

第1章

犯罪时空预测方法的发展历程

预测(forecast),作为一种认知行为,其本质在于依据当前可获取的信息、数据、知识积累或既有模式,对未来可能发生的事件、状态演变、趋势走向或最终结果进行科学合理的估计与推断。这种实践可追溯至远古时期,当人类对自然界与社会运行机制的理解尚处于蒙昧阶段时,便已尝试借助占卜等手段,探索未来的奥秘,并依据这些预测性结论指导生产实践活动。预测活动的核心价值,在于为决策者提供一个分析框架,用以评估特定事件发生的可能性以及不同潜在结果所蕴含的不确定性。这一过程不仅增强了决策的合理性与前瞻性,而且为决策者针对所述事件及其多种可能后果制定应对策略提供了不可或缺的参考依据。因此,预测不仅是连接已知与未知的桥梁,更是提升决策质量、降低决策风险的重要工具。

犯罪(crime),通常被界定为违反法律法规或未做出符合法律要求的行为,在量刑定罪中将受到法律的制裁和惩处,所以,犯罪行为(criminal behavior)是一种违反刑法条文的行为^[1]。尽管世界各国刑法体系在犯罪类型的具体划分上展现多样性,但对于普遍存在的犯罪活动与行为模式,国际社会往往存在着一些共识。此共识基于对各类型犯罪行为本质特征的深入理解与广泛认同,超越了单一法律体系的界限。因此,在探讨这些共通性较高的犯罪现象时,尽管法律框架与术语表述各异,仍可寻得跨文化的认知一致性,这构成了国际刑法交流与比较研究的重要基础。例如,入室盗窃(burglary),指的是未经允许非法侵入他人住宅或建筑物,意图实施窃取他人财物或其他犯罪行为的情形。这一犯罪类型,尽管在不同国家的刑法中可能有着不同的具体定义、构成要件及刑罚幅度,但其核心要素,即“非法侵入”与犯罪意图的结合,却是国际普遍认可且严厉打击的。

正是由于上述“普遍存在的犯罪活动与行为模式”往往展现出显著的共性特征,人们开始认识到,通过深入探究这些特征背后的重复性规律,有可能实现对犯罪活动的预测。实际上,诸多经典的犯罪学理论,诸如日常活动理论(routine activity theory)与犯罪模式理论(crime pattern theory)等,均蕴含着对犯罪活动进行预测的意图与尝试。这些理论不仅深化了我们对犯罪现象的理解,也为犯罪预防与打击策略的制定提供了重要的理论依据。

在探讨特定类型犯罪活动的共性特征时,时间分布特征与空间分布特征作为两大核心维度,频繁地成为学术研究的焦点。通过对大量犯罪案件统计数据的深入剖析,学者们早期便揭示了一系列显著的犯罪活动在时间维度与空间维度上的分布规律。值得注意的是,

这些时空分布规律并非在所有观测尺度上都稳定存在,也并不能普遍适用于所有类型的犯罪活动。然而,尽管如此,它们对于预测未来犯罪活动的时空分布趋势,以及为相关决策的制定提供辅助支撑,仍然具有不可忽视的重要意义。

基于广泛收集的不同时间、不同地域、不同类型的犯罪案件统计数据,国内外众多学者深入探索了犯罪时空预测的方法论体系。在这一研究领域中,犯罪时序预测可以视为犯罪时空预测的一个重要而特殊的分支(或者说一种特例)。具体而言,犯罪时序预测在分析与预测的实践过程中,专注于特定空间区域内犯罪案件的时间序列特征,而暂不涉及这些案件的空间分布属性。其预测目标聚焦于该空间范围内犯罪数量或犯罪率(即犯罪数量与人口数量的比值)随时间推移所展现的变化趋势。然而,值得注意的是,从历史发展脉络来看,犯罪时序预测作为犯罪预测研究的一个早期分支,其出现时间早于更具综合性的犯罪时空预测研究。鉴于此,本章将首先回顾犯罪时序预测的发展历程,进而延伸到犯罪时空预测的更广泛背景与演进轨迹。在此基础上,将进一步阐述经典犯罪学理论如何为时空预测提供理论支撑与框架指导。最后,聚焦于当前研究的前沿动态,详细阐述基于深度学习的犯罪时空预测原理,这一技术路径正逐渐成为该领域的主流方法。

1.1 犯罪时序预测

犯罪时序预测是指针对特定地理区域内,不同时间点上的犯罪发生率或犯罪事件数量所构成的时间序列数据进行预测分析。研究发现,犯罪时间序列存在显著的时间自相关效应^[2],具体表现为犯罪活动呈现出规律性的长期变化趋势、季节性波动等特征。犯罪时序变化的影响因素众多,其中,特定时段的警务活动是一个重要考虑因素。除此之外,实时变动的人员流动模式以及天气条件等外部因素,也有可能对犯罪的时序变化产生不可忽视的影响^[3-6]。

犯罪时序预测的方法论历程,大致经历了从传统统计学方法为主,逐步向机器学习乃至深度学习技术演进的过程。

鉴于犯罪现象中存在显著的时间自相关效应,部分学者利用历史犯罪数据来研究并预测犯罪活动的时序变化。在此背景下,差分自回归移动平均模型(auto-regressive integrated moving average 模型,简称 ARIMA 模型,亦称 B-J 模型,由 Box 和 Jenkins 于 20 世纪 70 年代共同创立)^[7]作为时间序列分析领域内广泛应用的统计模型之一,得到了大量的应用。ARIMA 模型通过融合自回归、差分运算以及移动平均这三种技术手段,对具有明显规律性的犯罪时间序列数据进行有效的建模与预测。该模型的应用有助于在按时间序列排列的随机数据中发掘潜在的统计规律,进而实现对犯罪趋势的预测分析^[8]。21 世纪以来,国内多位学者尝试运用 ARIMA 模型或其简化形式 ARMA(自回归移动平均,即不涉及差分项)模型,基于犯罪案件数据或警情数据,对短期的、相对平稳的犯罪时序进行了预测分析,普遍得到了较为准确的预测结果^[9-12]。大量统计资料与深入研究表明,犯罪时间序列数据中普遍蕴含着周期性的组成要素。具体而言,若以年度为观测周期,可明显辨识出季节性周期变动的特征。例如,一般伤害类犯罪往往在夏季呈现出高发态势,随后于秋季有所回落,至冬季则降至年度最低点,而进入春季后又开始逐步攀升。为有效捕捉并提取此类周期性变化的时序特征,部分学者创新性地引入了季节性差分自回归移动平均

(seasonal auto-regressive integrated moving average, SARIMA)模型进行犯罪时序预测研究。SARIMA 模型作为 ARIMA 模型的扩展与改进版本,不仅继承了原有模型的优势,还融入了对季节性或周期性因素的考虑,从而能够更为全面且精准地刻画时间序列数据的变化规律。例如,以 2005—2013 年我国某北方大型城市的一般伤害、抢夺及抢劫三类犯罪案件数量数据为样本,研究人员应用 SARIMA 模型对这三类犯罪的趋势进行了预测分析,结果显示,该模型在预测一般伤害犯罪的趋势方面展现出了较高的准确性,然而,对于抢夺和抢劫犯罪的预测,其误差相对较大^[13]。

在涉及更长周期及更小时间尺度的预测情境中,犯罪率随时间推移所展现的波动性更为显著。在此背景下,以 ARIMA 模型为代表的传统时间序列预测方法,其预测精度面临极大挑战,显现出局限性。鉴于此,部分学者转而探索机器学习(machine learning)方法的应用,旨在实现对犯罪时序变化更为精确的预测。在此探索历程中,诸如逻辑回归模型、梯度提升模型、支持向量机以及 BP 神经网络模型等一系列机器学习经典算法,被广泛采纳并应用于犯罪时序预测的研究领域,相关文献[14]~文献[18]对此进行了详尽阐述,并展示了这些方法相较于传统方法的优越性。例如,有研究团队通过引入基于模糊信息粒化技术的支持向量机模型,针对侵财类案件的时序数据进行了深入分析与预测,实验结果表明,该方法所取得的预测效果明显优于传统的 ARIMA 模型^[18],进一步验证了机器学习模型在处理复杂犯罪时序数据方面的潜力与价值。

近年来,深度学习(deep learning)技术以其迅猛的迭代速度与发展态势,在数据分析领域展现出了独特的优势,尤其擅长于挖掘大规模数据集的内在关联并提取高级特征。深度学习方法依托于庞大神经元网络中复杂的连接架构与高效的计算机制,能够敏锐地捕捉时间序列数据中的周期性、趋势性以及不规则性联系,表现出强大的适应性和灵活性。鉴于此种技术优势,部分学者已着手探索将深度学习应用于犯罪时序预测的可能性,以期获得更为精确和可靠的预测结果。例如,来自国内不同研究机构的科研团队,分别基于不同城市、不同时间段以及不同类型的犯罪数据集,均采用长短期记忆(long short-term memory, LSTM)网络模型进行犯罪时序预测分析,实验结果显示,LSTM 网络模型相较于传统机器学习模型(如随机森林、朴素贝叶斯、支持向量机等)在预测效能上展现出了显著的优势^[19,20]。值得一提的是,LSTM 作为一种典型的深度学习算法,特别擅长处理和预测时间序列数据中的长期依赖关系,这为犯罪时序预测的研究提供了新的视角和工具。随着犯罪时序预测研究领域的不断深化,研究人员对数据的关注点也将不再局限于单纯的犯罪案件统计数据。为了更全面地理解并预测犯罪活动的时序变化,影响犯罪的外部因素,诸如人员流动模式、自然环境条件等多种维度的信息,也将融入犯罪时序预测模型的构建过程,旨在对未来的犯罪时序分布进行更为精准的预测,从而提升预测结果的准确性和实用性。

1.2 犯罪时空预测

犯罪时序预测作为犯罪时空预测研究的早期分支,主要聚焦于特定区域内犯罪活动随时间变化的趋势分析,通过对历史犯罪数据的时间序列建模,预测未来某一时间点的犯罪数量或犯罪率。随着研究领域的不断深化,研究人员逐渐意识到,犯罪行为并非仅受时间因素所驱动,也与其发生的空间分布特征紧密相关,构成了一个复杂的交互系统。基于此,

犯罪时序预测的研究范畴已逐步扩展,演变为更为综合性的犯罪时空预测研究。这一演进不仅代表了时序预测的自然延续与深化,而且构建了一种全新的预测模式,即同步考虑时间与空间两个维度的关联性。犯罪时空预测不仅延续了对时间维度的细致考察,更将预测视野拓展至二维空间层面,旨在实现关于犯罪数量或犯罪率在地理空间上的分布预测。这种拓展具有重要的学术与实践意义,有助于揭示犯罪案件的时空邻近性重复现象,即那些在时间上相近、空间上相邻的犯罪事件之间普遍存在的、不可忽视的关联性。进一步地,犯罪时空预测还可以揭示犯罪风险在特定的时空范围内显著的扩散与传播特征,从而为犯罪预防与控制策略的制定提供更为精准的科学依据^[21,22]。这意味着,当附近环境因素发生变化时,仅依赖时序数据对犯罪活动进行预测可能无法及时捕捉到这些变化带来的影响,从而限制了预测的准确性和前瞻性^[23]。相比之下,犯罪时空预测不仅结合了犯罪的时间序列特征,还综合了空间因素及其他可能影响犯罪的相关数据,如社会经济状况、环境条件等,能够更精准地预测特定时空范围内的犯罪趋势。这种方法克服了传统时序预测在波动性捕捉上的局限性,并且在应用层面上,时空预测可以涵盖更大范围的区域、更加细化的空间单元,从而为不同地域的犯罪预防和治理措施提供科学依据^[24],这种更全面的预测模型有助于提高警务决策支持的效能,更好地应对现实中的犯罪防控需求。

近年来,国内外关于犯罪时空预测的研究呈现增长趋势,涉及的预测方法也层出不穷,早期的研究工作主要是基于统计学方法或传统的机器学习方法开展。其中,犯罪时空热点分析模型这类诊断性方法也因其具有对犯罪时空分布规律的分析和总结能力,而被应用于时空预测中^[25]。自激点振荡(self-exciting point process, SEPP)模型在犯罪时空预测领域的应用也见于国外学者的研究中,并已经通过美国芝加哥与洛杉矶犯罪数据的验证^[26,27]。国外研究者还探索了广义线性模型(generalized linear model, GLM)与时空指示函数的融合应用,通过模拟数据集以及源自美国某大型城市的真实犯罪数据,对这一方法在犯罪时空预测中的应用进行了验证^[28]。可见,美国诸多城市(如芝加哥、洛杉矶、纽约等)所公开的犯罪数据源被频繁采用,作为验证基于机器学习算法的犯罪时空预测模型效能的基础数据集。国内学术界亦不乏尝试利用这些公开数据集进行同类研究的实例。例如,有学者运用基于规则网格的四面体细分(grid-enabled subdivision of tetrahedra, GeST)模型,针对美国纽约2011—2018年每季度发生的盗窃案件数量,开展了时空预测分析,其预测性能显著优于传统的ARIMA模型^[29]。另有学者将改进的诺克斯时空交互算法与基于时空网格优化的犯罪预测模型相结合,对2016年芝加哥地区四种高发类型犯罪进行了精准预测分析,该模型所展现的平均绝对误差值维持在较低水平,体现了其较高的预测精度^[30]。当然,国内学术界同样不乏利用脱密处理后的犯罪统计数据,在犯罪时空预测领域进行创新性研究的范例。具体而言,有研究团队采用了2006—2016年我国某一线城市各行政区域年度盗窃类犯罪的统计数据,构建了一个基于转移概率矩阵自学习的犯罪分布预测模型。该研究将整个研究区域按照行政区域划分为若干规则的子区域,进而运用所建模型对该市盗窃案件的分布情况进行了预测,该模型预测结果的平均绝对误差值低至0.01^[31],这一结果充分体现了其在犯罪时空预测方面的准确性。

随着深度学习技术的持续进步与广泛应用,国内外的研究者们正逐步探索利用深度神经网络(deep neural networks, DNNs)来捕捉犯罪活动中蕴含的复杂时空特征。这类方法旨在构建更为精准的犯罪时空预测模型,以期实现对犯罪时空分布的有效预测^[32,33]。在

此类犯罪时空预测的研究中,研究人员普遍采用了两种主流的空间特征提取策略:一是基于空间规则网格的划分方法,二是依据空间拓扑结构的分析手段。基于上述两种方法,可以从不同时间尺度的窗口中有效地抽取犯罪空间特征,用于构建和优化犯罪时空预测模型。国内研究人员在基于深度学习的犯罪时空预测模型的研究方面做了很多有效的尝试。例如,在采用“小时”作为时间尺度的研究中,研究人员依托时空残差网络(spatial-temporal residual networks)模型,利用了我国苏州经过脱敏处理的犯罪数据,创新性地提出了一种具备自适应空间分辨率识别能力的犯罪时空预测方法,实现了对犯罪时空分布相对较高精度的预测^[34]。而在以“日”为时间尺度的研究范畴内,一种尤为典型的技术路径是将长期记忆网络与时空图卷积网络(spatial-temporal graph convolutional networks, STGCN)相结合,用于犯罪时空预测。我国学者利用美国芝加哥 77 个社区的数据集,对这一融合方法进行了验证,研究结果显示,该方法在犯罪时空分布预测上的性能显著优于岭回归、随机森林等传统机器学习模型^[35]。近两年,部分学者在犯罪时空预测模型的构建上实现了进一步深化、创新。例如,我国学者提出了一种顾及道路权重的图卷积犯罪时空预测模型(road-weighted spatio-temporal graph convolutional network, RW-STGCN),其创新之处在于引入了道路通达度和距离衰减因子,这两个因素的考虑使得模型能够在微观尺度下对路网拓扑结构进行更为精细的刻画,从而实现对犯罪时空分布的精细化预测^[36]。此外,我国研究人员还提出了一种结合空间通道注意力机制与多图卷积网络的犯罪时空预测方法,通过空间通道注意力机制捕捉空间相似性特征,同时利用多图卷积网络深化对空间结构的理解,并结合基于多头时空注意力机制的 Transformer 预测网络,实现了不同尺度上的较高的预测准确性和稳定性,为犯罪时空预测提供了新的研究视角和技术手段^[37]。

1.3 犯罪学理论对时空预测的支撑

经典犯罪学理论常被援引以阐释犯罪数量(或犯罪率)在时间与空间维度上所展现的统计规律性。鉴于此,这些理论为基于上述规律而构建的犯罪时空预测模型提供了不可或缺的理论支撑。

1.3.1 日常活动理论

日常活动理论(routine activity theory)^[38]是由美国犯罪学家 Lawrence E. Cohen 与 Marcus Felson 于 1979 年共同发表的文章《社会变迁与犯罪率趋势:一种日常活动视角》“Social Change and Crime Rate Trends: A Routine Activity Approach”中首次提出的。该理论的核心假设构建于一个双重前提之上:犯罪行为的实现不仅受潜在犯罪者动机的驱动,也需满足特定的时空条件,即存在适宜的犯罪目标以及缺乏有效监控的环境。日常活动理论深刻洞察到,个体及群体在日常生活中的常规活动模式对犯罪行为的发生具有显著影响。此理论的提出,源于作者对 20 世纪 60 年代以来美国犯罪率攀升现象的深入研究。他们研究发现,这一时期的犯罪率增长与社会结构的深刻变迁以及民众日常活动模式的转变之间存在着紧密的关联。通过这一理论框架,他们为理解犯罪现象提供了新的视角,强调了社会动态与个人行为模式交互作用下对犯罪发生率的作用。根据日常活动理论的阐

释,犯罪行为的实现是三个基本要素相互作用的结果,缺一不可,它们共同构成了犯罪发生的必要条件,为犯罪预测提供了理论基础。具体而言,这三个要素包括:

(1) 具有犯罪动机的潜在犯罪人。潜在犯罪人,作为犯罪行为的直接执行者,其犯罪动机的形成与个人社会化过程紧密相关。仅当个体具备犯罪动机时,其方有可能成为潜在犯罪人,进而实施犯罪行为。

(2) 合适的犯罪目标。合适的犯罪目标,即犯罪行为的直接指向对象,其特性被 Cohen 和 Felson 精炼为 VIVA 原则:价值性(value)、惯性(inertia,即目标不常移动的特性)、可视性(visibility)和易接近性(accessibility)。这些特性共同决定了某一目标是否易成为犯罪活动的实施对象。

(3) 缺乏有效的监管。即便存在具有犯罪动机的潜在犯罪人以及合适的犯罪目标,如果现场有强有力的监管者存在,犯罪行为仍难以实现。有效的监管者包括但不限于警察、保安人员、邻居、熟人或监控设备等,他们的在场能够对潜在犯罪人产生一定程度的威慑效果,从而降低犯罪行为的发生概率。

日常活动理论强调犯罪的发生不仅依赖于潜在犯罪人的动机,还需要特定的时空条件^[39],即合适的犯罪目标和缺乏有效监管的情境。这种理论框架有助于理解犯罪行为的规律性和可预测性,从而为犯罪时空预测提供理论基础。

潜在犯罪目标在时间与空间上的分布呈现出一定的规律性,这一观点在日常活动理论中得到了深刻的阐述。该理论强调,犯罪行为倾向于选择那些在时空维度上既易于接近又具备高度吸引力的目标作为攻击对象。在时间维度上,犯罪活动的发生频率不仅受到季节性周期变化的深刻影响,还与节假日及大型活动等特殊时段紧密相连。这些时段内,犯罪目标在社会层面的暴露程度呈现显著差异,进而使得犯罪活动的数量在宏观层面与时间因素展现出明确的关联性。精准捕捉这些时序特征,对于提高犯罪时序预测的准确性至关重要。在空间维度上,不同区域和地点的犯罪目标暴露数量同样存在显著差异,以城市商业区域为例,这些区域在营业时段内因人流量庞大、贵重物品集中而频繁成为扒窃等犯罪活动的高风险地带。潜在犯罪目标在时间与空间上的分布规律,为构建犯罪时空预测模型奠定了坚实的理论基础。通过深入挖掘这些规律,并结合实际数据进行特征提取,预测模型能够更为精确地把握犯罪活动在时间与空间上的分布特征,从而实现高效、准确的时空预测。

监管者的日常活动,同样在时间与空间维度上展现出显著的规律性,这一观察在日常活动理论的框架下得到了进一步的阐释。该理论指出,监管力量的部署与行动往往受限于特定的时间与空间条件,其活动模式对犯罪活动的发生具有重要影响。在时间维度上,监管者的巡逻频次与强度常受工作日与休息日、昼夜更替以及特定勤务安排等因素的制约。这些时间因素不仅影响监管资源的分配,也间接形成了犯罪活动的潜在机会窗口,使得某些时段内犯罪风险相对增高或降低。在空间维度上,监管者的活动范围与重点监控区域同样呈现出明显的地域特征。例如,城市中心区域、治安复杂地段或历史高发犯罪区域,通常会吸引更多的监管注意力与资源投入。然而,这也可能导致监管力量的空间分布不均,为犯罪分子在监管薄弱区域寻找可乘之机提供了可能。监管者日常活动在时间与空间上的分布规律是日常活动理论支撑犯罪时空预测的又一重要方面。通过研究这些规律,结合实时动态的监管数据,可以构建精准度、自适应性更强的犯罪时空预测模型。

1.3.2 犯罪模式理论

犯罪模式理论(criminal pattern theory)^[40]是环境设计预防犯罪(crime prevention through environmental design,CPTED)理论的重要支撑之一。该理论借鉴了日常活动理论的一些理念,并在此基础上有所发展,主要关注潜在犯罪者的目标选择过程以及个人认知空间对其犯罪决策的影响。犯罪模式理论主张,犯罪决策及其起因是一个多维度的构造,深受个体特性、生活历程、周遭环境特性以及时间等多种因素的交互影响。该理论强调,当环境特征与潜在犯罪者的内在动机相互契合,且与某种预设的“犯罪模板”(crime template)相匹配时,犯罪行为的发生概率将显著上升。犯罪模板是指潜在犯罪者在特定环境中形成的思维定式,这种定式影响他们的犯罪决策。

在这一理论框架中,认知空间扮演着至关重要的角色,它从根本上界定了潜在犯罪者实施犯罪行为的可能性范畴。具体而言,犯罪模式理论阐释了个体如何通过其日常活动模式,界定并熟悉主要的行为空间区域,这些区域不仅包含了物理环境的特征,也蕴含了丰富的社会环境信息。认知空间,作为这一理论的核心概念,被定义为个体基于经验积累而形成的、对特定场所深刻理解的集合体。这些场所,因其与个体生活的紧密联系,成为犯罪决策过程中不可或缺的因素。犯罪模式理论对空间环境中促成犯罪的关键因素进行了精炼的概括,将其区分为犯罪发生因子与犯罪吸引因子两大核心要素。

(1) 犯罪发生因子,这一概念界定为那些能够吸引无特定犯罪意图的公众以及具有犯罪倾向的潜在犯罪者聚集的活动节点空间。此类空间,如公交车站等,因人员的高度集中而自然形成了实施犯罪行为的潜在机会结构,为犯罪活动的发生提供了便利条件。

(2) 犯罪吸引因子,则是指那些因频繁发生犯罪行为而广为人知的节点空间。这些地点,由于历史上累积的犯罪事件,形成了对潜在犯罪者强烈的吸引力,主要归因于其中蕴含的丰富犯罪机会。此类空间的存在,不仅加剧了当地的犯罪风险,也对公众安全感构成了严重威胁。

犯罪模式理论认为,潜在犯罪者在其认知空间内通过日常活动选择犯罪机会。这种选择过程依赖于他们对周围环境的熟悉程度和认知。犯罪模式理论提出的犯罪模板解释了犯罪行为在特定空间环境中的发生机制。以下是犯罪模板的几个关键要素。

- (1) 接触能力:空间环境是否方便潜在犯罪者靠近并实施犯罪。
- (2) 隐蔽能力:空间环境是否方便潜在犯罪者隐匿踪迹。
- (3) 通行能力:空间环境是否方便潜在犯罪者接近犯罪目标以及实施犯罪后逃逸。
- (4) 自然监视:空间环境中是否缺少自然监视及社会监视,或者空间是否缺乏管理。

犯罪模式理论为犯罪时空预测领域提供了坚实的理论支撑。特定类型的空间环境,以其便于接触性、隐蔽性及通信便利性,同时缺乏自然监视的特性,在特定时间维度内,展现出对犯罪活动尤为显著的促生或吸引效应,相较于其他时空节点,这些环境对犯罪行为的诱发具有更为强烈的影响。因此,对这些空间环境特征进行深入的数据信息提取与分析,尤其是运用诸如机器学习等先进技术手段,能够显著提升犯罪时空分布预测的准确性。此过程不仅涉及对空间环境多维度特征的精确刻画,还强调了在时间动态变化中捕捉犯罪活动规律的重要性,从而为犯罪预防与控制策略的制定提供更为科学、精准的依据。

此外,犯罪模式理论还深入探讨了犯罪出行与空间决策之间的内在联系,为犯罪时空

预测提供了又一重要的理论基石。犯罪者在实施犯罪行为时,往往倾向于选择那些他们熟悉且感到舒适的环境,以此来减轻因未知环境所带来的行为负担和心理压力。这一选择偏好导致犯罪活动在其日常活动区域内呈现出一定的空间规律性。

具体而言,这一规律性体现在以下几个方面。

(1) 距离衰减效应:犯罪发生的概率与犯罪者居住地之间的距离呈现出显著的负相关关系,犯罪者更倾向于在离其居住地较近但又不会过于接近的地方实施犯罪,以避免被邻居识别或增加被警方排查的风险。

(2) 成本最小化原则:在实施犯罪行为之前,犯罪者会精心权衡犯罪收益与行为成本之间的关系,尽管远距离出行会增加行为成本,但若预期收益足够高,犯罪者仍可能选择远距离作案。

基于上述犯罪活动的空间规律性分析,为探究案件数据的时空分布特征增添了新的分析维度,进而为构建犯罪时空预测模型提供了坚实的理论基础与支撑。

1.3.3 NAE 与 GA 理论

负面影响逃逸(negative affect escape,NAE)模型^[41]提出,随着个体不适感(uncomfortableness)的累积,其攻击性行为倾向会随之增强,直至不适感超越某一临界阈值。在此阈值之后,个体避免因厌恶环境而引发的逃避动机将显著增强,进而对攻击行为产生抑制作用。该模型的核心论断在于,不适感及伴随的负面情绪是激发攻击性行为的重要因素;然而,当不适感升级至极端水平时,个体的行为倾向将转变为逃避,而非持续攻击。

NAE 模型植根于以下四个基本假设。

(1) 负面情绪与攻击动机之关联:该模型首先假定,个体负面情绪的累积与其攻击动机之间存在正向关系,即负面情绪强度的增加会相应地提升攻击动机的水平。

(2) 负面情绪与逃避动机之联系:其次,NAE 模型提出,逃避动机同样随负面情绪的增长而增强,表明负面情绪不仅是攻击行为的催化剂,也是逃避倾向的驱动力。

(3) 低强度负面情绪下的主导行为倾向:在负面情绪处于较低水平时,该模型预测,攻击性行为将成为个体的主导反应模式,凸显了在轻微不适状态下攻击性的相对优势。

(4) 逃避动机相对于攻击动机的优势斜率:最后,NAE 模型强调,在负面情绪增长的过程中,逃避动机的增长速率(即其与负面情绪关系的斜率)相较于攻击动机更为陡峭,意味着当负面情绪达到一定强度后,逃避成为更为强烈的行为倾向,从而可能抑制攻击行为的发生。

个体的行为模式会经历从攻击性向逃避性的转变。这一模型特性阐释了为何在特定环境条件下,犯罪行为呈现出一定的可预测性。具体而言,在环境刺激处于中等强度时,个体可能更易于展现出攻击性行为;然而,当环境条件恶化至引发极端不适感时,个体则更倾向于选择逃避策略,以规避进一步的负面影响。

一般情感攻击(general affective aggression,GAA)模型^[42]是一个综合性的分析框架,它跨越多个分析层次,旨在深入剖析攻击行为的产生与维持机制。该模型强调,攻击行为并非单一因素所致,而是生理、心理及社会环境因素相互交织、共同作用的结果。GAA 模型的核心在于其多层次的分析视角,它认为从生理基础到社会环境,各层次因素相互关联,共同促成了攻击行为的出现。此外,GAA 模型特别指出了社会与环境变量在攻击行为形

成中的关键作用。这些变量通过影响个体的攻击性认知、情感反应及生理唤醒状态,最终促使攻击行为的发生。这一过程可细分为以下几个阶段。

- (1) 环境刺激:如高温等外部环境条件。
- (2) 个体反应:个体对环境刺激所产生的情感反应及生理唤醒。
- (3) 认知评价:个体对自身情感反应及生理唤醒状态的认知评估。
- (4) 行为结果:在情感反应与认知评价的共同驱动下,个体最终表现出攻击行为或逃避行为。

NAE 与 GAA 两个理论模型,共同揭示了犯罪活动的可预测性,为犯罪时空预测奠定了坚实的理论基础。具体而言,它们在以下几个方面展现了显著的解释力。

环境刺激的作用机制:NAE 与 GAA 理论均着重强调了环境因素对个体行为的深远影响。这些外部环境刺激,通过诱发个体的负面情绪以及伴随的生理反应,进而对其行为决策过程产生显著的塑造与引导作用。借助对环境变化的精细监测与科学分析手段,能够预见到,在特定的环境条件下,个体更倾向于展现出攻击性行为,抑或是采取逃避策略。因此,当某些具有规律性和时空重复性的环境条件出现时,对于那些包含攻击性行为的特定犯罪类型,例如故意伤害罪,其发生的概率在一定程度上是可以被预测和评估的。

情感与认知过程的核心地位探析:GAA 理论深度挖掘了情感反应与认知评价在个体行为决策机制中的核心角色。该理论通过精细解析个体面对特定环境刺激时所展现的情感响应及其内在的认知加工机制,为我们提供了一个更为精确的框架,用以预测个体的行为倾向性。举例来说,在环境条件适宜的情境下,个体可能更倾向于展现攻击性行为模式;相反,在遭遇极端高温或低温等不利环境条件时,逃避行为则可能成为更为普遍的选择。理论上,通过对那些可能诱发适宜或极端环境条件的时空节点的深入认知与分析,我们能够构建出更为精准的犯罪时空分布预测模型。

攻击与逃避动机的动态平衡探析:NAE 模型着重阐述了攻击动机与逃避动机间存在的复杂而精细的动态平衡关系。该模型指出,随着个体负面情绪的不断累积,其攻击动机在初期会呈现出增强的趋势。然而,当这种负面情绪累积至某一特定的临界阈值时,逃避动机将开始逐渐占据主导地位,形成动机转换的关键节点。这一动态平衡机制为我们提供了在特定情境下精确预测犯罪行为的重要理论支撑。以高温环境为例,在温度初升阶段,个体的攻击行为可能会因负面情绪的刺激而有所增加。然而,随着温度的持续攀升并超过某一阈值,逃避行为将逐渐取代攻击行为,成为个体的主导反应。这一现象揭示了环境条件对个体行为选择的深刻影响,并提示我们,在特定环境对应的特定空间内,犯罪活动的发生概率可能会随关键环境条件的变化而呈现出动态变化的特征。

1.4 基于深度学习的犯罪时空预测原理

犯罪时空预测的发展经历了从经典统计学方法向机器学习及深度学习技术的转型。在初期阶段,犯罪时空预测主要基于统计分析手段,例如 ARIMA、空间热点分析等方法,这些方法通过对历史犯罪数据的统计分析,揭示犯罪模式与趋势特征。然而,面对复杂多变的犯罪时空数据,传统统计方法呈现出其不可避免的局限性,特别是在捕获数据中深层次的非线性关系方面显得力不从心。随着机器学习技术的蓬勃兴起,犯罪时空预测领域迎来

了方法论上的革新。相较于传统方法,机器学习模型凭借其自动学习与特征提取的能力,显著提升了预测的精确度,诸如支持向量机、决策树、集成学习以及神经网络等算法开始被广泛应用于犯罪时空预测的研究与实践中。尽管如此,机器学习模型仍在一定程度上依赖于人工特征工程的设计,且在解析具有高度复杂时空结构的数据时,可能无法充分发掘隐藏于数据深处的有用信息。

深度学习技术的兴起,为犯罪活动的时空预测领域带来了显著的推进。该技术依托于多层神经网络架构,凭借其自动化的特征提取机制及强大的复杂非线性建模能力,得以有效处理并分析蕴含高度复杂性的时空数据集。深度学习模型的核心优势,在于其具备从原始数据中自主学习并提炼出有价值特征的能力,这一过程无须依赖人工特征工程的介入,从而极大地提升了模型在处理犯罪预测问题时的效能与准确性。因此,在犯罪时空预测的实践中,深度学习模型展现出了卓越的性能表现,为该领域的研究提供了强有力的技术支持。

卷积神经网络(convolutional neural network,CNN)是一种典型的深度学习算法,其设计初衷是针对计算机视觉任务,通过巧妙地利用卷积层对输入数据执行局部感受野分析,以有效抽取局部特征信息。在犯罪时空预测这一复杂应用中,CNN展现出处理空间数据(如犯罪空间散点图或犯罪空间热力图)的强大能力,可以实现对空间特征的深度挖掘。那么,对不同时间点(或时间段)特定空间区域内的犯罪数据执行多层次的卷积运算,逐步实现对犯罪时空分布的高级特征提取。相比于传统机器学习算法,CNN增强了模型对犯罪模式时空特性的捕捉能力,从而总体上提升了预测精度。

循环神经网络(recurrent neural network,RNN)特别适用于处理时间序列数据。RNN的独特架构设计使得信息能够在连续的时间步长之间进行有效传递,进而使模型具备捕捉时间序列中时间依赖性的能力。然而,传统的RNN在处理尤为漫长的时间序列时,可能会遭遇梯度消失或梯度爆炸的难题,这极大地制约了其对长时间依赖关系的准确建模。为了克服这一局限性,长短期记忆网络作为RNN的改良版应运而生。LSTM巧妙地引入了门控机制,这一创新设计有效地解决了传统RNN在处理长时间序列时遇到的问题。通过精确调控信息的遗忘与保留过程,LSTM能够深入捕捉到长时间序列中复杂的依赖关系。在犯罪时空预测的应用中,LSTM展现出了优越的性能,可以高效地处理犯罪时间序列数据,从中识别出长期的犯罪趋势以及周期性的变化规律,对于提升对犯罪时序预测精确度具有重要意义。

除CNN和LSTM外,图卷积网络(graph convolutional network,GCN)在处理犯罪时空数据方面同样具有独特优势。GCN作为一种专门用于处理图结构数据的深度学习模型,能够高效地分析诸如社会网络或地理网络等复杂图结构数据。在犯罪时空预测的应用场景中,GCN的优势在于其能够深入挖掘不同空间区域之间的内在联系和相互影响,通过精细地分析区域网络间犯罪活动的传播路径,精准地识别潜在的犯罪高风险区域以及犯罪活动的传播模式。

深度学习模型的优势显著,主要体现在其自动化的特征提取能力以及卓越的非线性建模性能上。这些特性使得深度学习能够从错综复杂的犯罪时空分布数据中,有效地提取高级特征,进而为构建精准的犯罪时空预测模型奠定基础。依据预测目标的不同,犯罪时空预测在监督学习的框架下可细分为回归与分类两大模式。具体而言,针对犯罪数量的预测