滑模型，包括简单指数平滑及其用于处理趋势和季节性的扩展模型 [39], ，为平滑时间序列数据、识别潜在趋势提供了一个框架。这些模型的精妙之处在于其统计学原理，通过状态空间模型 [40]，能够处理各种形式的趋势和季节性。自回归积分滑动平均模型（ARIMA）及其前身自回归滑动平均模型（ARMA）进一步推动了该领域的发展，通过处理时间序列的随机特性，并根据数据的平稳特征进行模型选择。这些模型已用于修正交通事故预测中的误差项，并与回归模型等其他方法相结合，以提高预测结果的可靠性。

马尔可夫链模型采用概率方法进行预测，重点关注随时间变化的离散状态之间的转移概率 [41]。这种方法适用于随机波动显著但没有明显趋势的情形，有助于揭示交通事故的随机特性。

2.3 天气相关事故预测的深度学习模型

深度学习是机器学习的一个子领域，其特点是使用具有多个层次的神经网络。它已成为交通领域的一种强大工具

事故预测 [26–30]。在相关文献中，深度学习在交通事故预测中的应用仅限于卷积神经网络（CNNs）、循环神经网络（RNNs）等特定模型，以及长短期记忆网络（LSTM）和门控循环单元（GRUs）等变体。这些架构擅长处理交通系统中固有的时空数据，能够对传统模型可能忽略的复杂模式和关系进行建模。

卷积神经网络已被证明能够有效处理空间数据，因此适合分析按地理单元汇总的交通事故数据，例如网格地图 [26]。卷积神经网络通过卷积滤波器捕捉空间依赖关系，能够识别与交通流、道路基础设施及其他空间因素相关的模式，这些因素都会影响交通事故风险 [30]。另一方面，循环神经网络和长短期记忆网络专为处理序列数据而设计，能够刻画交通事故发生的时间动态。这些模型能够从历史事故数据中学习，识别随时间变化的模式，例如交通量的周期性特征及其与交通事故的相关性 [32]。此外，能够记忆长期依赖关系的长短期记忆网络，在克服传统循环神经网络中常见的梯度消失问题方面尤为有效。

Major improvement
nk-level crash frequency model developed.
oth XGBoost and RF models generated milar results on feature importance for ree sets of models. Also, there are on-linear relationships of many risk factors th bus crashes
redict traffic conflict by mining heterodox ata.
xponential smoothing model has a better on crash data over SARIMA judging from e MAE, RMSE, MAPE, and BIC score
tegrating time series with a count data odel can capture traffic crash features and count for the temporal autocorrelation
affic volume use in crash rate analysis.
odel for equitable planning/incentive ograms.
nproved DNN modeling for dynamic nditions.

2.4 文献缺口与未来方向

尽管深度学习在交通事故预测方面展现出巨大潜力，但仍面临若干挑战。这些挑战包括：需要大量且多样化的数据集来有效训练模型；深度学习算法的计算复杂性和资源需求；以及这些模型的“黑箱”特性，往往使其预测结果难以解释。要应对这些挑战，需要持续开展研究与开发，包括努力提高模型的透明度和可解释性、提升计算效率，并确保交通数据得到合乎伦理的使用。

此外，将深度学习模型与物联网（IoT）和边缘计算等新兴技术相结合，为未来的交通事故预测带来了令人振奋的机遇。通过利用网络边缘的实时数据收集和处理能力，可以开发出更动态、响应更迅速的预测模型，使其能够适应不断变化的交通状况，并为构建更安全、更高效的交通系统作出贡献。

3 方法论

本节介绍研究中使用的数据，阐述问题的表述方式，并介绍我们的特征提取技术。

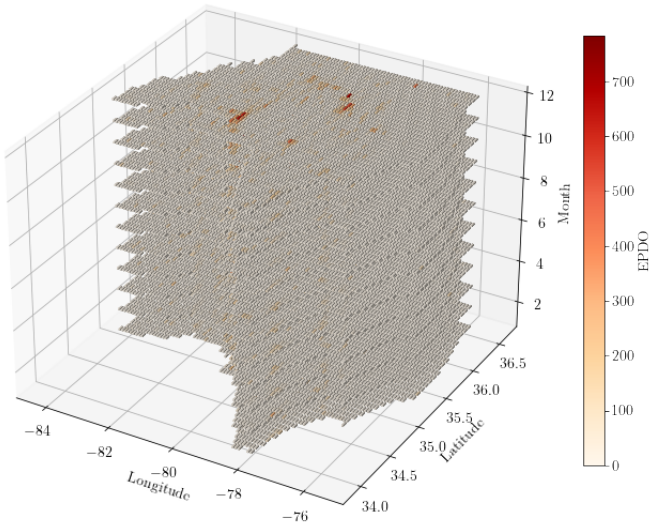

图 1：研究区域中构建的时空立方体

3.1 数据来源

在分析中，我们选取美国北卡罗来纳州（NC）作为研究区域。北卡罗来纳州的天气现象丰富多样，包括但不限于降雪、降雨和风。这种天气状况的多样性使北卡罗来纳州成为研究天气，尤其是降水，对道路交通事故影响的理想州份；一项研究也指出了这一点： [46] 他们的研究。我们的研究主要使用的数据集来自公路安全信息系统 HSIS[43, 47], ，涵盖2015年至2018年的车辆碰撞记录。研究使用新冠疫情前的数据，因为疫情期间的出行行为导致交通需求、暴露程度和碰撞机制出现结构突变。纳入此类受扰时期的数据会违反时空预测模型所依据的平稳性假设，并使参数学习产生偏差，从而降低模型对正常道路状况的泛化能力。在 [5, 7], 的研究基础上，本研究将时空立方体框架应用于网格层面，预测未来可能发生的天气相关交通事故风险。北卡罗来纳州交通事故地点的空间分布见图1。为避免信息泄漏，模型未纳入天气特征。实际应用中，预测周的未来天气无法实时获取，因此模型仅使用在恶劣天气条件下记录的事故进行训练，从而无需使用未来天气数据即可预测天气相关碰撞风险。

3.2 问题定义

我们的目标是构建一个预测框架，用于估算空间网格 S 的指定单元在不同时间区间内发生的交通事故总数。该网格记为 $S = \{s_1, s_2, \ldots, s_n\}$，由 n 个细分单元组成，每个单元代表 $d \times d$ 平方英里的面积。举例来说，若考虑 $d = 5$英里，那么北卡罗来纳州的整个地理区域可划分为 2，045 个网格单元。时间被划分为离散区间，称为时段。本分析采用一周（7 天）作为标准时长，但该方法支持在空间维度（d）和时间维度（t）上进行调整。图2 展示了训练数据集的 EPDO 趋势。我们将问题表述如下：

给定输入：

- 一个由矩阵 $S \times T$ 表示的时空框架，其中 S 表示具有 n 个划分单元的空间网格，而 T 则表示研究期间的一系列 t 时间区间。
- 一个维度为 $n \times t$ 的矩阵 A，其中元素 A_{ij} 表示空间单元 s_i 在时间 t_j 的碰撞等效财产损失。
- 一系列矩阵 m $\{M_1, M_2, \ldots, M_m\}$，每个矩阵 M_k 的维度为 $n \times t$，用于记录各网格单元 s_i 在各个时间段 t_j 的不同相关属性。
- 训练数据集 $D_{\text{训练}}$由 A 中的时间区间与 $T_{\text{训练}}$时间段内的特征矩阵所组成的配对数据构成，测试数据集 $D_{\text{测试}}$则包含$T_{\text{测试}}$时间段内时间区间的配对数据。

目标：

• 构建一个能够准确预测 A 所有$t_j \in T_{测试}$时间区间的事故数量矩阵的模型，旨在最小化预测事故数量与实际事故数量之间的差异。

约束条件：

•事故数量与特征（M_k）之间的相关性因不同空间单元而异。

• 假设事故仅发生在道路网络范围内。
• 对于任何即将到来的时间段 t_i，相应的特征矩阵 $M_{k,\ t_i}$ 无法用于预测 $A_{i,\ t_i}$，这意味着 $t_i \in T_{测试}$。

3.3 特征提取

为准备模型所需的特征，我们将数据集与每个网格 s_i和每周 t_i 的组合进行对齐，并汇总数据以整理出特征列表。对于因变量，我们计算了2015年1月至2018年12月期间每个网格 s_i 在每周 t_i的 EPDO。提取自变量特征的过程详见以下各节。

我们将道路网络映射到网格单元上，并叠加掩膜图层以划定研究区域。需要注意的是，尽管整个区域按网格划分，交通事故仍仅限于道路网络。我们基于两个因素评估每个网格的风险等级：事故频率和事故严重程度。为获得更准确的预测结果，我们用每个网格内的道路总长度对EPDO评分进行归一化，并为没有道路的网格赋予空值。鉴于道路网络随时间保持稳定，该特征被视为时不变特征。

在分析中，我们通过计算并存储每个网格单元的两项附加指标来增强网络掩膜图层：平均道路长度和平均限速。此外，我们纳入了与道路属性相关的特征，包括不同交通控制类型的比例、平均车道数、不同路线类型的比例、道路，以及各网格单元的年平均日交通量（AADT） s_i。这些特征被视为时不变特征。

3.4 实验设置

本研究旨在利用基于2015年至2017年数据训练的深度学习模型，预测北卡罗来纳州2018年的天气相关事故。该数据集按周聚合，形成包含209个时间帧的序列：其中157个用于训练，52个用于测试，并将10%的训练帧留作验证以调整超参数。每个时间帧由一个空间张量构成，代表北卡罗来纳州全境2,153个5英里网格单元。

对于2018年的每一周，所提出的ConvLSTM模型基于历史事故、道路和交通数据，预测每个网格单元中的事故结果。我们的研究由以下三个研究问题引导：

1. 所提出的框架在预测准确度方面是否优于传统模型和标准 ConvLSTM?

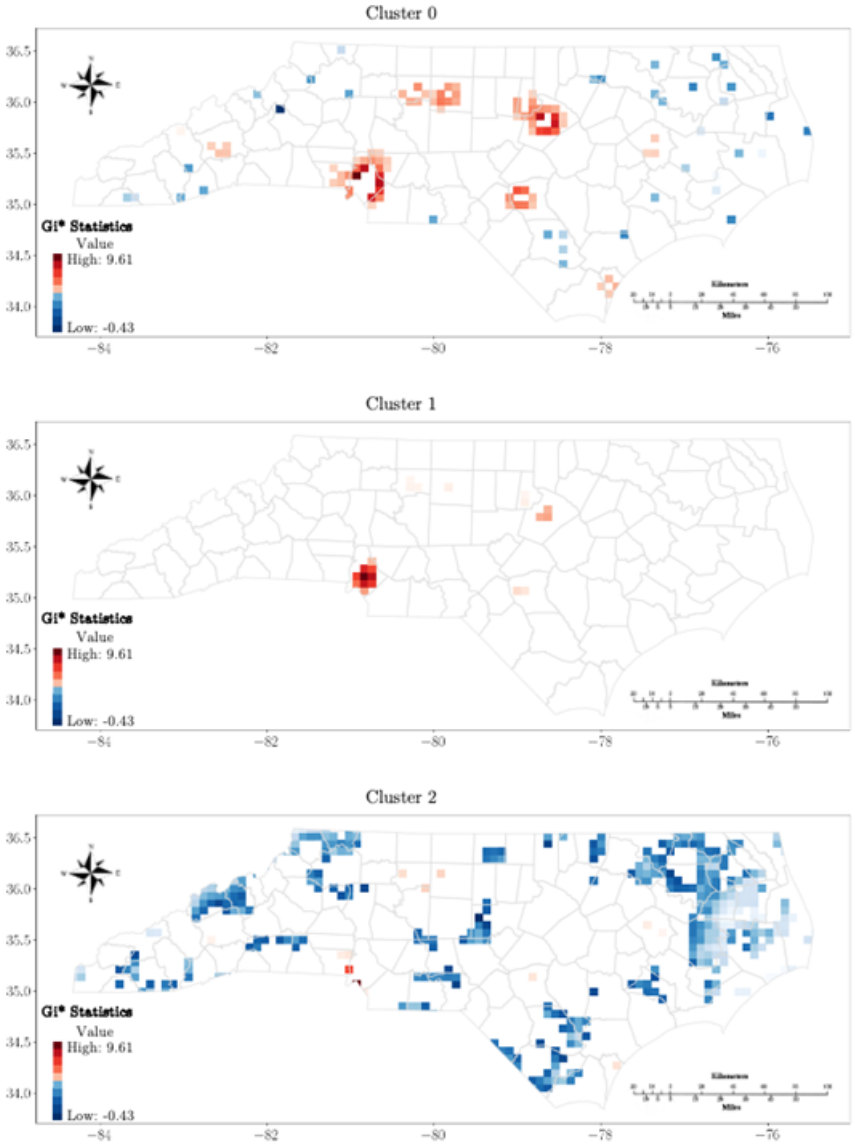

图2：DTW-G*聚类

2. 我们提出的模型在不同事故风险区域（例如高风险和低风险区域）的表现有何差异？3. 模型的预测结果在空间上是否与实际交通事故地点相符，从而验证其合理性?

为评估模型的精确度，我们采用均方误差（MSE）和均方根误差（RMSE）作为主要指标。此外，Cross-K函数

用于评估预测结果与实际数据之间的空间相关性。

3.5 时空集成 ConvLSTM

本节介绍我们预测天气相关事故的方法。首先，我们描述用于本研究的单个卷积长短期记忆网络（ConvLSTM）框架。随后，我们详细阐述时空卷积长短期记忆网络（空间 ConvLSTM）模型的构建过程，该模型包含多个 ConvLSTM。ConvLSTM模型是传统长短期记忆网络的扩展，最初由 Shi 等人（2015年）为降水临近预报开发。该模型尤其适用于处理空间维度和时间维度都至关重要的数据。ConvLSTM 网络的每个输入都被视为一个三维时空张量。典型的长短期记忆网络节点在 ConvLSTM 中经过修改，将卷积运算纳入其结构，如图 3所示的单个 ConvLSTM 中所示。具体而言，ConvLSTM 单元中的输入到状态和状态到状态转换涉及卷积运算，并输出三维张量。这些修改由算法 1控制。

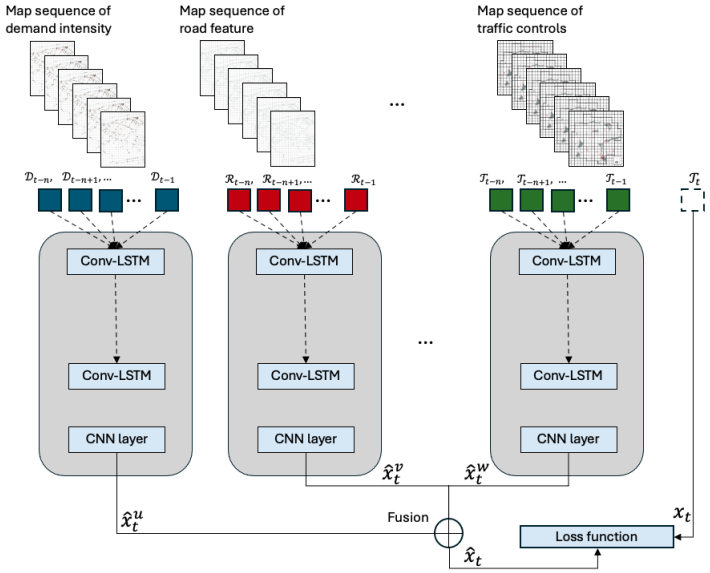

图 3：单个 ConvLSTM 架构

为应对天气相关事故预测中的空间异质性挑战，该方法针对研究区域内的不同簇分别构建长短期记忆网络模型。这些簇根据数据的空间异质性确定，可反映不同的风险等级，例如图4所示的高风险或低风险区域。随后采用集成方法整合多个模型的结果，从而减轻数据异质性的影响。

算法1 空间集成卷积长短期记忆网络

为每个窗口初始化模型参数
在每个训练轮次中 $num\ epochs$ **执行**
    对每个窗口 $study\ area$ **执行**
        提取窗口内的时空数据 x
        对每个时间步 t在 x **中执行**
            计算输入门:
            $i_t = \sigma(w_{xi} * X_t + w_{hi} * h_{t-1} + b_i)$
            计算遗忘门:
            $f_t = \sigma(w_{xf} * X_t + w_{hf} * h_{t-1} + b_f)$
            计算输出门:
            $o_t = \sigma(w_{xo} * X_t + w_{ho} * h_{t-1} + b_o)$
            更新细胞状态:
            $C_t = f_t \cdot C_{t-1} + i_t \cdot$ 双曲正切函数$(w_{xc} * X_t + w_{hc} * h_{t-1} + b_c)$
            隐藏状态输出:
            $h_t = o_t \cdot$双曲正切函数(C_t)
            存储最后一个隐藏状态 h_t
        结束循环
        汇总并存储所有帧的输出
    结束循环
    使用集成方法合并所有窗口的预测结果
    评估模型性能
    根据梯度和学习率调整参数
结束循环

采用移动窗口技术，每个窗口的大小为 10×10个网格单元。此举旨在捕捉异质的局地气象模式。研究区域通过移动窗口进行划分，窗口从坐标为 (0,0) 的左上角移动至坐标为 (128, 64) 的右下角。窗口在网格上沿水平和垂直方向均以16个单位为步长移动，确保全面覆盖研究区域并形成重叠。这一策略有助于捕捉局部空间特征，从而准确预测事故。

对于每个滑动窗口区域，研究人员使用与该窗口对应的局部训练数据集训练专用的 ConvLSTM 模型。随后，该模型针对该特定区域的测试数据集进行预测。通过使用局部数据训练独立模型，可以捕捉各区域独特的时空特征；由于气象和交通状况各不相同，这些特征可能至关重要。特定网格位置 s_i 在第 t_j 周的最终预测结果通过集成方法计算得出，该方法汇总了所有覆盖 s_i 的模型所做的预测。该汇总结果是对 s_i 在 t_j 时所有显著模型的预测结果进行加权平均后得到的，如（公式1）所示。

$$\hat{C}(s,t) = \frac{1}{\sum_{k=1}^{N} w_k} \sum_{i=1}^{N} w_i \hat{C}_i(s,t) \times I(s \in W_i). \tag{1}$$

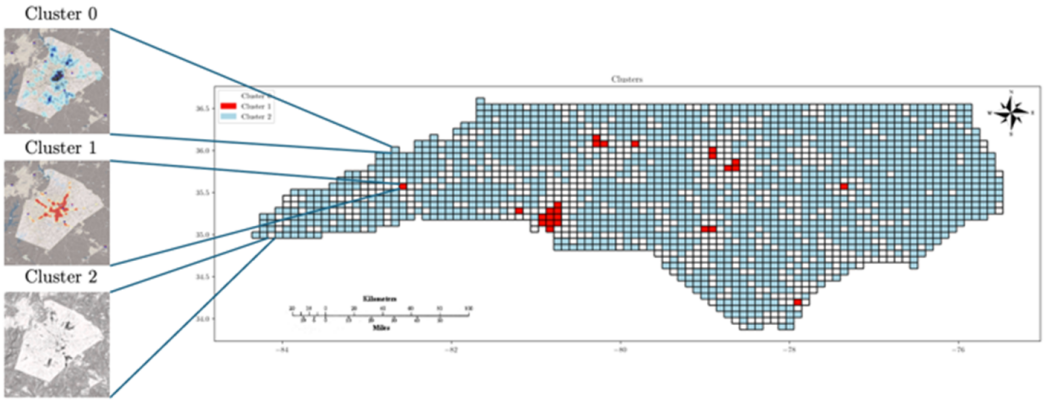

图 4：按簇划分的帧分布

4 结果

图 5 展示了四种预测模型的对比：LR、 自回归积分滑动平均模型、ConvLSTM 和时空集成 ConvLSTM。研究使用 Cross-K函数衡量这些模型对天气相关事故的预测准确性。以“距离”为横轴绘制的 Cross-K函数值，可用于评估各模型的预测结果与实际事件的吻合程度。

在四种预测模型中，线性回归的性能最低，其 Cross-K 函数值虽持续上升，但在整个范围内始终低于其他模型。这表明，线性回归虽然能够预测趋势，但其简单性限制了它捕捉天气相关交通事故数据中复杂模式的能力。自回归积分滑动平均模型的性能优于线性回归，但仍不及基于神经网络的模型。它能够将过去的数值和预测误差纳入未来预测，因此比线性回归略具优势；然而，它缺乏有效处理空间依赖性或多维时间依赖性的能力，而这对于天气相关事件的研究至关重要。

ConvLSTM的表现显著优于线性回归和自回归积分滑动平均模型，凸显了将卷积层融入LSTM网络的优势。这种架构使模型能够同时捕捉空间特征和时间序列，因此特别适用于天气模式等时空动态都很重要的场景建模。时空集成 ConvLSTM在所有距离范围内的Cross-K函数值均为最高。该模型整合了多个ConvLSTM模型，从而更稳健地利用多样的空间和时间特征，降低对模式过拟合的风险，并提升在各种场景下的泛化能力。

性能差异可归因于多个因素，例如模型的复杂度和架构。更复杂的模型（ ConvLSTM 和时空集成 ConvLSTM）旨在同时处理时空数据的复杂性，这对于准确建模

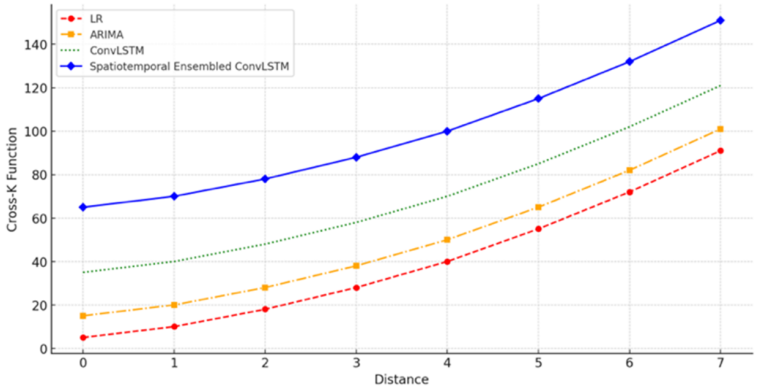

图5：预测与实际天气相关事故风险之间的Cross-K函数

天气相关事故这类同时具有空间和时间变化性的现象至关重要。此外，各模型处理数据的能力也会发挥作用。ConvLSTM 能够同时处理时间和空间维度的数据，从而更细致地理解不同区域的天气状况如何随时间影响事故率。此外，时空集成 ConvLSTM 的优异表现表明，集成技术通过结合多个模型的预测结果来提高准确性，在处理交通等领域涉及的复杂且含噪数据集时尤为有效。

表2：模型性能评估

模型	聚类0		簇1		聚类2		所有区域	
	均方根误差	均方误差	均方根误差	均方误差	均方根误差	均方误差	均方根误差	均方误差
LR	0.321	0.103	0.146	0.021	0.184	0.034	0.852	0.7259
自回归积分滑动平均模型	0.288	0.082	0.091	0.008	0.151	0.023	0.543	0.2948
ConvLSTM	0.253	0.064	0.073	0.005	0.084	0.007	0.331	0.1096
集成 ConvLSTM	–	–	–	–	–	–	0.024	0.0006

表2. 对四种预测模型——LR、ARIMA、ConvLSTM 和时空集成 ConvLSTM——在不同簇中的均方误差（MSE）和均方根误差（RMSE）进行了比较分析。每个簇代表 EPDO 的不同特征，EPDO 用于衡量事故的严重程度和发生频率。

聚类0表示逐渐增加的低等效财产损失事故（EPDOs）。在此，线性回归（LR）、自回归积分滑动平均模型（ARIMA）和ConvLSTM的均方误差（MSE）与均方根误差（RMSE）依次降低，表明随着模型复杂程度提高，预测准确性也在提升。从LR到ARIMA，再到ConvLSTM的改进说明，该聚类中EPDO严重程度随时间逐渐增加的趋势，通过能够处理具有趋势和季节性的时间序列数据的算法可以得到更好的建模。然而，聚类1表示具有波动性的高EPDOs。该聚类表现出

所有模型中最低的均方误差（MSE）和均方根误差（RMSE），鉴于其波动性，这似乎有些违反直觉。然而，这可能表明模型，尤其是ConvLSTM，能够有效捕捉EPDO的快速波动。较低的误差指标表明，ConvLSTM等复杂模型尤其擅长处理该聚类中的高度变异性。另一方面，聚类2表示稳定的低EPDOs。尽管EPDO较为稳定，但其误差（MSE和RMSE）高于聚类1，而在ConvLSTM中低于聚类0。这可能是因为，尽管数据的稳定性使其更易于预测，但绝对误差仍然较低且可察觉，反映出模型持续存在低估或高估的情况。

对所有区域合并数据集在各模型之间进行了比较。在汇总所有簇时，值得注意的是，ConvLSTM和时空集成 ConvLSTM的表现显著优于较简单的模型。集成方法很可能发挥了各模型的优势并弥补了其不足，从而提高了整体预测精度。模型复杂度与适应性的提升（从线性回归到集成 ConvLSTM）通常会带来更好的性能。ConvLSTM同时整合卷积层与LSTM层，能够高效处理时空数据，这对于预测等效财产损失事故至关重要，因为后者既受空间因素（例如道路状况和交通密度）影响，也受时间因素（例如季节变化和一天中的时段）影响。簇1的波动性可能通过提供多样化情景供模型学习，从而有助于模型训练，这或许可以解释该簇的误差出人意料地低于更为稳定的簇2。相比之下，簇2的稳定性虽然在理论上更易预测，却可能导致误差降低方面的自满，从而使误差指标略高于簇1。时空集成 ConvLSTM在“所有区域”中的优异表现表明，组合多个模型有助于捕捉数据中更广泛的模式与异常，从而提高预测精度。这在处理各区域异构数据时尤为有益。

5 结论

关于使用空间集成 ConvLSTM 框架预测天气相关事故风险，可以得出若干结论与建议。空间集成 ConvLSTM 框架在准确性方面确实优于线性回归、自回归积分滑动平均模型以及标准 ConvLSTM模型等传统预测模型。这一点体现在所有区域的均方误差和均方根误差值更低，尤其是在汇总不同事故风险区域的数据时。该集成方法有效结合了多个 ConvLSTM 模型的优势，通过对数据中空间和时间变化的稳健处理提高了预测准确性。

所提出的模型在不同事故风险区域的表现存在明显差异。在风险较高且波动较大的区域（簇1），模型的均方误差和均方根误差最低，这表明它能够有效应对并准确预测交通事故风险高度变化的情形。相较之下，在风险较低且较为稳定的区域（簇2），模型虽仍优于较简单的模型，但误差略高于高风险区域，这可能是因为在本身风险较低的环境中捕捉细微变化更具挑战性。

该框架能够在空间上使预测结果与实际交通事故地点相匹配，尤其是在高风险、高波动区域表现优异，这表明其具有合理性。模型整合了空间数据，能够有效地根据不同的地理和环境因素绘制并预测交通事故发生的位置，从而证实了它在实际应用中的实用性和准确性。

尽管模型在高风险区域的表现值得肯定，但仍建议针对低风险区域开展更多研究并调整模型，以完善预测结果并尽量减少误差。这可能包括整合更细粒度的数据点，或探索专门针对稳定性而非波动性进行优化的不同集成配置。此外，为了最大限度地发挥空间集成 ConvLSTM 框架的实际效益，将该模型与实时交通监测系统集成，可提供动态、及时的预测结果，直接用于交通管理和交通事故预防。最后，开发决策支持工具，利用模型输出为城市规划人员和公共安全官员提供可操作的见解，可显著增强模型预测能力的影响力。

致谢

本文部分基于美国交通部助理部长研究与技术办公室（USDOT/OST-R）大学交通运输中心计划资助的研究项目所收集的信息撰写（Grant #69A3551747127）。

数据可用性声明

本研究期间生成和分析的数据集可在提出合理请求后向通讯作者获取。此外，本研究使用了 Ogungbire & Pulugurtha（2025）的原始数据和伪代码，全州范围内天气相关交通事故的时空风险制图：一种机器学习方法，发表于*Machine Learning with Applications*（DOI：10.1016/j.mlwa.2025.100642）。获取这些材料须遵循原作者和出版商的相关政策。

参考文献

[1] 联邦公路管理局 (FHWA)：使用 21 世纪技术开展 21 世纪运营：天气事件如何影响道路，https://ops.fhwa.dot.gov/weather/q1 roadimpact.htm。访问日期：4 月 28 日

[2] Ran,B., Jin, P.J., Boyce, D., Qiu, T.Z.,Cheng, Y.: 未来交通研究展望：智能交通系统技术对下一代交通建模的影响。Journal of Intelligent Transportation Systems 16(4), 226–242 (2012)

[3]Quddus, M.: 使用……对区域范围内的计数结果进行建模。《事故分析与预防》(2008)[4] Aguero-Valverde, J., Jovanis, P.P.: 宾夕法尼亚州致命事故和伤害事故的空间分析。《事故分析与预防》**38**(3), 618–625 (2006)[5]Ogungbire, A., Pulugurtha, S.S.: 全州范围内的天气相关交通事故时空风险制图：一种机器学习方法。Machine Learning with Applications **20**, 100642 (2025)[6] Plug, C., Xia, J.C., Caulfield, C.: 事故分析的时空可视化技术。《事故分析与预防》**43**(6), 1937–1946 (2011)[7] Ogungbire, A.R.: 天气相关事故预测的新型机器学习技术。博士学位论文, 北卡罗来纳大学夏洛特分校 (2024)[8]Bao, J., Liu, P., Yu, H., Xu, C.: 将基于Twitter的人类活动信息纳入城市地区事故的空间分析。《事故分析与预防》**106**, 358–369 (2017)[9] Wu, P., Chen, T., Wong, Y.D., Meng, X., Wang, X., Liu, W.: 探索城市道路网络事故风险热点的关键时空特征：一种机器学习方法。《交通研究A辑：政策与实践》**173**, 103717 (2023)[10] Roland, J., Way, P.D., Firat, C., Doan, T.-N., Sartipi, M.: 田纳西州查塔努加市车辆事故发生的建模与预测。《事故分析与预防》**149**, 105860 (2021)[11]Bao, J., Liu, P., Yu, H., Xu, C.: 将基于Twitter的人类活动信息纳入城市地区事故的空间分析。《事故分析与预防》**106**, 358–369 (2017)[12] Gonzalez, M.C., Hidalgo, C.A., Barabasi, A.-L.: 理解个体人类移动模式。《自然》**453**(7196), 779–782 (2008)[13] Hasan, S., Schneider, C.M., Ukkusuri, S.V., Gonz´alez, M.C.: 城市人类移动的时空模式。《统计物理学杂志》**151**(1), 304–318 (2013)[14]Zhao, J., Liu, P., Li, Z.: 利用浮动车轨迹数据和图卷积网络探索出行模式对空间聚合事故的影响。《事故分析与预防》**194**, 107340 (2024)[15] Duddu, V.R., Pulugurtha, S.S.: 利用整合的地理空间土地利用数据和路网特征对路段级事故频率进行建模。Journal of

[16] Pulugurtha, S.S., Duddu, V.R., Kotagiri, Y.：基于土地利用特征的交通分析区级事故估算模型。《事故分析与预防》**50**,678–687 (2013)[17] Kalambay, P., Pulugurtha, S.S.：通过整合共享单车系统及其他替代指标，开展面向城市且兼顾包容性的自行车与机动车事故频率建模。《交通研究跨学科展望》**16**, 100714(2022) [18] Pulugurtha, S.S., Mahanthi, S.S.B.：通过交通仿真评估高速公路事故造成的时空效应。交通政策案例研究**4**(2),122–132 (2016)[19] Najaf, P., Duddu, V.R., Pulugurtha, S.S.：与基于聚类的模型和一般负二项回归模型相比，城市主干道混合路段级事故频率模型的可预测性与可解释性。国际伤害控制与安全促进杂志 **25**(1),3–13 (2018)[20] Khan, M.A., Etminani-Ghasrodashti, R., Kermanshachi, S., Rosenberger, J.M., Pan, Q., Foss, A.：共享出行服务能否减少交通事故？时间序列分析。交通伤害预防 **23**(6), 333–338 (2022)[21] Feng, M., Wang, X., Quddus, M.：构建多元时间序列模型，考察警察执法、交通违法与交通事故之间的相互关系。事故研究分析方法 **28**, 100139 (2020)[22] Iranitalab, A., Khattak, A.：比较四种用于事故严重程度预测的统计与机器学习方法。《事故分析与预防》**108**, 27–36(2017)[23] Ogungbire, A., Kalambay, P., Gajera, H., Pulugurtha, S.S.：用于天气相关事故严重程度预测的深度学习、机器学习或统计模型。技术报告 2320，23-32，米内塔交通研究所，圣何塞′，加利福尼亚州（2023年12月）。 https://doi.org/10.31979/mti.2023.2320 。由美国交通部资助。 https://rosap.ntl.bts.gov/view/dot/73172[24] Pulugurtha, S.S., Krishnakumar, V.K., Nambisan, S.S.：识别并排列行人事故高发区的新方法：实例说明。《事故分析与预防》**39**(4), 800–811 (2007)[25] Ogungbire, A., Kalambay, P., Pulugurtha, S.S.：探究山地地形对天气相关事故的影响。IATSS Research**48**(2), 136–146 (2024)[26] Loo, B.P., Fan, Z., Lian, T., Zhang, F.：使用计算机视觉和机器

学习识别公交安全风险因素。《事故分析与预防》**185**,107017 (2023)[27] Valcamonico, D., Baraldi, P., Amigoni, F., Zio, E.：一种基于自然语言处理和机器学习、从报告中分类道路交通事故严重程度的框架。《英国机械工程师学会会刊 O辑：风险与可靠性期刊》**238**(5), 957–971 (2024)[28] Bibi, R., Saeed, Y., Zeb, A., Ghazal, T.M., Rahman, T., Said, R.A., Abbas, S., Ahmad, M., Khan, M.A.：基于边缘人工智能，利用深度学习自动检测并分类车载自组网中的道路异常。《计算智能与神经科学》**2021**(1),6262194 (2021)[29] Formosa, N., Quddus, M., Ison, S., Abdel-Aty, M., Yuan, J.：利用深度学习预测实时交通冲突。《事故分析与预防》**136**,105429(2020)[30] Huang, X., He, P., Rangarajan, A., Ranka, S.：智能交叉路口：用于交通视频实时近事故检测的双流卷积网络。《ACM空间算法与系统汇刊》（TSAS）**6**(2), 1–28 (2020)[31] Zhang, S.：利用深度学习预测行人闯红灯行为。电子学位论文，中佛罗里达大学，奥兰多，佛罗里达州（2020）。https://stars.library.ucf.edu/etd2020/160[32] Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K., Woo, W.-c.：卷积长短期记忆网络：一种用于降水临近预报的机器学习方法。《神经信息处理系统进展》**28** (2015)[33]Vickrey, W.S.：拥堵理论与交通投资。《美国经济评论》**59**(2), 251–260 (1969)[34] Downs, A.：《困于交通：应对高峰时段交通拥堵》。布鲁金斯学会出版社，华盛顿哥伦比亚特区（2000）[35] Bergel-Hayat, R., Debbarh, M., Antoniou, C., Yannis, G.：阐释道路交通事故风险：天气影响。《事故分析与预防》**60**, 456–465 (2013)[36] Jackson, T.L., Sharif, H.O.：降雨对交通安全的影响：得克萨斯州与降雨相关的致命交通事故。《地理信息学、自然灾害与风险》**7**(2), 843–860 (2016)[37] Smiley, A., Rudin-Brown, C.：驾驶员会适应——对此要有所准备！《事故分析与预防》**135**, 105370 (2020)[38] Kilpel¨ainen, M., Summala, H.：天气和天气预报对驾驶员行为的影响。《交通研究F辑：交通心理学与行为》

10(4), 288–299（2007）

[39] Rabbani, M.B.A., Musarat, M.A., Alaloul, W.S., Rabbani, M.S., Maqsoom, A., Ayub, S., Bukhari, H., Altaf, M.：基于时间序列模型的季节性自回归积分滑动平均（季节性自回归积分滑动平均）与指数平滑（指数平滑）在道路交通事故预测中的比较。《阿拉伯科学与工程杂志》**46**(11),11113–11138 (2021)[40] Hassouna, F. M., Al-Sahili, K.：道路交通事故时间序列预测模型的实用最小样本量。《土木工程进展》**2020**(1), 6672612(2020)[41] Pei, X., Wong, S., Sze, N.-N.：一种用于交通事故预测模型的联合概率方法。《事故分析与预防》**43**(3), 1160–1166 (2011)[42] Cai, B., Di, Q.：近期交通事故预测的不同预测模型比较。《应用科学》**13**(2), 759 (2023)[43] Ivan, J.N.：在交通事故率分析与预测中纳入交通流量的新方法。《交通研究记录》**1897**(1), 134–141 (2004)[44]Guevara, F., Washington, S.P., Oh, J.：规划层面的事故预测：应用于亚利桑那州图森的同步负二项交通事故模型。《交通研究记录》**1897**(1), 191–199(2004)[45] Huang, C., Zhang, C., Dai, P., Bo, L.：用于交通事故预测的深度动态融合网络。载于：第28届ACM信息与知识管理国际会议论文集，第2673–2681页（2019）[46] Mathew, S., Pulugurtha, S.S.：天气事件对出行时间可靠性和交通事故发生的影响。技术报告，报告编号22-41，项目2035，米内塔交通研究所（MTI），圣何塞，加利福尼亚州（2022年11月）。https://doi.org/10.31979/mti.2022.2035 。https://rosap.ntl.bts.gov/view/dot/65508[47] 联邦公路管理局（FHWA）：北卡罗来纳州数据文件。访问日期：2022-05-23（2022）。https://www.hsisinfo.org/