

基于概率图模型的危险驾驶罪刑期预测

陈鸿旭¹, 陈铁今¹, 王皓¹, 田维², 胡兵¹, 王竹³

(1. 四川大学数学学院, 成都 610064; 2. 西南石油大学法学院, 成都 610500; 3. 四川大学法学院, 成都 610207)

摘要: 针对司法实践中对于可解释性及预测性能的需求, 本文提出了一种基于概率图模型的量刑智能辅助方法. 该方法以量刑要素为基石建立含有隐节点的概率图模型, 由极大似然准则估计刑期分布的参数, 进而计算分布的数学期望得到预测值. 关于危险驾驶罪的实验结果表明, 概率图模型的预测准确率优于决策树和神经网络等对比模型, 且具有良好的可解释性.

关键词: 概率图模型; 刑期预测; 危险驾驶罪; 量刑要素

中图分类号: O29 **文献标识码:** A **DOI:** 10.19907/j.0490-6756.2022.061002

Prison term prediction of dangerous driving based on probabilistic graphical model

CHEN Hong-Xu¹, CHEN Tie-Jin¹, WANG Hao¹, TIAN Wei², HU Bing¹, WANG Zhu³

(1. School of Mathematics, Sichuan University, Chengdu 610064, China;

2. School of Law, Southwest Petroleum University, Chengdu 610500, China;

3. School of Law, Sichuan University, Chengdu 610207, China)

Abstract: To satisfy the actual demand for interpretability and prediction accuracy in judicial practice, we in this paper propose an intelligent sentencing method based on the probabilistic graphical model (PGM). This method is built on the cornerstone of sentencing factors. The parameters are estimated by using the maximum likelihood criterion, and the predicted value is obtained by calculating the mathematical expectation of distribution. Experimental result on dangerous driving shows that the prediction accuracy of the method is better than that based on comparison models, such as decision tree and neural network. Meanwhile, this method has good interpretability as well.

Keywords: Probabilistic graphical model; Prison term prediction; Dangerous driving; Sentencing factor

1 引言

随着量刑规范化改革的不断深入, 刑事量刑逐渐趋向规范化和精细化, 传统的“估堆式”量刑的弊端得以逐步消解, 这极大地推动了刑事司法的公开、公正与高效, 进一步维护了刑事司法的廉洁性. 已取得的成效让我们对量刑规范化寄予了更大的期待, 同时大家也在反思如何挣脱传统量刑理论与

技术的桎梏, 使量刑规范化发展进入新的快车道. 当下, 人工智能技术在计算机视觉、自然语言处理等许多领域取得了令人瞩目的成就. 法院信息化建设和计算法学等交叉学科的兴起^[1]为司法智能化的快速发展提供了新契机, 同时也为量刑规范化开拓了新视野. 利用人工智能技术辅助量刑, 进一步解决“案多人少”和“类案不同判”等传统问题已成为刑事司法领域的热点^[2].

收稿日期: 2020-12-23

基金项目: 国家重点研发计划(2018YFC0830300)

作者简介: 陈鸿旭(1998-), 男, 山东滨州人, 硕士研究生, 主要研究方向为机器学习. E-mail: chenhongxuzzz@foxmail.com

通讯作者: 田维. E-mail: 418818347@qq.com

刑事案件的判决预测主要包含法条推荐、罪名预测和刑期预测等三个子任务^[3]。通常,人们将判决预测任务作为文本分类问题,应用极端随机树^[4]、支持向量机^[5]等传统机器学习模型分类。近年来,随着深度学习的崛起,判决预测的研究重心逐渐转向深度学习模型^[6-11]。例如,文献^[6]提出了一种同时预测法条和罪名的、基于注意力机制的神经网络,文献^[7-9]关注了判决预测子任务之间的拓扑结构或文本中含有的法律语义信息,文献^[10, 11]通过增加门控结构、混合深度神经网络等方法提高模型的预测准确率。然而,基于深度学习的端到端的方法在可解释性方面有所不足。此外,量刑指导意见等规范性文件还为司法审判过程提供了大量的先验知识,而这些结构化的先验知识却难以在神经网络中得到体现。同时,通过人工智能技术辅助量刑规范化需要更高的可解释性,在模型中引入更多的先验知识。

概率图模型通过对条件独立性进行建模,可以直观地表示推理过程,刻画联合分布与边缘分布。经过几十年的发展,概率图模型已被广泛应用于机器学习^[12]、自然语言处理^[13]、计算机视觉^[14]等领域,成为人工智能发展必不可少的一类关键技术^[15]。司法审判作为典型的人类推理活动,遵循制定好的模式章程,有利于应用概率图对这一过程进行建模。

本文提出了一种基于概率图的刑期预测方法,并在危险驾驶罪上进行了实验。后续内容组织如下。第二部分介绍概率图模型的构建过程,提出基于量刑要素的建模方法,讨论如何应用极大似然准则学习模型的参数。第三部分中我们选取了四川地区危险驾驶罪的案例进行实验,并与决策树、SVM和神经网络等方法进行了对比。最后,第四部分对全文进行总结并讨论本文工作的后续改进和发展方向。

2 刑期预测模型

本文提出的基于概率图量刑智能辅助模型如图 1 所示。模型的具体流程如下:(i)对输入判决书根据正则表达式进行要素提取,得到案例的要素向量表示;(ii)将要素向量作为概率图的输入,通过隐节点对数据进行降维,在条件概率表的参数给定的情况下对不同输入求解其刑期分布的数学期望或概率最大值作为刑期的预测值。

2.1 量刑要素

量刑要素是对量刑起关键作用的事实因素,可分为法定要素和酌定要素,能够调和法定刑与基准刑之间的矛盾。以基准刑为基础,综合考量量刑要素的制约,便可得出宣告刑,这是量刑要素在量刑规律中的功能所在^[16]。

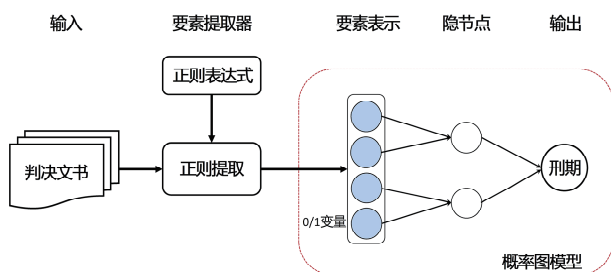


图 1 模型流程图

Fig. 1 Flow chart of the model

相比于民事案件,刑事案件判决书中的表述更规范,从而可以用较为有限的正则表达式对量刑要素进行匹配^[17]。应用正则表达式提取要素的部分主要为判决书中描述案件事实的部分,当出现“经审理查明”或“本院认为”等字样时,认为该自然段为事实部分,若无类似的关键字样,则可对检察院指控部分进行要素匹配。

对于危险驾驶罪,由法条中明确规定的法定要素和法学专家给出的酌定要素,有如表 1 所示的量刑要素表(部分)。

2.2 概率图模型构建

假设某罪名下的量刑要素数量为 N ,则经过要素提取后的案例可用 N 维的向量表示:

$$X = [x_1, x_2, x_3, \dots, x_N] \in \mathbf{R}^{1 \times N} \quad (1)$$

其中每个分量 x_i 代表此案例是否含有相应的要素, $x_j = 1$ 代表案例中含有此要素, $x_j = 0$ 代表不含此要素,即 X 的每个分量均为 0/1 变量。

建立概率图模型最简单的方式是密集连接,即将所有量刑要素假设为独立的,并直接与刑期相连接,但这种做法会使得模型参数量指数级上升。以危险驾驶罪为例,共有 143 个量刑要素,刑期取值为 1~6 个月,参数总数为 $2^{143} \times 6$ 。毫无疑问,这是不现实的。所以我们要先根据要素出现的频率及其相关性分类,增加模型的深度以减少参数量。

量刑活动是一个动态过程,需要综合考量犯罪人在犯罪行为实施前、犯罪行为实施过程中及犯罪人的一系列情节和因素,最终得出对犯罪人的宣告刑。基于量刑活动的基本规律和客观特征,我们以

罪前、罪中、罪后作为分类依据对相关要素进行分类, 设置隐节点, 最终得到一个含有隐节点的三层树结构概率图模型。

表 1 部分危险驾驶罪的量刑要素

Tab. 1 Some sentencing factors of dangerous driving

隐节点分类依据	隐节点	量刑要素
危险驾驶情形		饮酒驾驶(20~80 mg/100 mL)
		醉酒驾驶(80~200 mg/100 mL)
		醉酒驾驶(200 mg/100 mL 以上)
罪中
事故责任		犯罪主体负主要责任
		犯罪主体负全部责任
		犯罪主体负直接责任
刑事责任能力		完全刑事责任能力
		限制刑事责任能力
		无刑事责任能力
罪前	累犯及前科	前科
		一般累犯
		特殊累犯
		...
罪后	法定从轻情节	坦白
		自首
		主动取得被害人谅解
		...

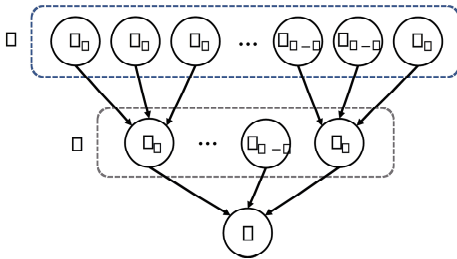


图 2 量刑预测概率图模型

Fig. 2 Probabilistic graphical model for the prison term prediction

如图 2 所示, X 为量刑要素, Y 表示刑期, Z 是具有明确法律语义的隐节点, 皆为离散的随机变量。对于不同的罪名, X 与 Z 有不同的语义信息, 下标 N 与 M 为不同罪名下节点的数目。在危险驾驶罪中, X 为醉酒驾驶、坦白、自首等要素, Z 表示危险驾驶情形、造成后果、法定从轻情节等。

考虑最简单的确定隐节点 Z 的方式, 由 X 的某些分量经过线性组合确定性地得到 Z 的值。对于 Z 的每一个分量 $z_k (k=1, 2, \dots, M)$, 其对应着 x_j 的某个下标集合, 我们用 L_{z_k} 来表示。则每个 z_k 可由如下公式计算:

$$z_k = \sum_{j \in L_{z_k}} \omega_j \cdot x_j \quad (2)$$

其中 ω_j 为 x_j 的权重, 一般取为整数值, 可由法学专家或根据量刑指导意见确定其取值。

含有隐节点的概率图模型的推断与参数估计一直以来都是概率图模型中较难处理的部分, 特别是像本文中参数量非常大的密集连接结构。虽然 EM 算法与采样是解决数据缺失或含隐变量参数估计的方法, 但会大大增加计算复杂度, 且 EM 算法初值的选取会影响模型最终的收敛结果。

2.3 参数学习及推断

图 2 中所建立的概率图模型可以简写为: $X \rightarrow Z \rightarrow Y$ 。又因为 $X \rightarrow Z$ 为线性映射, 超参数由人工给出, 所以我们需要关注的条件概率只有 $P(Y|Z)$ 。

假设训练集 D 有 d 个样本, 每个样本可以表示为二元对 $\langle Z[i], y[i] \rangle$ (因为隐节点 Z 由要素 X 确定性地计算得到, 所以每个训练样本可看作隐节点 Z 与刑期 Y 的三元对), 我们使用极大似然原则对参数进行估计。刑期 Y 的取值为从 1 到 m 的整数值, 隐节点 Z 的取值不妨设为 J 个: Z_0, \dots, Z_{J-1} 。令 θ 表示条件概率表中的所有参数的集合, $\theta_{Y|Z}$ 表示刻画条件概率 $P(Y|Z)$ 的所有参数, $\theta_{Y|Z_0}$ 表示集合 $\theta_{1, Z_0}, \dots, \theta_{m, Z_0}$, 其中 θ_{k, Z_0} 为条件概率表中刻画 $Z=Z_0$ 时 $Y=k$ 的概率大小的参数。

案例样本可视为 d 次独立实验, 故有极大似然函数

$$L(\theta; D) = \prod_i P(Z[i], y[i]; \theta) \quad (3)$$

将联合分布拆分为条件概率的乘积:

$$L(\theta; D) = \prod_i P(Z[i]; \theta) P(y[i] | Z[i]; \theta) \quad (4)$$

交换乘积的顺序, 上述公式可以等价地写为

$$L(\theta; D) = \left(\prod_i P(Z[i]; \theta) \right) \left(\prod_i P(y[i] | Z[i]; \theta) \right) \quad (5)$$

这样一来, 似然函数被分解为两项, 分别对应于随机变量 Z 和 Y 。进一步, 每一项都是一个局部似然函数, 用于测量变量在给定其父节点的情况下的预测程度。

现在, 我们分别考虑公式(5)中的两项。第一项 $\prod_i P(Z[i]; \theta)$ 取决于数据集中变量 Z 的取值情况。因为数据集是给定的, 可将此项视为常数。第二项可进一步分解为

$$\prod_i P(y[i] | Z[i]:\theta_{Y|Z}) = \prod_{i:Z[i]=Z_0} P(y[i] | Z[i]:\theta_{Y|Z}) \cdots \prod_{i:Z[i]=Z_{j-1}} P(y[i] | Z[i]:\theta_{Y|Z}) = \prod_{i:Z[i]=Z_0} P(y[i] | Z[i]:\theta_{Y|Z_0}) \cdots \prod_{i:Z[i]=Z_{j-1}} P(y[i] | Z[i]:\theta_{Y|Z_{j-1}}) \quad (6)$$

我们可以使用充分统计的概念进一步简化公式,以上述公式中第一项为例,有

$$\prod_{i:Z[i]=Z_0} P(y[i] | Z[i]:\theta_{Y|Z_0}) \quad (7)$$

我们将注意力放在满足条件 $Z=Z_0$ 的数据上,这些数据根据 $y[i]$ 的取值又可分为 m 类,可以由其中满足 $y[i]=k$ 的数据来估计得到参数 θ_{k,Z_0} . 将满足条件 $Y=k, Z=Z_0$ 的样本数记为 $M(Y=k, Z=Z_0)$, 满足条件 $Z=Z_0$ 的样本数记为 $M(Z=Z_0)$. 公式(7)等价于

$$\prod_{i:Z[i]=Z_0} P(y[i] | Z[i]:\theta_{Y|Z_0}) = \theta_{1,Z_0}^{M(Y=1,Z=Z_0)} \cdots \theta_{m,Z_0}^{M(Y=m,Z=Z_0)} \quad (8)$$

注意到对分布 $P(Y|Z_0)$ 有 $\sum_{j=1}^m \theta_{j,Z_0} = 1$, 极大化公式(8)的似然函数等价于极大化取对数后的似然函数,即

$$\max \log(\theta_{1,Z_0}^{M(Y=1,Z=Z_0)} \cdots \theta_{m,Z_0}^{M(Y=m,Z=Z_0)}) \text{ s. t.}$$

$$\sum_{j=1}^m \theta_{j,Z_0} = 1.$$

对于此约束优化问题,由拉格朗日乘法有

$$F = \sum_{j=1}^m M(Y=j, Z=Z_0) \log(\theta_{j,Z_0}) + \lambda(1 - \sum_{j=1}^m \theta_{j,Z_0}) \quad (9)$$

对 θ 求导,令偏导数为零有

$$\frac{\partial F}{\partial \theta_{k,Z_0}} = \frac{M(Y=k, Z=Z_0)}{\theta_{k,Z_0}} - \lambda = 0 \quad (10)$$

则有 θ_{k,Z_0} ($k=1, \dots, m$) 的极大似然估计

$$\theta_{k,Z_0} = \frac{M(Y=k, Z=Z_0)}{\lambda} \quad (11)$$

又由 $\sum_{j=1}^m \theta_{j,Z_0} = 1$ 易得 $\lambda = \sum_{j=1}^m M(Y=j, Z=Z_0)$, 所以有最终的参数估计

$$\theta_{k,Z_0} = \frac{M(Y=k, Z=Z_0)}{\sum_{j=1}^m M(Y=j, Z=Z_0)} = \frac{M(Y=k, Z=Z_0)}{M(Z=Z_0)} \quad (12)$$

当模型的参数确定后,根据条件概率表在概率图上进行推断也就是给定 X 的取值去预测 Y 的取值. 主要方式有两种,第一种为求解概率最大值

$$\hat{y} = \max_y P(y | X), \quad (13)$$

第二种为求数学期望

$$\hat{y} = E[P(y | X)] = \sum_y y \cdot P(y | X) \quad (14)$$

因为刑期均为整数,一般将数学期望取整作为预测值.

值得注意的是,测试集中部分案例的隐节点取值 Z_c 在训练集中并未出现过,即 $M(Z=Z_c) = 0$. 此时(12)式的分母为 0, 条件概率表中不存在 $Z=Z_c$ 的参数. 我们计算条件概率表中与 Z_c 最接近的向量 $Z_{\min} = \operatorname{argmin}_{Z \in CPT} \|Z - Z_c\|_2$, 并将 $Z=Z_{\min}$ 的参数近似作为 $Z=Z_c$ 的参数,从而估计刑期.

3 实验结果与分析

3.1 实验数据集

在数据获取的过程中,我们考虑地域对判决的影响. 由于地域差异和民族差异,不同地方省级人民法院制定的量刑指导意见存有差异,案件的刑期分布也随之有所不同. 因而本文首先立足于本地,实验所用数据集为四川省的判决案例.

最高人民法院发布 2019 年上半年审判执行工作数据显示,2019 年上半年全国法院审结的刑事案件中,数量最多、占比最大的 5 类罪名分别是:危险驾驶罪,盗窃罪,走私、贩卖、运输、制造毒品罪,故意伤害罪,诈骗罪. 危险驾驶罪系《刑法修正案(八)》所设立的新罪. 该罪名近年来呈现出非常高发的态势,大有取代“两抢一盗”等传统犯罪成为我国发案率最高的刑事犯罪. 并且,本罪广受社会关注,且在理论研究和司法实践中饱受争议,在我国现阶段的刑事立法中非常具有代表性. 因此,我们特别选取了危险驾驶罪为实验罪名,共收集了 4969 个案例,其中随机选取 4000 个案例作为训练集,696 个案例作为测试集.

3.2 实验设计

为测试概率图模型在预测性能上的表现,我们选取决策树、随机森林、支持向量机和神经网络作为对比模型.

- 决策树:决策树是常用的分类模型,符合人类对问题处理的自然过程,具有较好的可解释性^[18].
- 随机森林:随机森林是决策树的扩展变体,

包含多个决策树并在训练过程中引入了随机属性选择^[19].

- 支持向量机(SVM): 支持向量机可以通过超平面训练一个二分类的分类器. 更一般地, 使用核方法可以有效地进行非线性分类. 文献[5, 6, 8]将 SVM 作为法律判决预测的主要模型或对比模型. 本文中使用了线性核.

- 神经网络: 本文中使用的神经网络为全连接的前馈神经网络. 为保证神经网络与概率图模型在参数等量级上具有可比性, 我们使用的神经网络大小为 143-50-10-1.

概率图模型的优势在于能够刻画刑期分布, 从而跳出分类模型的框架. 为更好体现这种优势, 本文中选取的预测刑期的方式为求解数学期望, 即公式(14), 决策树、随机森林与 SVM 均使用 scikit-learn^[20]实现, 神经网络由 pytorch^[21]实现.

3.3 评价指标及实验结果分析

危险驾驶罪的刑期为 1~6 个月, 即参数 $m = 6$. 假设案例中给出的宣告刑 y 为准确的刑期. 考虑到法官具有自由裁量权, 我们取预测值 \hat{y} 与准确值 y 误差不超过一个月为预测预测正确的标准, 即

$$S_i = \begin{cases} 1, & |y_i - \hat{y}_i| \leq 1, \\ 0, & |y_i - \hat{y}_i| > 1 \end{cases} \quad (15)$$

$$S = \frac{1}{d} \sum_{i=1}^d S_i \quad (16)$$

表 2 实验结果

Tab. 2 Experimental result

预测方法	准确率/%
	均值(±标准差)
决策树	83.20(±1.47)
随机森林	83.73(±1.92)
SVM	89.78(±0.93)
神经网络	88.29(±1.42)
概率图	90.46(±1.14)

对所有模型进行 10 次试验取平均, 得到表 2 和图 3 所示的实验结果. 图 3 所绘的箱线图为 10 次试验中各模型预测准确率, 从上到下依次为最大值、上四分位数、中位数、下四分位数和最小值. 由表 2 和图 3 可知, 概率图的预测性能远优于决策树与随机森林, 优于支持向量机与神经网络, 同时具有较小的方差. 概率图模型刻画了刑期分布, 在预

测过程中计算数学期望而不仅仅将刑期预测作为分类任务, 在一定程度上起到了去噪的作用, 提高了预测准确率.

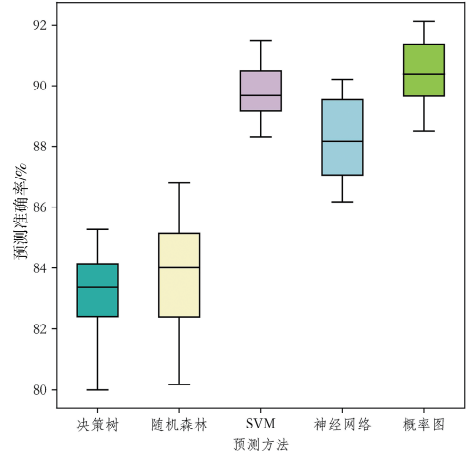


图 3 不同预测方法准确率的比较

Fig. 3 Comparison of the accuracy of different methods

4 结论

法院信息化建设的不断完善为量刑智能辅助技术研究提供了数据支撑. 本文提出的基于概率图模型的量刑预测技术通过正则表达式提取关键的量刑要素, 将文本表示为要素的向量化表达, 在量刑要素的基础上建立含有隐节点的概率图模型, 并根据极大似然准则估计条件概率表的参数, 得到不同条件下的刑期分布, 最终计算量刑预测值. 实验结果表明, 概率图模型在预测误差不超过一个月的标准下达到了 90% 的准确率, 优于决策树、SVM、神经网络等对比模型. 同时, 概率图模型具有更好的可解释性.

本文提出的刑期预测概率图模型框架具有普适性, 在其它罪名上亦可建立类似的概率图模型. 我们相信, 此类模型框架能够反映当下刑事量刑的客观规律, 回避基准刑、量刑情节在社会科学研究中所展现出的困境, 对于刑事量刑具有重大的辅助价值.

参考文献:

- [1] 张妮, 蒲亦非. 计算法学: 一门新兴学科交叉分支[J]. 四川大学学报: 自然科学版, 2019, 56: 1187.
- [2] 张勇. 人工智能辅助办案与量刑规范化的实现路径[J]. 上海政法学院学报(法治论丛), 2019, 34: 108.
- [3] Xiao C, Zhong H, Guo Z, et al. Cail2018: a large-scale legal dataset for judgment prediction [EB/

- OL]. [2020-12-13]. <https://www.arxiv.org/pdf/1807.02478.pdf>.
- [4] Katz D M, Bommarito II M J, Blackman J. Predicting the behavior of the supreme court of the united states: a general approach [EB/OL]. [2020-12-13]. <https://www.arxiv.org/pdf/1407.6333.pdf>.
- [5] Sulea O M, Zampieri M, Malmasi S, *et al.* Exploring the use of text classification in the legal domain [EB/OL]. [2020-12-13]. <https://www.arxiv.org/pdf/1710.09306.pdf>.
- [6] Luo B, Feng Y, Xu J, *et al.* Learning to predict charges for criminal cases with legal basis [C]// Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. Stroudsbury: ACL, 2017.
- [7] Hu Z, Li X, Tu C, *et al.* Few-shot charge prediction with discriminative legal attributes [C]// Proceedings of the 27th International Conference on Computational Linguistics. Stroudsbury: ACL, 2018.
- [8] Zhong H, Guo Z, Tu C, *et al.* Legal judgment prediction via topological learning [C]// Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Stroudsbury: ACL, 2018.
- [9] Long S, Tu C, Liu Z, *et al.* Automatic judgment prediction via legal reading comprehension [C]// China National Conference on Chinese Computational Linguistics. New York: Springer, 2019.
- [10] Chen H, Cai D, Dai W, *et al.* Charge-based prison term prediction with deep gating network [C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Stroudsbury: ACL, 2019.
- [11] 王文广, 陈运文, 蔡华, 等. 基于混合深度神经网络模型的司法文书智能化处理[J]. 清华大学学报: 自然科学版, 2019, 59: 505.
- [12] Koller D, Friedman N. Probabilistic graphical models: principles and techniques [M]. Cambridge: MIT Press, 2009.
- [13] Blei D M, Ng A Y, Jordan M I. Latent Dirichlet allocation [J]. J Mach Learn Res, 2003, 3: 993.
- [14] Krähenbühl P, Koltun V. Efficient inference in fully connected crfs with Gaussian edge potentials [C]// Advances in Neural Information Processing Systems. Cambridge: MIT Press, 2011.
- [15] 张宏毅, 王立威, 陈瑜希. 概率图模型研究进展综述[J]. 软件学报, 2013, 24: 2476.
- [16] 姜涛. 认知、诠释与激活: 一个关于量刑规律的解释程式[J]. 江海学刊, 2011(1): 139.
- [17] 张静, 张妍. 正则表达式及其在信息抽取中的应用[J]. 电脑知识与技术, 2009, 5: 3867.
- [18] Breiman L, Friedman J, Stone C J, *et al.* Classification and regression trees [M]. Boca Raton: CRC Press, 1984.
- [19] 周志华. 机器学习 [M]. 北京: 清华大学出版社, 2016.
- [20] Pedregosa F, Varoquaux G, Gramfort A, *et al.* Scikit-learn: machine learning in Python [J]. JM-LR, 2011, 12: 2825.
- [21] Paszke A, Gross S, Massa F, *et al.* Pytorch: an imperative style, high-performance deep learning library [C]// Advances in Neural Information Processing Systems. Cambridge: MIT Press, 2019.

引用本文格式:

中文: 陈鸿旭, 陈铁今, 王皓, 等. 基于概率图模型的危险驾驶罪刑期预测[J]. 四川大学学报: 自然科学版, 2022, 59: 061002.

英文: Chen H X, Chen T J, Wang H, *et al.* Prison term prediction of dangerous driving based on probabilistic graphical model [J]. J Sichuan Univ: Nat Sci Ed, 2022, 59: 061002.