



非线性递推辨识理论在量刑数据分析中的应用

王芳¹, 张蓝天², 郭雷^{2*}

1. 山东大学数据科学研究院, 济南 250100

2. 中国科学院数学与系统科学研究院, 北京 100190

* 通信作者. E-mail: lguo@amss.ac.cn

收稿日期: 2022-08-18; 接受日期: 2022-08-28; 网络出版日期: 2022-09-29

国家自然科学基金 (批准号: 12288201) 资助项目

摘要 司法大数据已成为法律实证研究和智慧司法工程建设的重要基础, 相应地, 数据计算结果的可解释性与可靠性等基础性问题愈加重要. 为此, 我们对非线性递推辨识理论进行了相应创新, 并应用于量刑数据分析. 具体来讲, 依据相关法律建立了更加符合法逻辑的非线性随机量刑模型 (S-模型), 应用我们提出的非线性递推辨识算法和建立的关于有限数据样本下辨识精度的数学理论, 对近 20 万故意伤害罪判决数据进行了计算分析. 研究发现, 与传统线性模型及最小二乘算法相比, 基于我们的 S-模型和非线性递推辨识算法所给出的计算结果, 更符合量刑基本原则和具体规则, 可以更准确地反映量刑要素的影响及变化, 并具有更好的预测能力.

关键词 非线性模型, 递推辨识算法, 辨识精度保证, 量刑, 故意伤害罪, 司法判决数据

1 前言

量刑问题, 关乎刑罚公正, 是刑事正义的终极体现. 为实现“努力让人民群众在每一个司法案件中感受到公平正义”¹⁾, 国家持续推进量刑规范化改革, 规范刑罚裁量权, 促进量刑公正. 随着国家智慧法院建设工程的不断推进, 智能审判辅助系统在全国司法审判实践中广泛应用, 公众对于司法规范性和公正性的关注和期待不断上升, 相关研究也越来越关注定量分析与规范研究的结合, 量刑预测以及相关因素的因果关系分析成为研究热点. 这就对基于司法大数据的计算模型和计算方法的可解释性和可靠性等提出了更高要求.

目前, 国内外关于基于司法判决数据的量刑问题量化研究和应用主要有两种思路. 一是遵循经典的统计模型或实证方法, 二是基于机器学习和自然语言处理技术挖掘法律文本中的关键信息预测分析

1) 习近平在中央全面依法治国工作会议上发表重要讲话. 2020 年 11 月 17 日. http://www.gov.cn/xinwen/2020-11/17/content_5562085.htm.

引用格式: 王芳, 张蓝天, 郭雷. 非线性递推辨识理论在量刑数据分析中的应用. 中国科学: 信息科学, 2022, 52: 1837-1852, doi: 10.1360/SSI-2022-0325
Wang F, Zhang L T, Guo L. Applications of nonlinear recursive identification theory in sentencing data analyses (in Chinese). Sci Sin Inform, 2022, 52: 1837-1852, doi: 10.1360/SSI-2022-0325

法官决策. 目前,在我国法律实证研究领域第一种思路仍为主流. 其中,研究实际场景中量刑的规范性和客观性是关注焦点. 白建军^[1]以14万余交通肇事罪案件为样本对量刑进行确定性检验,发现通过限缩量刑情节的裁量幅度,控制样本离散性程度可以提高量刑的确定性,并在此基础上建立量刑的预测模型. 左卫民^[2]基于案件数据和访谈资料,对检察机关在认罪认罚案件中量刑建议的实践机制进行实证检验和理论反思. 同时,特定因素如何影响量刑也是研究热点. 魏建等^[3]对2014~2016年贪污罪和受贿罪一审判决书进行实证分析,运用最小二乘回归和机制分析方法研究了异地审理与腐败惩罚的关系. 唐应茂等^[4]基于西部某基层法院的随机抽样构造庭审直播实验组和对照组,通过实验方法研究庭审直播对公正审判的影响. 王芳^[5,6]分析故意伤害罪样本发现通过不同途径实现的民事赔偿对量刑的影响力存在明显差别,并基于故意伤害罪致人轻伤样本研究认罪认罚对量刑的实际影响.

国外特别是美国的实证研究学者较早地将机器学习方法应用于法官决策研究中,对法官经验和法律决策模式进行分析,构造和模拟出同人类决策类似的决策模型,应用于裁判结果预测等智能系统的研发^[7]. Kleinberg等^[8]通过决策树、随机森林、梯度提升算法等机器学习方法构建和训练计算模型,对比法官决策结果与算法预测结果之间的差异,进而探索差异形成的原因. Berk等^[9]通过机器学习算法对家庭暴力案件审讯前被告人是否可以保释的问题进行研究,并量化不同特征元素对预测精确度的贡献,预测再犯风险. Medvedeva等^[10]采用欧洲人权法院数据,研究如何使用自然语言处理技术挖掘法庭审判文本,进而通过机器学习方法实现对司法判决的自动预测. 我国近年来在这方面也开展了一些研究工作,如Lyu等^[11]提出了一种基于强化学习的犯罪元素提取网络,并使用多任务预测算法进行判决预测. Huang等^[12]将机器学习与逻辑推理相结合的“反绎学习”方法应用在盗窃案辅助量刑工作中. 尽管深度学习方法在量刑预测等方面受到广泛关注和应用,进一步的成果也值得期待,但目前结果的可解释性和算法可靠性保证等方面仍存在不足. 本文研究重点在于量刑特征要素作用大小的辨识问题,因此暂不考虑深度学习方法.

值得指出,对于法治场景,特别是涉及人身自由与财产等方面基本权利的数据分析及预测,其背后的数学模型的适用性与计算方法的可靠性至关重要. 尽管司法大数据分析在法律实证研究领域已取得了许多重要进展,但在数学模型的适用性和计算结果的可靠性方面仍鲜有深入研究. 首先,建立能够适应具体法治场景的数学模型,依赖于对法律关系的深入分析和对法律推理逻辑的准确把握,而目前常用的统计学中的多元线性回归模型等仍有明显局限,本文中讨论的量刑问题就是这方面的例子(详见本文2.2小节). 其次,经典的统计学计算方法,其理论依据主要基于大数定律和中心极限定理等概率统计中渐近性质的经典结果,往往需要先验性地假设数据满足良好的统计性质(如独立同分布等),并且在数据样本量有限的实际情况下,难以给出对计算结果可靠性的精准估计.

为克服传统线性模型的适用性局限并保证计算结果的可靠性,我们依据《刑法》和量刑规则,提出了新的非线性量刑模型;考虑到相关法律法规和刑事政策可能随时间动态变化,我们利用在相伴论文^[13]中提出的非线性递推计算方法,对故意伤害罪判决数据进行计算,实现了以下3个方面的创新.

第一,模型创新. 建立了更加符合法逻辑的,具有可解释性的非线性量刑模型(S-模型),体现了量刑所固有的非线性饱和特性. 详言之:(1)增加了基于犯罪构成要素对量刑起点和基准刑的考虑,更加符合量刑的法逻辑;提出了处理量刑起点与基准刑的不确定性所引起的非适定性问题的方法.(2)在此基础上,进一步引入非线性饱和函数,以体现实际量刑中对宣告刑的法定刑区间限制,即对于根据量刑情节调节计算后超过或低于相应法定刑区间的案件,其宣告刑应限定在法定刑区间内,但允许宣告刑因“减轻”情节而向下浮动. 这一对法定刑区间限制的建模考虑弥补了传统线性模型的相应不足.(3)缓刑与有期徒刑之间的关系是许多研究者关注的问题,我们通过对比实验讨论了缓刑因素在建模中的适当作用.

第二,理论保证.针对我们建立的新的非线性量刑模型,需要创造相应的能保证计算可靠性的新算法.作者在相伴论文^[13]中构建了两步骤随机拟牛顿(two-step quasi-Newton, TSQN)递推辨识算法,并建立了相应的算法收敛性理论.运用这一递推算法,可以从理论上给出根据司法数据所计算的未知参数估计值的可靠性保证,还可以观测估计值随时间的可能变化趋势.换言之,(1)算法具有全局收敛性理论保障,并且不需要数据满足传统的独立同分布等假设条件,更加适合司法判决这一类实际数据的基本性质.(2)鉴于全国刑事司法审判在空间上的一致性和时间的关联性,通过递推算法可以观察主要量刑影响因素的实际作用随时间的可能变化趋势.(3)从理论上给出在有限数据样本下参数估计的可靠性保证,准确界定量刑情节的实际作用大小.

第三,计算效果.利用故意伤害罪判决数据,对司法判决与量刑规则的符合程度进行了实际检验,使用的数据集包括2011年1月到2021年6月的故意伤害罪刑事一审判决.从检验效果来看,(1)根据我们建立的非线性模型和相应的新计算方法,给出的刑期预测的准确度明显高于线性回归模型,具有更好的预测能力;(2)基于非线性模型的计算结果更符合量刑基本原则和具体规则,可以更好地反映量刑情节的实际影响.这对于发现司法审判事实,推动司法公正具有重要意义.

2 量刑模型的建立

2.1 量刑的逻辑基础及过程

量刑,是法院根据犯罪行为及刑事责任的轻重,在定罪的基础上对被告人是否判处刑罚,判处何种刑罚,何种刑度以及是否立即执行的刑事审判活动^[14].量刑的结果承载着刑罚公正,在某种意义上是罪责刑相适应的刑罚基本原则的终极体现.现代刑罚观,一般既强调基于报应主义的一般公正,满足一般人的法感情;也蕴含基于人身危险性的差别处遇,满足对社会的防卫需求.我们可以将其理解为惩罚犯罪行为的确定性及预防再犯的不确定性的统一.注意到,上述两个方面的作用或功能并不是均分的.虽然在预防主义刑罚观的思想推动下,人身危险性要素逐渐在量刑中发挥越来越重要的作用,但无论人身危险性要素如何发挥作用,刑罚适用的轻重程度都必须以法定刑为标准,并且不能超出刑事责任范围.因此,在责任主义刑罚观为主的现代刑罚体系中,确定性或一致性仍占据主导地位.对于确定性因素相同或相近的案件给予相同或相近的刑罚处罚,是目前我国司法改革所强调的“同案同判”的主旨,它体现了以责任为基础的刑罚公正.但同时,有关“人”和政策的一些不确定性要素仍可以在量刑中发挥一定作用.对这些“不确定性”要素的考量,体现了更为广泛的法官自由裁量权.总之,量刑的模型化并不意味着机械化,更不意味着绝对的整齐划一.它应当是共性与个性的统一,一致性与多样性的统一.因此,一个好的量刑模型及计算方法,应该能够达到比较高的预测精度,但不可能也不应该达到100%的预测准确性.建立量刑模型的目的在于,借助“法律规范”和“司法共识”推动量刑的规范化,实现刑罚公正;同时,也为法律实证研究提供一个可计算、可依照的基本出发点.

就量刑的基本方法步骤,2009年之前最高人民法院颁布的《人民法院量刑指导意见(试行)》(简称《量刑指导意见》)要求在法定量刑幅度内划分若干刑格,在刑格中确认基准刑,然后确认宣告刑.自2010年修订后,《量刑指导意见》改变了刑格方式,而采用了“量刑起点-基准刑-宣告刑”的量刑模式.参考2010年以后的《量刑指导意见》,具体的量刑过程如下:在定性分析的基础上,结合定量分析,依次确定量刑起点.基准刑和宣告刑.量刑起点应根据基本犯罪构成事实在相应的法定刑幅度内确定;再根据其他影响犯罪构成的犯罪数额、犯罪次数、犯罪后果等犯罪事实,在量刑起点的基础上增加刑罚量确定基准刑;然后根据量刑情节调节基准刑,并综合考虑全案情况,依法确定宣告刑.根据

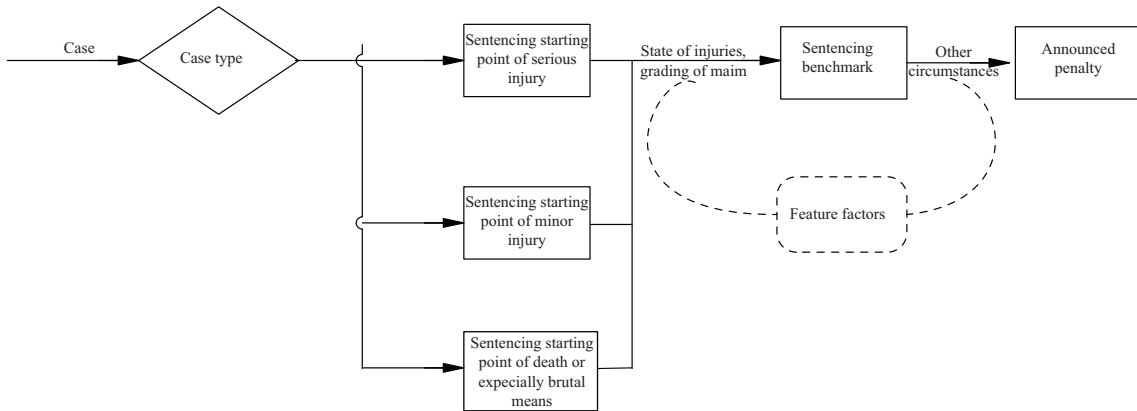


图 1 故意伤害罪量刑逻辑过程

Figure 1 Sentencing logical process for the crime of intentional injury

《量刑指导意见》，量刑情节调节基准刑的方法，是根据量刑情节的调节比例直接调节基准刑；对于具有多个量刑情节的，一般根据各个量刑情节的调节比例，采用同向相加，逆向相减的方法调节基准刑。这一按比例调节的方法，在模型中表现为乘积关系。

我国《刑法》中涉及罪名众多，每个罪都有独立的犯罪构成要件和量刑阶梯，因此，很难建立一种准确适应所有类型犯罪的通用量刑模型；或者说通用模型很难实现计算的精准性目标。因此，我们需要根据具体犯罪的犯罪构成，还原符合个罪特征的量刑逻辑过程。本文以故意伤害罪为例进行建模。图 1 展示了故意伤害罪基本的量刑逻辑过程，包括了致人重伤、致人轻伤、手段特别残忍或致人死亡等三类量刑起点类型。

值得指出，在量刑建模过程中，宣告刑具有浮动边界。一方面，量刑情节对基准刑的调节结果并不等同于宣告刑，宣告刑需受法定刑边界的限制，并且这一边界是浮动的。在实际的案件中，多量刑情节共存是比较普遍的情况。按照“同向相加，逆向相减”的计算规则，可能经常会出现超出法定刑区间的计算结果。当出现超出法定刑区间的计算结果时，需要考虑以下两种情况对计算结果进行调整。第一种情况，法定刑边界，即宣告刑边界，宣告刑不能突破法定刑区间限制。这种情况适用于有“从轻”“从重”情节时（依据《刑法》第 62 条）。第二种情况，可以在法定刑底线以下确定宣告刑，宣告刑边界向下浮动。这种情况适用于具有“减轻”情节时（依据《刑法》第 63 条）。具体就故意伤害罪而言（《刑法》第 234 条），根据罪行的轻重，法定刑区间分为三类：（1）致人轻伤的，处 3 年以下有期徒刑，拘役或者管制。（2）致人重伤的，处 3 年以上 10 年以下有期徒刑；（3）致人死亡或者以特别残忍手段致人重伤造成严重残疾的，处 10 年以上有期徒刑，无期徒刑或者死刑。另一方面，有期徒刑总量存在区间控制。就一罪（不考虑数罪并罚）而言，根据《刑法》第 45 条，有期徒刑的期限为 6 个月以上，15 年以下。亦即刑期总量控制的区间为 6 个月至 15 年。

总之，有期徒刑量刑除受罪行轻重（致人轻伤、重伤、死亡或手段特别残忍）的影响，还受具体情节的性质（从重、从轻、减轻）的影响，也受有期徒刑刑期总量控制。因此，在构建数学模型时，需要根据这些规则通过饱和函数的变化来体现宣告刑的边界。

2.2 非线性量刑模型 (S-模型) 及特点

基于上述量刑逻辑过程和建模要点，我们将所有样本按照判决时间先后排序，可以得到如下的饱

和 (saturation) 非线性回归模型 (简称 S- 模型):

$$y_t = S_t \left(\underbrace{\left(\underbrace{a_t}_{\text{量刑起点}} + \underbrace{bx_t^{(1)} + cx_t^{(2)} + dx_t^{(3)}}_{\text{基准刑}} \right)}_{\text{刑罚量}} \right. \\ \left. \left(\underbrace{1 + \phi_t^T \vartheta + e}_{\text{量刑情节因素的影响}} \right) + w_t \right), \quad (1)$$

其中, 非线性主要体现为饱和函数 S_t 的非线性, 以及模型参数的乘积所体现的非线性. 值得指出, 模型中的乘积非线性项可以通过扩展回归向量维数或根据数据性质分组转化为多个线性项, 而饱和非线性特征无法转换. 饱和函数具体定义如下:

$$S_t(x) = \begin{cases} U_t, & x > U_t, \\ x, & L_t \leq x \leq U_t, \\ L_t, & x < L_t. \end{cases} \quad (2)$$

模型中 y_t 为第 t 个案件的有期徒刑刑期 (单位: 月); 同一天发生的案件可以随机排序, 对计算结果没有实质性影响. a_t 表示量刑起点 (单位: 月); $x_t^{(1)}$, $x_t^{(2)}$, $x_t^{(3)}$ 分别表示第 t 个案件中决定刑罚量的轻伤人数、重伤人数、死亡人数; b, c, d 分别代表每多造成一个轻伤、重伤、死亡所增加的刑期; ϕ_t 表示所选取的量刑特征因素构成的回归向量 (特征因素的选择问题, 将在 2.3 小节讨论), 其各分量的值为 0 或 1; ϑ 表示量刑特征因素所对应的未知参数向量, 每一个分量体现了对应特征因素作用所占的百分比; e 是建模的偏置项, 代表可能未考虑到的其他量刑特征因素的综合影响; w_t 是可能存在的随机噪声; U_t 是相应法定刑区间的上限, 分别取为 36 (月), 120 (月) 和 180 (月); L_t 是相应法定刑区间的下限, 分别取为 6 (月), 36 (月) 和 120 (月), 它们因轻伤、重伤、死亡 (手段特别残忍) 案件性质的不同而不同, 并且根据法定量刑情节的性质而浮动; $(\cdot)^T$ 表示向量转置符号.

值得指出, 相较目前法律实证研究中常用的线性模型, 上述 S- 模型的特色至少体现在如下三方面.

第一, 体现了量刑中固有的非线性饱和特性. 饱和函数 S_t 体现了法定刑区间, 弥补了传统线性模型无上下界的不足. 在具体取值时, 具有“减轻”情节的死亡案件, 饱和函数的下界可取为重伤案件饱和函数的下界; 对于有“减轻”情节的重伤案件来说, 饱和函数的下界可取为轻伤案件饱和函数的下界; 但对于有“减轻”情节的轻伤案件来说, 饱和函数的下界取为 6 (月).

第二, 依据量刑起点、基准刑、量刑情节因素在司法中的逻辑关系, 明确了它们在模型中的具体作用. 量刑起点与基准刑的确定是量刑中一个基本问题. 在以往的研究中, 通常利用的是多元线性回归模型, 犯罪构成与量刑情节等诸多要素的影响是以线性叠加的方式出现的. 根据《刑法》和《量刑指导意见》的相关规定, 量刑情节对基准刑的调节是“比例 (乘积)”型的逻辑关系, 据此, 我们在 S- 模型中明确了量刑起点、基准刑、量刑情节因素的应然作用, 由此可以通过判决数据合理判断各要素的具体作用大小与法律规范的符合程度.

第三, 模型不但考虑了上述“确定性”因素的影响, 而且考虑了未建模或“不确定性”因素的影响. 对此, 我们设置了未知偏置项 e 和随机噪声项 w_t 以体现未建模或不确定性因素对量刑的可能影响.

此外, 可以根据各省具体规定进一步细化模型, 提高模型的准确性. 以山东省为例, 根据山东省高

级人民法院《关于常见犯罪的量刑指导意见》关于量刑起点及基准刑确定的规定²⁾, 追加考虑轻微伤人数、被害人人数、被害人伤残等级、持械伤人等情况, 并可以给出“基准刑”的确定值. 因本文主要研究全国判决数据样本, 故在此不详细讨论各省具体情况.

2.3 量刑特征选择

对于样本数据, 最高人民法院司法大数据研究院在人工标注基础上运用自然语言处理技术提取了量刑相关字段 302 个. 在此基础上, 我们根据不同的计算目的, 分别进行了进一步的特征选择.

首先, 按照这些字段的法律属性归类 (比如将“前科”与“因 ** 受过刑事处罚”合并), 得到如下 64 个“自然特征”用于刑期预测: 缓刑、提出附带民事诉讼、致人死亡、重伤一级、重伤二级、重伤、轻伤一级、轻伤二级、轻伤、致人轻微伤、残忍手段、一级伤残、二级伤残、三级伤残、四级伤残、五级伤残、六级伤残、首要分子、一般主犯、雇佣他人、从犯、主动自首、准自首、劝说自首、避免严重后果发生、坦白、揭发同案犯共同犯罪事实、被害人过错、民间矛盾、家庭纠纷、累犯、前科、初犯偶犯、认罪认罚、当庭自愿认罪、谅解、积极赔偿并达成谅解、刑事和解、积极赔偿并刑事和解、积极赔偿、抢救被害人、持械斗殴、是否有辩护人、75 周岁以上、互殴、结伙聚众斗殴、又聋又哑的人或盲人、刑事责任年龄 (14~16)、不满十八周岁、胁从犯、教唆犯、正当防卫、防卫过当、紧急避险、避险过当、精神病人犯罪、立功、犯罪预备、未遂犯、中止犯、涉黑涉恶、寻衅滋事、犯罪对象特殊、未造成损害后果.

其次, 进一步选择“主要特征”, 用于对主要特征因素影响的辨识.

第一步, 根据相关性对自然特征进行合并. 直观上讲, 用于建模的特征因素之间的相关性越大, 辨识区分这些特征对量刑的影响程度越困难. 理论上讲, 特征间的相关性越大, 相应的“信息矩阵”所包含的信息量越少, 辨识结果的可靠性越差^[13, 15]. 因此, 为了得到良好的辨识结果, 我们根据法律中相关规定对相近或相似的自然特征进行必要的合并. 比如, 将“首要分子”“一般主犯”“雇佣他人”合并为“主犯”.

第二步, 根据具体特征的分布情况, 删除了部分过分稀疏的特征 (频次少于 200, 加入后不足以产生影响). 为进一步排除这些特征的影响, 我们把含有这些特征的案件也相应删除. 最终在建模中确定了 28 个主要的特征因素: 重伤人数、轻伤人数、轻微伤人数、手段残忍、伤残等级/人数、缓刑、死亡、自首、坦白、和解、谅解、积极赔偿、认罪认罚、附带民事诉讼、主犯、从犯、民间矛盾、抢救被害人、持械、是否有辩护人、初犯偶犯、当庭自愿认罪、被害人过错、累犯、前科、75 周岁以上、又聋又哑盲人、互殴. 注意到, 其中“缓刑”与其他特征因素的性质有所不同, 因此有必要专门讨论其在建模中的作用方式.

第三步, 确定缓刑 (特征因素) 在建模中的作用及方式.

缓刑是一种刑罚执行方式, 是附条件的暂不执行原判刑罚. 根据《刑法》第 72 条规定, 对于被判处拘役, 三年以下有期徒刑的犯罪分子, 可以宣告缓刑, 对其中不满十八周岁的人、怀孕的妇女和已满七十五周岁的人, 应当宣告缓刑. 从相关法律规定看, 缓刑与有期徒刑并无明确的因果关系. 但是, 我们尚无法排除在司法实践中缓刑与有期徒刑之间存在影响的可能性, 更缺乏对有期徒刑与缓刑之间定

2) 山东省高级人民法院《关于常见犯罪的量刑指导意见》故意伤害罪量刑起点: (1) 故意伤害致一人轻伤的, 轻伤二级的, 在一年至一年六个月有期徒刑幅度内确定量刑起点; 轻伤一级的, 在一年六个月至二年有期徒刑幅度内确定量刑起点. 基准刑确立: (1) 每增加一人轻微伤, 增加一个月至二个月刑期. (2) 每增加一人轻伤, 轻伤二级的, 增加六个月至一年刑期; 轻伤一级的, 增加一年至一年六个月刑期. (3) 造成被害人六级至三级残疾, 每增加一级残疾, 增加一年至一年六个月刑期; 造成被害人残疾程度超过三级的, 每增加一级残疾, 增加二年至二年六个月刑期. (4) 使用刀具等锐器、棍棒等钝器伤人的, 每次犯罪增加一个月至三个月刑期; 使用枪支伤人的, 每次犯罪增加六个月至一年刑期. 事先准备或者携带上述工具并使用的, 在增加刑期幅度内从重考虑.

表 1 缓刑对刑期预测的影响

Table 1 Effects of probation to sentencing prediction

	(a) Without probation	(b) Probation variable (dummy)	(c) Probation variable (with length)
Prediction accuracy	0.9088	0.9120	0.9074

量关系的恰当描述. 为此, 我们利用数据做了以下三组对照实验, 以探究缓刑 (特征因素) 的实际作用.

(a) 假定缓刑不影响有期徒刑刑期. 选取除缓刑外的全部其他自然特征进行建模, 并利用 TSQN 算法对刑期进行递推预测, 记录预测精度.

(b) 假定缓刑影响有期徒刑刑期, 但缓刑期限不影响. 在量刑情节中加入缓刑哑变量 (即若有缓刑为 1, 否则为 0) 作为特征因素, 进行递推预测计算并记录预测精度.

(c) 假定缓刑影响有期徒刑刑期, 并且缓刑期限也有影响. 在模型中加入缓刑期限变量, 进行递推预测计算并记录预测精度.

表 1 展示了上述 3 种情况下缓刑 (特征) 对刑期预测精度影响的实验结果. 可以看出, 在情形 (b) 下, 预测精度最高. 这说明把缓刑哑变量作为建模的特征因素之一更恰当.

3 计算方法及说明

3.1 样本数据说明

本研究数据来源于最高人民法院司法大数据研究院. 样本取自 2011 年 1 月至 2021 年 6 月的故意伤害罪初审判决. 为减少文本结构化过程中的误差, 提高数据准确性, 我们排除了多被告、数罪的判决文书, 即采用了故意伤害罪一罪的判决, 并选取其中判处有期徒刑的判决, 共计 19.959 万. 其中, 致人轻伤案件 17.1666 万, 致人重伤案件 2.4503 万, 致人死亡案件 3421. 由于致人死亡的结果与死刑和无期徒刑的判决有较大关联, 且有期徒刑判决数量相对较少, 本文主要考虑致人重伤或轻伤的样本 (共计 19.6169 万), 致人死亡案件另文研究.

同时, 由于司法判决数据随着时间的增加而逐渐积累, 而且可能因法律或刑事政策的变化而变化, 司法判决数据在本质上是关于时间的流数据. 进一步, 全国的刑事司法审判还具有空间上的一致性和时间上的关联性, 其依据在于: 第一, 《刑法》《量刑指导意见》在全国范围内具有一致的法定指导作用, 各省在量刑上虽然可能存在地域差异, 但差异不能超出法定范畴. 第二, 类案推送系统在全国范围的适用, 以及最高人民法院批量指导案例与典型案例的发布, 对后续的全局司法审判均有显著的引导作用. 因此, 按判决时间进行排序并进行相关分析是合理的.

3.2 不适宜问题处理

根据《量刑指导意见》, 量刑起点是一个区间. 在审判实践中, 需要根据基本犯罪构成事实在相应的幅度内确定一个具体的起刑点, 但其具体值可能因地区或司法习惯的差异而有所不同. 关于量刑起点如何确定, 理论界曾有一些讨论和建议, 但并未转化为司法实践的确定性规则. 为此, 我们需要通过计算实验并结合司法实践, 确定模型中量刑起点的计算值.

从 S- 模型可以看出, 在量刑起点、刑罚量系数、量刑情节因素系数和偏置项都未知的情况下, 对量刑模型进行求解是一个数学上的不适宜问题, 即解不具备存在唯一性. 进一步, 从 S- 模型可以看出, 基准刑与量刑情节因素以乘积的形式出现在模型中, 前者减小或增大总能通过后者增大或减小来补偿. 换言之, 从方程求解的角度, 同时估计量刑起点、刑罚量、量刑情节作用和偏置项大小, 是不适

表 2 量刑预测精度随量刑起点的变化

Table 2 Changes of the prediction accuracy in terms of different sentencing starting points

	Range 0	Range 1/6	Range 1/3	Range 1/2	Range 2/3	Range 5/6	Range 1
Prediction accuracy	0.9119	0.9120	0.9120	0.9120	0.9119	0.9118	0.9116

表 3 偏置项估计值随量刑起点的变化

Table 3 Changes of the bias term estimates in terms of different sentencing starting points

	Range 0	Range 1/6	Range 1/3	Range 1/2	Range 2/3	Range 5/6	Range 1
Bias term estimate	0.1062	0.0346	-0.0289	-0.0854	-0.1359	-0.1814	-0.2226

定的数学问题. 因此, 为了估计量刑情节因素的真实作用, 我们需要额外信息和其他方法来确定合适的量刑起点. 值得指出, 如果我们的额外信息是“偏置项为零或可以忽略”, 那么上述“不适定”问题将变成可以解决的适定问题.

在一般情形下, 我们可以通过进一步的计算实验并结合司法实践经验给出解决不适定性问题的方案. 首先, 我们构造并开展如下计算实验: 将量刑区间六等分, 分别取量刑起点为量刑区间的 1/6, 1/3, 1/2, 2/3, 5/6 处以及区间的最低点和最高点进行计算, 得到 7 组不同的预测精度及偏置项估计值, 结果如表 2 和 3 所示.

由表 2 可以看出, 量刑预测精度受量刑起点变化的影响很小 (小于 0.04%), 尤其是换算为天数后误差小于一天, 故误差可忽略不计. 从数学模型上看, 量刑起点选择的差异性, 可以通过量刑情节作用的大小进行调节, 从而能够保持刑期的预测精度.

进一步, 在 7 种不同量刑起点计算情形下, 通过计算我们发现量刑情节因素系数的估计值变化不大. 然而, 偏置项估计值 e 的变化相对比较显著 (见表 3). 这说明, 偏置项的变化主要受量刑起点选择的影响. 因此, 考虑到偏置项在建模中的意义, 对量刑起点的合理选择, 应使其所对应的偏置项绝对值最小. 根据上述实验结果我们发现, 偏置项的绝对值在量刑区间的 1/3 处达到最小值 (见表 3).

同时, 我们调研访谈了山东省三地市以及上海市某区基层法院刑事审判庭, 获知法官一般也将量刑起点选择在量刑区间的三分之一处. 因此, 我们在模型构建和数据计算过程中, 将量刑起点选在相应量刑区间的 1/3 处. 具体到故意伤害罪, 根据《量刑指导意见》, 可以根据致人轻伤、致人重伤、致人死亡或手段特别残忍三个等级所规定的量刑起点区间 (分别为 2 年以下, 3 年到 5 年, 10 年到 13 年)³⁾, 确定出具体的量刑起点. 当然, 也可以通过实验来进一步寻找可能更小的偏置项所对应的量刑起点值. 但那样做对参数估计和量刑预测结果都没有显著影响, 因此可不必作进一步讨论.

3.3 具体计算方法

针对当前 S- 模型的双重非线性, 有两种方法可以将饱和函数内部的乘积非线性项转化为线性回归的形式: 一是升高回归向量的维数, 二是根据数据性质分组. 在本文中两种方法的计算结果基本一致, 以下只介绍第一种方法. 引入新的高维回归向量 φ_t 如下:

$$\varphi_t = \left(a_t, x_t^{(1)}, x_t^{(2)}, x_t^{(3)}, a_t \phi_t^T, x_t^{(1)} \phi_t^T, x_t^{(2)} \phi_t^T, x_t^{(3)} \phi_t^T \right)^T, \quad (3)$$

3) 故意伤害罪可以根据下列不同情形在相应的幅度内确定量刑起点: (1) 故意伤害致一人轻伤的, 可以在二年至五年有期徒刑幅度内确定量刑起点. (2) 故意伤害致一人重伤的, 可以在三年至五年有期徒刑幅度内确定量刑起点. (3) 以特别残忍手段故意伤害致一人重伤, 造成六级严重残疾的, 可以在十年至十三年有期徒刑幅度内确定量刑起点. 依法应当判处无期徒刑以上刑罚的除外.

相应地, 定义如下未知参数向量:

$$\theta = (1 + e, b(1 + e), c(1 + e), d(1 + e), \vartheta^T, b\vartheta^T, c\vartheta^T, d\vartheta^T)^T. \quad (4)$$

则上述 S- 模型可以转换为如下形式上的饱和非线性随机模型:

$$y_t = S_t(\varphi_t^T \theta + w_t). \quad (5)$$

显而易见, 只要从模型 (5) 中辨识出未知参数 θ , 就可以根据 (4) 确定出原模型 (1) 的参数 $(e, b, c, d, \vartheta^T)$. 对上述模型, 为了提高非持续激励数据条件下的辨识精度, 我们在相伴论文 [13] 中提出了两步骤随机拟牛顿 (TSQN) 递推辨识算法并建立了相应的估计误差理论. 该算法具体公式如算法 1 所示.

算法 1 TSQN 算法

Step 1. 对 $t \geq 1$, 递推计算初步的估计值 $\bar{\theta}_t$:

$$\begin{aligned} \bar{\theta}_t &= \Pi_{\bar{P}_t}^{-1} \{ \bar{\theta}_{t-1} + \bar{a}_t \bar{\beta}_t \bar{P}_{t-1} \varphi_t [y_t - G_t(\varphi_t^T \bar{\theta}_{t-1})] \}, \\ \bar{P}_t &= \bar{P}_{t-1} - \bar{a}_t \bar{\beta}_t^2 \bar{P}_{t-1} \varphi_t \varphi_t^T \bar{P}_{t-1}, \\ \bar{\beta}_t &= \min \left\{ \underline{g}_t, \frac{1}{2 \bar{g}_t \varphi_t^T \bar{P}_{t-1} \varphi_t + 1} \right\}, \\ \bar{a}_t &= \frac{1}{1 + \bar{\beta}_t^2 \varphi_t^T \bar{P}_{t-1} \varphi_t}. \end{aligned} \quad (6)$$

Step 2. 对 $t \geq 1$, 基于 $\bar{\theta}_t$ 递推计算改进的估计值 $\hat{\theta}_t$:

$$\begin{aligned} \hat{\theta}_t &= \Pi_{P_t}^{-1} \{ \hat{\theta}_{t-1} + a_t \beta_t P_{t-1} \varphi_t [y_t - G_t(\varphi_t^T \hat{\theta}_{t-1})] \}, \\ P_t &= P_{t-1} - a_t \beta_t^2 P_{t-1} \varphi_t \varphi_t^T P_{t-1}, \\ \beta_t &= \frac{G_t(\varphi_t^T \bar{\theta}_{t-1}) - G_t(\varphi_t^T \hat{\theta}_{t-1})}{\varphi_t^T \bar{\theta}_{t-1} - \varphi_t^T \hat{\theta}_{t-1}} I_{\{\varphi_t^T \bar{\theta}_{t-1} - \varphi_t^T \hat{\theta}_{t-1} \neq 0\}} + G'_t(\varphi_t^T \hat{\theta}_{t-1}) I_{\{\varphi_t^T \bar{\theta}_{t-1} - \varphi_t^T \hat{\theta}_{t-1} = 0\}}, \\ a_t &= \frac{1}{\mu_t + \beta_t^2 \varphi_t^T P_{t-1} \varphi_t}, \end{aligned} \quad (7)$$

其中, 函数 $G_t(x) = \mathbb{E}[S_t(x + w_t) | \mathcal{F}_t]$ 是在给定 \mathcal{F}_t 下的条件数学期望, $\{\mathcal{F}_t\}$ 是由噪声产生的非降 σ - 代数族; $\Pi_{\bar{P}_t}^{-1}$ 是投影算子, 详见文献 [13]; $\underline{g}_t = \inf_{x \in D} \{G'_t(\varphi_t^T x)\}$, $\bar{g}_t = \sup_{x \in D} \{G'_t(\varphi_t^T x)\}$, 其中 $G'_t(x)$ 是 $G_t(x)$ 关于 x 的导数; μ_t 可以选取为任意 \mathcal{F}_t 可测的随机变量, 但满足 $0 < \inf_{t \geq 0} \{\mu_t\} \leq \sup_{t \geq 0} \{\mu_t\} < \infty$; 算法初始值 $\bar{\theta}_0$ 及 $\hat{\theta}_0$ 可以任意从未知参数所属的先验凸集 D 中选取, 而初始矩阵 $\bar{P}_0 > 0$ 及 $P_0 > 0$ 可任意选取.

该算法的突出特点如下: 第一, 是针对量刑中具有饱和性质的 S- 模型所设计的, 不同于传统的线性最小二乘等算法. 第二, 可以证明, 算法不但具有全局收敛性理论依据, 并且当数据的样本量有限时, 也可以从理论上给出参数估计误差的可靠上下界, 详见文献 [13]. 第三, 不需回归向量的独立同分布性等传统上难以满足的统计假设, 更加适合司法判决这一类复杂社会数据的特性. 第四, 算法具有自适应性, 即下一时刻的估计值是当前时刻的估计值根据新数据所做的实时更新, 因此通过自适应算法能够观察模型中量刑特征因素作用大小可能随时间变化的情况.

具体到本文考虑的量刑数据分析, 通过数据对噪声 w_t 进行估计, 启示我们其分布可以用均值为 0, 标准差为 5 的正态分布来建模. 因此, 在具体量刑计算和由 Monte Carlo 方法给出的参数估计误差等式中, 我们假设了噪声独立并服从 $N(0, 25)$ 分布. 事实上, 对这样建模的噪声, 我们用近 20 万的司法判决数据, 可以给出对刑期的高精度自适应预测 (见 4.1 小节), 由此也说明对噪声这样建模的合理性.

表 4 S- 模型预测 vs. L- 模型预测
Table 4 S-model prediction vs. L-model prediction

	Prediction accuracy
S-model	0.9120
L-model	0.8494

此外, 在本文考虑的量刑数据计算问题中, 函数 $G_t(\cdot)$ 可以具体表达为 $G_t(x) = U_t + (L_t - x)F(L_t - x) - (U_t - x)F(U_t - x) + 25[f(L_t - x) - f(U_t - x)]$, 导数 $G'_t(\cdot)$ 的表达式为 $G'_t(x) = F(U_t - x) - F(L_t - x)$, 其中 $F(\cdot)$ 及 $f(\cdot)$ 分别是正态分布 $N(0, 25)$ 的分布函数及概率密度函数; 特征因素“重伤人数”对应参数的投影区间为 $[0, 40]$, 特征因素“轻伤人数”对应参数的投影区间为 $[0, 10]$, 偏置项投影区间为 $[-1, 1]$, 其余特征中增刑特征因素 (如, 持械) 对应参数的投影区间为 $[-0.1, 1]$, 减刑特征因素 (如, 自首) 对应参数的投影区间为 $[-1, 0.1]$; $\mu_t = 25$; 初始值 $\bar{P}_0 = P_0 = I$, $\bar{\theta}_0$ 及 $\hat{\theta}_0$ 选取为 θ 的线性最小二乘估计值作为上述算法的初始值. 进一步, 针对当前给定的有限数据样本集, 本文利用 Monte Carlo 模拟方法及相应误差估计理论 (见文献 [13], Proposition 1) 给出参数估计误差的上下界, 其中可调参数选择为 $\alpha = 0.09$, $t = 0.01$, $K = 100000$.

4 结果分析及意义

4.1 量刑预测精度

本小节将依据实际判决数据对刑期进行预测, 并对式 (5) 所给出的 S- 模型与式 (5) 中没有饱和函数时的线性 (linear) 模型 (简称 L- 模型) 的预测精度进行比较. 当我们只关注致人轻伤案件时, 从数据中可以看出大部分判决的刑期都在相应的饱和区间之内, 在此情况下, 饱和函数并不发挥本质性作用. 但是, 在致人重伤的情形下, 13429 个判决达到致人重伤的法定刑区间 (饱和函数) 下限 (3 年), 11074 个判决位于法定刑区间内; 在此情况下, 饱和函数可以发挥关键作用 (可以充分体现模型的饱和和性质). 我们定义量刑预测精度为

$$\frac{1}{T} \sum_{t=1}^T \frac{|y_t - \hat{y}_t|}{y_t}, \quad (8)$$

其中, y_t 是第 t 个案件判决的实际有期徒刑, \hat{y}_t 是根据前 $t - 1$ 个案件的判决数据对第 t 个案件刑期的自适应预测, T 为判决总数. 上述定义给出的是相对预测误差的平均值. 作为对比, 我们同时实验了 L- 模型下递推最小二乘 (RLS) 算法的量刑预测精度. 表 4 展示了总体数据集下, 两类模型在精度预测方面的对比, 可以看出, 针对故意伤害致人重伤案件的刑期预测, S- 模型与 L- 模型相比总体平均提高了约 6.26%. 图 2 展示了 2011~2021 年预测精度的变化趋势, 可以看出, S- 模型的预测精度始终远高于 L- 模型的预测精度.

4.2 参数辨识的合理性与可靠性

本小节利用故意伤害罪实际判决数据进行计算, 给出 S- 模型中关于特征因素影响大小的具体估计值, 说明其合理性与可靠性. 与此同时, 我们也将讨论 L- 模型给出的估计值与 S- 模型估计值的差距.

随着近年来我国全面依法治国战略的推进, 特别是量刑规范化改革的不断深入, 我们认为, 刑事司法审判在总体上符合《刑法》和《量刑指导意见》的相关规定. 在这一前提下, 我们对 S- 模型和 L-




图 2 重伤案件量刑预测精度对比 (2011~2021): S- 模型 vs. L- 模型

Figure 2 Comparison of prediction accuracies between S-model and L-model based on serious injury data (2011~2021)

模型估计值的合理性进行比较, 详见表 5. 其中, S- 模型估计误差的上下界是在有限样本 (19.6169 万) 下基于 Monte Carlo 方法得到的 90% 置信界, 置信上下界分别代表估计误差 $(\theta - \hat{\theta})$ 的 0.95 分位数和 0.05 分位数的估计值, 具体计算公式参见文献 [13] (Proposition 1); L- 模型估计误差上界为 90% 概率误差绝对值上界, 具体由有限样本下最小二乘算法估计误差 inequality 进行计算 (见 [16], p. 155).

通过表 5 可以看出 S- 模型的两方面特点.

第一, S- 模型的建模更合理. 如前所述, 在量刑模型中偏置项体现了未建模因素对量刑的可能影响. 偏置项的绝对值越小, 说明未建模因素的影响越小或建模误差越小. 由表 5 可以看出, L- 模型的偏置项估计值 (0.04~0.05) 大于 S- 模型估计值 (0.0289), S- 模型的建模误差更小, 因此更合理.

第二, S- 模型对具体量刑情节的估计更合理. 根据表 5, 我们将说明 S- 模型相较 L- 模型对具体的量刑情节的估计更加合理, 特别是对从犯、75 周岁以上、自首、和解谅解等情节的估计, 更加符合法定预期. 为说明这一合理性, 我们首先需要回顾相关量刑情节的“调节强度”与适用“优先级”两个方面的要点.

一是“调节强度”. 这里的“调节强度”包括两个维度, 第一个维度是, 是否具有“强制性”, 即该情节出现时, 是否应当适用而不是选择性适用; 第二个维度是, 对基准刑的调节幅度, 具体体现为调节的比例. “调节强度”可以作为量刑情节影响估计准确性或合理性的参照系. 根据《量刑指导意见》, 上述量刑情节的调节强度如下所述: (1) 对于从犯, “应当”从轻、减轻处罚或者免除处罚, 调节幅度为基准刑的 20%~50%, 犯罪较轻的, 可以减少基准刑的 50% 以上或者依法免除处罚. (2) 对于年满 75 周岁故意犯罪的, “可以”从轻或者减轻处罚, 调节幅度为基准刑的 40% 以下. (3) 对于故意犯罪后自首的, 可以从轻或减轻处罚, 调节幅度为基准刑的 40% 以下, 犯罪较轻的可以减少基准刑的 50% 以上或者依法免除处罚. (4) 对于积极赔偿被害人经济损失并取得谅解的, “可以”减少基准刑的 40% 以下. (5) 对于达成刑事和解协议的, 可以减少基准刑的 50% 以下, 犯罪较轻的可以减少基准刑的 50% 以上或者依法免除处罚.

表 5 S- 模型参数估计 vs. L- 模型参数估计
Table 5 Parameter estimation: S-model vs. L-model^{a)}

Feature	Estimate $\hat{\theta}$ of S-model	Estimation error bound of S-model		Estimate $\hat{\theta}$ and estimation error bound of L-model
		Lower bound	Upper bound	
Bias term	-0.0289	-0.0108	0.0104	-0.0458 ± 0.0082
Number of people suffering a serious injury	25.67	-6.292	5.634	24.65 ± 5.2558
Number of people suffering a minor injury	6.55	-0.733	1.0655	6.59 ± 0.8566
Probation dummy variable	-0.0838	-0.0231	0.0075	-0.0541 ± 0.0055
Surrender	-0.1506	-0.0080	0.0060	-0.091 ± 0.0047
Confession	-0.0454	-0.0073	0.0073	-0.0238 ± 0.0045
Reconciliation, reconciliatory	-0.2987	-0.0142	0.0084	-0.1815 ± 0.0057
Compensation	-0.0654	-0.0122	0.0074	-0.039 ± 0.0063
Admitting guilt & accepting punishments	-0.1110	-0.0229	0.0248	-0.0695 ± 0.0111
Incidental civil action	0.1303	-0.0080	0.0116	0.084 ± 0.0052
Principal criminal	0.0387	-0.0266	0.0240	0.058 ± 0.0173
Accessory criminal	-0.3440	-0.0783	0.0564	-0.1099 ± 0.031
Civil dispute	-0.0398	-0.0130	0.0060	-0.0216 ± 0.004
Rescuing the victim	0.0650	-0.0455	0.0475	0.0785 ± 0.0268
Armed	0.1829	-0.0068	0.0074	0.1422 ± 0.0041
Having a defender	-0.0089	-0.0149	0.0068	0.037 ± 0.0043
First offender	-0.0038	-0.0088	0.0132	-0.0009 ± 0.0055
Pleading guilty in court	-0.0001	-0.0121	0.0073	0.003 ± 0.004
Victim's fault	-0.0436	-0.0109	0.0056	-0.0242 ± 0.004
Recidivism	0.1983	-0.0090	0.0110	0.143 ± 0.0084
Criminal record	0.0358	-0.0123	0.0139	0.0125 ± 0.01
Aged 75 and over	-0.2396	-0.0620	0.0453	-0.1287 ± 0.0238
Deaf and mute, blind	-0.0040	-0.0281	0.0227	0.0083 ± 0.0125
Assaulting each other	-0.0155	-0.0085	0.0063	0.0003 ± 0.0048

a) The parameter estimates corresponding to main features are the proportions of their adjustments to the sentencing benchmark except the two features about the numbers of people suffering serious and minor injuries.

二是适用“优先级”。具体量刑情节的适用存在“优先级”的不同。自 2013 年至今三版的《量刑指导意见》均规定,“具有未成年人犯罪,老年人犯罪,限制行为能力的精神病人犯罪,又聋又哑的人或者盲人犯罪,防卫过当,避险过当,犯罪预备,犯罪未遂,犯罪中止,从犯,胁从犯和教唆犯等量刑情节的,先适用该量刑情节对基准刑进行调节,在此基础上,再适用其他量刑情节进行调节”。在具体计算时,具有多个量刑情节的,一般根据各个量刑情节的调节比例,采用同向相加,逆向相减的方法调节基准刑。这可以作为量刑情节参数估计准确性或合理性的一个重要法律依据。

在明确上述两个要点的基础上,我们发现,S-模型给出的关于量刑情节调节作用大小的估计值更符合《刑法》与《量刑指导意见》的相关规定,对于分析研究我国刑事司法审判实践具有重要意义。

首先,S-模型能够合理估计“从犯”的作用,而L-模型给出的估计甚至部分偏离《量刑指导意见》。考察上述两方面要点,我们可以发现从犯具有“强制性”“优先适用”和“幅度大”三个基本特征。其中“幅度大”,是指从犯对量刑的减轻调节作用的上限为 50%,并且是除未成年人犯罪外唯一的写明

了调节幅度“底线”(20%)的量刑情节.因此,从犯对量刑的合理影响应当较大,并且落在20%~50%的调节区间之内.根据表5的计算结果,S-模型估计结果为-0.3440,L-模型估计为-0.11左右;分别对应着从犯对量刑的调节作用为-34%和-11%.可以看出,S-模型的估计更加准确,而L-模型的估计则远离合理区间,偏差较大.

其次,S-模型对75周岁以上(老年人犯罪)、自首、和解谅解等情节的估计似乎也更加符合法定预期.考察前述两方面要点我们发现,老年人犯罪具有“优先适用”和“幅度较大”(40%以内)两大基本特征,因而“75周岁以上”这一量刑情节的调节作用应当较大.相似地,根据《量刑指导意见》,“自首”“谅解和解”对量刑的减轻作用较大(根据不同情况可以减少基准刑的40%以内或以上).由表5的计算结果,S-模型对上述3个情节作用的估计值分别为-0.2396,-0.1506,-0.2987,对应的调节作用分别为-23.96%,-15.06%和-29.87%左右;而L-模型估计为-0.1287,-0.091,-0.1815,对应的调节作用分别为-12.8%,-9%和-18%.这再次说明,S-模型中饱和函数的作用是显著的,使得估计结果更加符合法律预期,在建模中不可忽视.

与以往的研究不同,我们还同时给出了参数估计的可靠性保证.从表5可以看出,我们不但给出了在有限样本量下特征因素的估计值,并且计算出了估计误差的上下界.注意到这一误差界比估计值本身普遍小一个数量级,即使考虑其对估计值的最大可能影响,也足够小,因此足以保证估计值的可靠性.

进一步,我们的辨识递推算法可以呈现量刑特征要素的影响随时间的变化趋势,进而发现司法的变化规律及其背后的法治变迁轨迹.分析发现,总体来看,建模中的量刑特征因素随时间变化的表现平稳,但也存在个别特征变化明显,如图3所示.

从图3可以看出,偏置项和认罪认罚两个特征出现了随时间的明显变化.

第一,关于偏置项的变化,由于前端数据数量小,所含信息不足以给出参数的合理估计,导致瞬态估计值波动明显,不具参考意义;随着数据量随时间的增加,偏置项的具体值不断降低,说明我国刑事司法实践中未建模不确定性因素的影响越来越低,量刑规范化改革不断取得显著成效.另一方面,偏置项的具体值逐渐发展为负值,这说明未建模调节因素的综合效果逐渐呈现出减轻刑罚的作用,间接地表现出一种刑事政策上的刑罚轻缓化趋势.

第二,认罪认罚作为一项创新的刑事诉讼制度,2016年9月开始在北京、上海、天津等18个地区开展试点,2018年10月纳入《刑事诉讼法》,在全国正式实施.因为2018年之前相关数据很少,在此之前算法的估计值无法有效更新,表现为常值(算法初始值).因此,算法的瞬态响应的波动推迟至2019年前后,其未来发展趋势值得进一步关注.无论如何,从图3看出,认罪认罚估计值呈现减轻刑罚的作用,符合认罪认罚从宽制度改革的政策预期.

总之,根据S-模型的计算结果,说明在我国刑事司法审判中,量刑情节的适用在总体上符合法律和相关司法解释的规定.与此同时,也存在一些值得进一步关注和探讨的问题.例如,(1)关于坦白情节,《量刑指导意见》给出的基础的从宽幅度为“减少基准刑的20%以下”(有进一步从宽情节,这一幅度还可以增大).根据我们的计算结果,坦白的从宽幅度(平均)为4%左右.(2)关于认罪认罚情节,《量刑指导意见》给出的基础的从宽幅度为“减少基准刑的30%以下”(具有其他从宽条件的,这一幅度也可以进一步增大).根据我们的计算结果,认罪认罚的从宽幅度(平均)为11%左右.

5 结语

信息技术正在以前所未有的深度和广度助力法治中国建设,对司法大数据的分析利用也成为目前

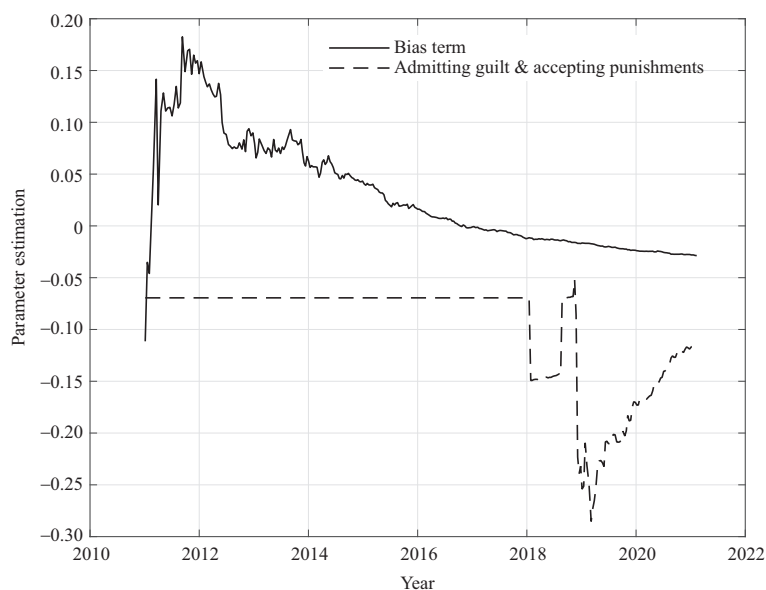


图 3 S-模型部分关注变量变化趋势 (2011~2021)

Figure 3 Variation tendency in S-model (2011~2021)

广泛关注的热点。法治场景的数据分析特别需要建立在可解释性与可靠性的基础上。然而,目前相关研究在数学模型、计算方法和理论保证等方面,还存在许多基本问题需要研究解决,迫切需要信息科学与法学研究的实质性交叉融合。特别地,需要构建符合法律基本逻辑的具有可解释性的数学模型,提出相应的新的数据分析算法,给出关于计算结果可靠性的理论保证,为科学立法和公正司法等提供更加可靠的决策支撑。在上述背景下,我们根据《刑法》和《量刑指导意见》给出的法逻辑,针对故意伤害罪建立了非线性量刑模型(S-模型),并利用我们建立的非线性递推辨识理论,对近20万判决数据进行计算分析和刑期预测。在模型创新方面,我们建立的S-模型体现了量刑逻辑过程所固有的非线性饱和特性,具有针对性和可解释性;在理论保证方面,我们运用非线性递推辨识理论,给出了在有限数据样本下对量刑要素辨识结果的可靠性估计;在计算效果方面,利用故意伤害罪刑事判决数据进行检验,发现与传统线性模型相比,基于法逻辑建立的S-模型的计算结果更符合量刑的基本规则和法定预期,具有更好的预测能力,体现出非线性量刑模型的优越性与非线性递推辨识理论的有效性。此外,在具体计算中也发现了一些值得进一步探讨的问题。作者认为,本文建立的模型和所利用的理论,可以推广至我国刑法各罪的量刑分析与预测,具有基础性意义。

致谢 作者感谢最高人民法院司法大数据研究院提供的判决数据支持,感谢中国科学院数学与系统研究院刘念和甘叠的讨论和帮助。

参考文献

- 1 Bai J J. Sentencing prediction research based on judges' collective experience. *Chin J Law*, 2016, 6: 140-154 [白建军. 基于法官集体经验的量刑预测研究. *法学研究*, 2016, 6: 140-154]
- 2 Zuo W M. Practice mechanism of sentencing suggestion: empirical research and theoretical reflection. *Contemporary Law Rev*, 2020, 4: 47-54 [左卫民. 量刑建议的实践机制: 实证研究与理论反思. *当代法学*, 2020, 4: 47-54]

- 3 Chu H L, Sun S M, Wei J. The effect for anti-corruption of trial in a non-resident area court: an empirical study of judicial judgments. *Tsinghua Univ Law J*, 2018, 4: 23–34 [褚红丽, 孙圣民, 魏建. 异地审理与腐败惩罚: 基于判决书的实证分析. *清华法学*, 2018, 4: 23–34]
- 4 Tang Y M, Liu Z. Do trial lives influence fairness? An empirical study of a court in China's western region. *Tsinghua Univ Law J*, 2021, 5: 146–162 [唐应茂, 刘庄. 庭审直播是否影响公正审判?——基于西部某法院的实验研究. *清华法学*, 2021, 5: 146–162]
- 5 Wang F. Compensation's effects on punishments and the reasonable control in criminal lawsuits. *Legal Forum*, 2020, 3: 95–103 [王芳. 刑事诉讼中积极赔偿对量刑的影响及其合理控制研究. *法学论坛*, 2020, 3: 95–103]
- 6 Wang F, Gan D, Liu N. A study on impact of leniency on sentencing for suspects admitting guilt & accepting punishments-based on data of misdemeanor crime of intentional injury. *J Shandong Univ (Philos Soc Sci)*, 2022, 3: 65–77 [王芳, 甘叠, 刘念. 认罪认罚量刑从宽实效研究 – 基于故意伤害罪轻罪的数据解读. *山东大学学报 (哲学社会科学版)*, 2022, 3: 65–77]
- 7 Surden H. Machine learning and law. *Washington Law Rev*, 2014, 89: 87–115
- 8 Kleinberg J, Lakkaraju H, Leskovec J, et al. Human decisions and machine predictions. *The Quart J Econ*, 2018, 133: 237–293
- 9 Berk R A, Sorenson S B, Barnes G. Forecasting domestic violence: a machine learning approach to help inform arraignment decisions. *J Empirical Legal Studies*, 2016, 13: 94–115
- 10 Medvedeva M, Vols M, Wieling M. Using machine learning to predict decisions of the European Court of Human Rights. *Artif Intell Law*, 2020, 28: 237–266
- 11 Lyu Y, Wang Z, Ren Z, et al. Improving legal judgment prediction through reinforced criminal element extraction. *Inf Processing Manage*, 2022, 59: 102780
- 12 Huang Y X, Dai W Z, Yang J, et al. Semi-supervised abductive learning and its application to theft judicial sentencing. In: *Proceedings of IEEE International Conference on Data Mining*, 2020. 1070–1075
- 13 Zhang L T, Guo L. Adaptive identification with guaranteed performance under saturated-observation and non-persistent excitation. 2022. [ArXiv:2207.02422](https://arxiv.org/abs/2207.02422)
- 14 张明楷. *刑法学*. 第6版. 北京: 法律出版社, 2021
- 15 Guo L. Estimation, control, and games of dynamical systems with uncertainty. *Sci Sin Inform*, 2020, 50: 1327–1344 [郭雷. 不确定性动态系统的估计, 控制与博弈. *中国科学: 信息科学*, 2020, 50: 1327–1344]
- 16 Guo L. *Time-Varying Stochastic Systems: Stability and Adaptive Theory*. 2nd ed. Beijing: Science Press, 2022. 155 [郭雷. *时变随机系统: 稳定性与自适应理论*. 第二版. 北京: 科学出版社, 2022. 155]

Applications of nonlinear recursive identification theory in sentencing data analyses

Fang WANG¹, Lantian ZHANG² & Lei GUO^{2*}

1. *Data Science Institute, Shandong University, Jinan 250100, China;*

2. *Academy of Mathematics and Systems Science, Chinese Academy of Sciences, Beijing 100190, China*

* Corresponding author. E-mail: lguo@amss.ac.cn

Abstract Judicial data have become an important base for empirical legal studies and the construction of smart court systems. Thus, the interpretability and reliability of the computation results become increasingly important. Therefore, we established a new theory of nonlinear recursive identification and applied it to sentencing data analyses. Specifically, based on the criminal law and sentencing guidelines, we established a nonlinear stochastic model for sentencing, to which the corresponding nonlinear recursive identification theory is applied with a specified finite length of data, which is nearly 200000 judgment documents of the crime of intentional injury. Compared with the traditional linear regression model and the least squares algorithm, the computation results given by the nonlinear recursive identification theory are more consistent with the basic principles and rules of sentencing, can reflect the effects and changes of sentencing factors more accurately, and exhibit better prediction ability.

Keywords nonlinear model, recursive identification algorithm, identification accuracy guarantee, sentencing, crime of intentional injury, judicial documents data