

基于迁移学习的适用法条推荐模型

杨超群¹, 庞彦燕², 严若冰², 张世全¹, 胡兵¹, 王竹²

(1. 四川大学数学学院, 成都 610064; 2. 四川大学法学院, 成都 610207)

摘要: 本文提出了一个基于法律事实的适用法条推荐模型. 作为应用, 本文选取了刑事诈骗罪和民事离婚纠纷两个案由的裁判文书数据集, 使用 FastText 模型, 并基于迁移学习方法从预训练的通用词向量出发训练法律词向量, 再以此为基础进行文本分类. 结果显示, 经过迁移学习后, 无论诈骗罪案件还是离婚纠纷案件均能做到对案情描述文本全面、准确地推荐适用法条, 特别是具有针对性的法规、司法解释等. 随着迁移学习模式的不断完善, 本文研究的方法还应该可进一步用于证据推送、量刑预测等.

关键词: 适用法条推荐; 文本分类; 人工智能; 迁移学习

中图分类号: O29 **文献标识码:** A **DOI:** 10.19907/j.0490-6756.2021.021001

A model for recommendation of applicable law articles based on transfer learning

YANG Chao-Qun¹, PANG Yan-Yan², YAN Ruo-Bing²,
ZHANG Shi-Quan¹, HU-Bing¹, WANG Zhu²

(1. School of Mathematics, Sichuan University, Chengdu 610064, China;
2. Law School, Sichuan University, Chengdu 610207, China)

Abstract: In this paper, we propose a model for recommendation of applicable law articles. As an application, the judgment documents data sets of fraud and divorce dispute are selected from criminal and civil cases. Based on transfer learning, the legal word vectors are trained from the pre-trained general word vectors by using the FastText model. Then the text is classified according to the well trained vectors. The simulation results show that for both the fraud and the divorce dispute, after the transfer learning, the applicable law articles can be recommended comprehensively and accurately for the case description text, especially for the targeted regulations and judicial interpretations. With the continuous improvement of the transfer learning mode, our model is expected to be further applied to the evidence pushing and sentencing prediction.

Keywords: Applicable law article; Text classification; Artificial intelligence; Transfer learning

1 引言

随着社会的发展, 诉讼案件越来越多, 使如何提高案件办理效率成为了一个亟待解决的问题. 人

工智能在司法领域的应用不断增加正好适应了提高诉讼效率的需求. 许多机器学习的模型和算法也开始应用到法律领域, 通过人工智能来为法官提供基础的司法辅助工作.

收稿日期: 2020-02-11

基金项目: 国家重点研发计划(2018YFC0830300)

作者简介: 杨超群(1997-), 男, 湖北随州人, 硕士生, 研究方向为数据科学与高性能计算. E-mail: 2019222010031@stu.scu.edu.cn

通信作者: 张世全. E-mail: shiquanzhang@scu.edu.cn

适用法条推荐实质上是一个多标签文本分类任务,最终要达到的效果是对一段描述案情的法律文本给出全面而准确的适用法条. 文本分类是自然语言处理中的经典任务. 传统的方法,如 N-gram^[1]方法在文本分类上已经取得了较好的结果. 近几年来,研究者开始使用机器学习的方法进行文本分类,如 doc2vec^[2],FastText^[3-4]和最近的 Bert^[5],XLNet^[6]和 ERNIE^[7]等. 同时,也有一些研究者在法律领域中尝试着使用文本分类,如 Xiao 等^[8]在大规模数据集上进行了罪名预测、法条推荐和刑期预测. 刘宗林等^[9]提出了一种多任务学习模型,对罪名预测和法条推荐进行联合建模. 王业沛等^[10]使用深度学习在裁判文书数据上提出了一个判决结果倾向性分析的模型,张虎等^[11]提出了基于多模型融合的法条推荐方法,等等.

上述模型中的罪名预测、法条推荐等均针对所有法律领域的文本. 本文则利用中国裁判文书网上对外公开的海量基础数据,聚焦于诈骗罪和离婚纠纷案件,以两个不同案由下的裁判文书共十余万份作为数据集,使用 FastText 模型对预训练的通用词向量进行迁移学习^[14]得到法律词向量,再用法律词向量构建文档向量进行文本分类.

2 数据集

本文使用的数据集包含已分段的诈骗罪案件裁判文书 58 999 份,共 696 M,离婚纠纷案件裁判文书 49 882 份,共 260 M. 裁判文书中大致分主体基本信息、原告诉求(公诉机关指控)、被告答辩(仅限民事案件)、法院查明事实、法院说理、裁判依据、裁判结果等 7 个部分.

就法条推荐而言,仅其中法院查明事实、说理、裁判依据部分是有研究价值的. 因此,本文使用上述裁判文书数据时,为了避免不必要信息的干扰首先对裁判文书的不同部分进行了分段,每份分段的裁判文书都能看做一张表,如表 1 所示. 其中第一列的数字代表第三列文本的类别,如[1]代表裁判文书的标题,[3]代表原告被告信息. 在数据预处理中,我们筛选使用了类别 5(原告诉称)、6(被告辩称)、7(法院认定事实)、8(法院说理部分)、9(裁判依据)和 16(裁判结果),其中类别 5、6、7、8 和 16 用于训练词向量,类别 7 和 8 用于构建文档向量,类别 9 用于提取每份文书对应的法条.

表 1 分段的裁判文书格式示例

Tab. 1 Example of segmented judgment documents

文段类别	段落序号	文本
[1]	1	张一 x 与杨 xx 离婚纠纷一案民事判决书
...
[3]	5	原告张一 x,...
[3]	6	被告杨 xx,...
4	7	原告张一 x 与被告杨 xx 离婚纠纷一案,...
...
9	13	综上,依据《中华人民共和国婚姻法》第三十二条...
16	14	规定,判决如下:...
16	15	驳回原告张一 x 的诉讼请求,...
...


FastText 模型原本仅适用于英文. 由于中文在每句话内部不存在分隔符,只是一串连续的汉字,故需要将句子拆分成词和空格相间分布的格式. 成熟的中文分词算法能够达到更好的自然语言处理效果,帮助模型理解复杂的中文语言. 本文在对中文语料库进行分词时,直接使用了已有较知名的分词工具——结巴分词对语料库进行分词处理. 为了提高分词的效果,这里还使用了清华大学开放中文词库^[12]中的法律词汇.

词条归一化(token normalization)是将表面看起来不完全一致的多个词条归纳成一个等价类,以便在它们之间进行匹配的处理过程. 例如,在一篇裁判文书中有这样一句话:“被告人张三某,男”,则在此文书全文中,“被告人”和“张三某”是等价的. 为了维持词之间好的关联,将“张三某”关联到“被告人”是很有必要的. 更重要的是,“被告人”在语料库的任何地方的地位都是一样的,而“张三某”可能在此处是被告人,到另一处则是原告人. 因而词条归一化提前消除了这些会误导模型的信息.

由于本文使用的是中文法律语料库,相比一般的语料库其涵盖的词面较窄,所以在进行词条归一化时,我们选取了其中较为重要的类别做归一化. 如将原被告的人名替换成原被告,将形如“xxx, 以下简称 x”等进行归一化.

每篇文书的类别 9 包含了对应案件所用到的全部法条,包括法律法规、司法解释等,这正是法条推荐所需要的标签. 为此,我们编写程序,从每篇裁判文书的类别 9 中提取出所有的法条,精确到条. 例如将“《中华人民共和国刑法》第二百六十六

条第一款”提取为“刑法 266”。这样共得到了诈骗罪案件相关法条 864 个, 离婚纠纷案件相关法条 872 个。图 1 以词云的形式给出了两类案件中的频率前两百的法条。



(a) 诈骗罪案件法条



(b) 离婚纠纷案件法条

图 1 两种案件的频率排名前两百位的法条^[13]

Fig. 1 Top two hundred law articles in the two cases

3 模型与实验结果

除了以上三种预处理手段, 我们还使用网络上公开的停用词表, 删去了语料库中标点符号、特殊字符和其他无实意的词语; 又删除了文档字数大于三万或小于两百五的极端情况的文书。经过前述处理, 我们得到诈骗罪案件文书 57 241 份, 其中词向量数据集 302 M, 文档分类数据集 237 M; 离婚纠纷案件文书 46 303 份, 其中词向量数据集 86.6 M, 文档分类数据集 47.5 M。对于文档分类模型, 在每类案件的文书中分别随机选取 2 000 件文书用作验证集和测试集, 剩余文书用于训练集。

3.1 FastText 模型

FastText 模型是 Facebook 公司于 2016 年开源的一个词向量计算^[3]和文本分类工具^[4]。在本节

中, 我们基于迁移学习的思想以 FastText 预训练的 4.2G 通用中文词向量为初始向量, 使用 FastText 词嵌入模型在词向量数据集上训练法律词向量, 再以此为初始向量, 使用 FastText 文档分类模型对文档分类数据集进行法条推荐。




图 2 FastText 模型的训练过程

Fig. 2 Training process of the FastText model

FastText 中包含两个词嵌入模型, 分别是 CBOV 模型和 Skip-Gram 模型, 其中 CBOV 模型利用给定的上下文预测目标词, 而 Skip-Gram 模型则是利用输入中心词来预测上下文。它们充分利用了词的上下文信息, 这里我们只选用了 Skip-Gram 模型来训练词向量。Skip-Gram 的模型结构如图 3 所示。




图 3 Skip-Gram 模型的结构

Fig. 3 Structure of the Skip-Gram model

假设文本序列是“公安机关查获电动车发还被受害人”, 以“查获”作为中心词, 背景窗口大小设为 2。Skip-Gram 模型所关心的是对中心词“查获”生成与它距离不超过两个词的背景词“公安”、“机关”、“电动车”和“发还”的条件概率, 即

$$P(\text{公安} | \text{查获}) \cdot P(\text{机关} | \text{查获}) \cdot$$

$$P(\text{电动车} | \text{查获}) \cdot P(\text{发还} | \text{查获}),$$

更一般地, 对长度为 T 的给定文本序列, 在时间步 t 的词的向量表示为 $w^{(t)}$ 。假设中心词给定的情况下背景词的生成是相互独立的, 则当背景窗口大小为 m 时对任意给定中心词, 生成所有背景词的条件概率为

$$\prod_{t=1}^T \prod_{-m \leq j \leq m, j \neq 0} P(w^{(t+j)} | w^{(t)}).$$

模型在词向量数据集上训练时利用了已有的词向

量结果,以便加快训练速度并得到更好的收敛结果,这里我们采用 FastText 模型预训练的 4.2 G 300 维词向量作为训练起始向量,训练 20 个 epoch 得到了法律词向量。

相比于词嵌入模型, FastText 文档分类模型原理较为简单,图 4 给出了模型的示意图. 它将每篇裁判文书的文档向量化为其中所有词向量的平均,经过一个隐藏层和 softmax 函数后的结果作为每个法条适用于此文书的条件概率,来计算模型预测出的法条和实际用到的法条之间的误差,并通过梯度下降更新模型的参数和词向量. 这样,文档向量同时也得到了更新。

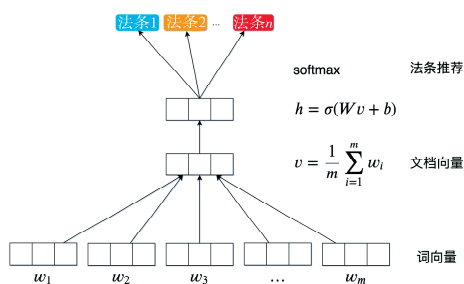


图 4 FastText 文档的分类模型结构

Fig. 4 Structure of the FastText document classification model

在训练时,我们使用第 2 节中构建的验证集作为 FastText 模型自动调参的输入,以微平均 F1 为自动调参的优化指标进行超参数的调节,使用微平均 F1 最高的一组超参数在训练集上训练. 利用训练好的模型,我们对测试集中的每个案件仅读取裁判文书中的 7(法院认定事实)和 8(法院说理部分)得到文档向量,计算每个法条与它的条件概率,并将大于阈值的法条作为该案件的适用法条推荐. 对于模型自动推荐的法条,我们通过与裁判文书中法官实际使用的法条(分段 9 裁判依据)对比来计算推荐法条的准确率和召回率。


3.2 结果分析

通过在词向量数据集和文档分类数据集上的训练,我们得到了两组词嵌入模型和文档分类模型,分别适用于诈骗罪案件和离婚纠纷案件. 在图 5 中,我们分别选取了诈骗罪案件和离婚纠纷案件的词向量列表中前 300 的词,使用 TSNE 将每个词的 300 维词向量投影到二维. 可以看出,词性词义相似的词会有相近的分布。

在表 2 中,我们对给定中心词 w_c 使用余弦相似度

$$\text{similarity}(w_c, w_i) = \frac{v_c \cdot v_i}{\|v_c\| \|v_i\|}$$

找出最邻近的 5 个词. 可以看出,相同的初始词和相同的模型,在数据集不同的情况下通过迁移学习得到了不同的结果. 在初始状态下,中心词和邻近词只是词义词性相近,而中心词对邻近词是没有“偏好”的. 分别通过诈骗罪案件数据集和离婚纠纷案件数据集训练后,中心词和邻近词的词义词性有所区别,但在邻近词的“偏好”上则体现了各自案件类型的特点. 这一现象表明通过对不同类型案件裁判文书的文本进行学习后所产生的向量是具备一定特殊性、针对性的。



(a) 诈骗罪案件 (b) 离婚纠纷案件

图 5 两种案件中词向量的二维投影

Fig. 5 Two-dimensional projection of the word vectors in the two cases

表 2 不同数据集下部分词与其邻近 5 个词

Tab. 2 Words in different data sets and their neighboring 5 words

关系	關係 关联 之间 关系 处好
初始	短信息 短息 iUU 短消息 彩信
双方	雙方 对方 两方 检辩 两军
关系	朋友 办事 生意 之间 母亲
诈骗	短信 发送 电话 基站 伪 诈骗
双方	协商 审理 认定 妻子 报案
关系	结婚 登记 相识 家庭 夫妻感情
离婚	手机短信 微信 短信量 发送 微信内
双方	离婚 被告 婚后 夫妻感情 原告

下文给出了一段分词后诈骗罪案件的裁判文书,当条件概率阈值取为 0.5 时,模型对此文本预测的法条为刑法 266 刑法 67 刑法 64 办理诈骗刑事案件具体应用法律若干问题的解释 1. 该段描述性文字通过本文采用的模型进行分析学习后,不仅准确地预测推荐了刑法第 266 条诈骗罪的法律条文,而且全面地预测推荐了更具有针对性的司法解释——《关于办理诈骗刑事案件具体应用法律若干问题的解释》第 1 条. 此法条是关于诈骗罪量刑标

准的金额确定,法官看到推荐的这条司法解释就能非常迅速地作出量刑裁判。

上述事实 被告 开庭审理 过程中 无异议 物证 手机 部 被害人 黄某 陈述 证人 辛某 彭某 唐某 证言 书证 归案 情况 户籍 证明 通话记录 微信 聊天记录 截图 陌陌 聊天 记录 截图 银行 流水 随案移送 物品 清单 刑事判决书 辨 认 笔录 监控 录像 被告 供述 证据 证实 足以认定 本院 认为 被告 非法占有 为目的 虚构事实 骗取 人财物 数额较大 其行 诈骗罪 公诉机关 指控 罪名 成立 本院 应予 支持 被告 涉嫌 犯罪 强制措施 期间 实施 犯罪行为 主观 恶性 社会 危害性 较大 酌定 从重 处罚 鉴于 被告 自愿 认罪 如实 供 述 犯罪 事实 悔罪 表现 酌情 从轻 处罚

表 3 给出了模型在诈骗罪案件和离婚纠纷案件测试集上的结果,其准确率 P 和召回率 R 由如下公式给出:

$$P = \frac{\sum_{i=1}^N TP_i}{\sum_{i=1}^N TP_i + \sum_{i=1}^N FP_i},$$

$$R = \frac{\sum_{i=1}^N TP_i}{\sum_{i=1}^N TP_i + \sum_{i=1}^N FN_i},$$

其中 TP_i 表示模型预测出法条 i 且法条 i 确为适用法条, FP_i 表示模型预测出法条 i 但法条 i 不是适用法条, FN_i 表示模型未预测出法条 i 但法条 i 为适用法条。

表 3 不同条件概率阈值下的准确率与召回

Tab. 3 Precision and recall under different conditional probability thresholds

	$P_{0.6}$	$R_{0.6}$	$P_{0.5}$	$R_{0.5}$	$P_{0.4}$	$R_{0.4}$
离婚	0.894	0.734	0.874	0.769	0.853	0.8
诈骗	0.927	0.522	0.902	0.561	0.868	0.6

显然,模型在两类案件上准确率都明显高于召回率. 离婚纠纷案件的准确率要稍高于诈骗罪案件,但离婚纠纷案件的召回率显著低于诈骗罪案件的召回率,这可以由图 6 给出解释. 图中“高频到低频”线上第 i 个点表示将此类案件所有法条按频数从高到低排序,前 i 个法条的频数和占总频数和的比例,“低频到高频”线上的点有对应定义. 为突出主要部分,我们只展示了两种排列首尾各 50 个法条的对应值,图中中间的跳跃部分为省却的法条。

另外,图中两条“高频到低频”线的交点的值为 91.1%,对应的两条“低频到高频”线的交点的值为 8.9%。这表明高频法条分布中离婚纠纷案件的被

少数几个法条占据主导地位,这有助于预测出的法条中有更多正确的法条,即离婚纠纷案件的准确率要稍高于诈骗罪案件。

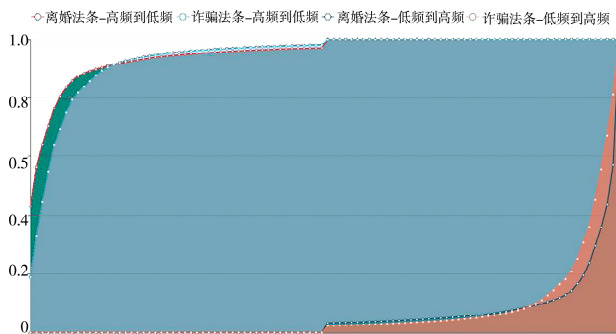


图 6 法条频数分布^[13]

Fig. 6 Distribution of the law articles' frequency^[13]

究其原因,主要有三条. 其一,离婚纠纷案件中所涉及的法条相对集中,常见的就是《婚姻法》和三部《婚姻法》司法解释,而诈骗罪所涉及的法条却很繁杂,虽然诈骗罪的刑法法条较为单一,但诈骗罪涉及的司法解释很多且更为分散,不同类型的司法解释均有. 其二,离婚纠纷案件的案情一般较为简单,仅针对离婚争议,基本仅涉及财产分割、债务承担和子女抚养三个大类,而诈骗罪案件所涉及的案情类型非常多,生活中存在着大量不同类型的诈骗行为,所对应的法条也各不相同. 其三,离婚纠纷都是单纯的一个民事法律关系,但诈骗罪案件中可能会涉及到数罪案件,也就是同一案件中被告人涉及多项犯罪,所以裁判文书中会涉及到多个罪名的案件事实、法条引用,最终会成为影响正确率的因素。

还应看到,在低频法条的分布中,随着频数的降低离婚纠纷案件的低频法条比诈骗罪案件占据更多比例,而模型在预测低频法条时会更容易遗漏,所以离婚纠纷案件的召回率显著低于诈骗罪案件的召回率。

4 结 论

首先,本算法是有效的. 根据上述结果分析显示,无论诈骗罪案件还是离婚纠纷案件中,经过本文采用的迁移学习方式后,均能够做到准确地针对案情描述性文本推送适用法条. 在将来的智慧司法发展过程中,还可以将本文成功的经验扩展到其它民事、刑事案件中,最终形成整个庭审辅助系统可以对不同案由的案件提供针对性的法条推荐。

其次,本算法具有针对性. 通过对比诈骗罪案

件和离婚纠纷案件所产生的的不同向量以及不同测试结果,可以看出不同类型案件由于自身特征的不同,在向量训练和最终法条推送过程中都存在着不同. 因此,在同一案由案件裁判文书的训练下进行迁移学习是非常有针对性的.

再次,本算法方式迁移学习具有全面性. 为了有效地帮助法官实现法条的全方位推荐适用,尤其是具有针对性的法规、司法解释,本文在数据预处理中加入了裁判文书中引用的所有法条,并且在实验模型的建立中实现了输出包含法规、司法解释在内的不同类型适用法条.

最后,本算法还具有可拓展性. 随着迁移学习模式的不断完善,可尝试利用这种模式开展对裁判文书数据进行其它方面的迁移学习,比如证据推送、量刑预测等等,进一步为人工智能提供司法辅助工作开拓新的思路.

参考文献:

- [1] Cavnar W B, Trenkle J M. N-gram-based text categorization [EB/OL]. [2020-01-09]. <https://www.osti.gov/biblio/68573>.
- [2] Le Q V, Mikolov T. Distributed representations of sentences and documents [C]//International Conference on Machine Learning. New York: ACM, 2014.
- [3] Bojanowski P, Grave E, Joulin A, *et al.* Enriching word vectors with subword information [J]. *Trans Assoc Comput Ling*, 2017, 5: 135.
- [4] Joulin A, Grave E, Bojanowski P, *et al.* Bag of tricks for efficient text classification [C]//Lapata M, Blunsom P, Koller A. *Proceedings of the 15th conference of the European Chapter of the association for computational linguistics (Vol. 2)*. Stroudsburg: Association for Computational Linguistics, 2017.
- [5] Devlin J, Chang MW, Lee K, *et al.* BERT: pre-training of deep bidirectional transformers for language understanding [C]// *Proceedings of the 2019 conference of the North American Chapter of the association for computational linguistics: human language technologies (Vol. 1)*. Stroudsburg: Association for Computational Linguistics, 2019.
- [6] Yang Z, Dai Z, Yang Y, *et al.* Xlnet: generalized autoregressive pretraining for language understanding [C]// Wallach H M, Larochelle H, Beygelzimer A, *et al.* *NeurIPS*, Cambridge: MIT Press, 2019.
- [7] Sun Y, Wang S, Li Y, Feng S, *et al.* ERNIE 2.0: a continual pre-training framework for language understanding [EB/OL]. [2020-01-09]. <https://arxiv.org/abs/1907.12412>.
- [8] Xiao C, Zhong H, Guo Z, *et al.* Cail2018: a large-scale legal dataset for judgment prediction [EB/OL]. [2020-01-09]. <https://arxiv.org/abs/1807.02478>.
- [9] 刘宗林, 张梅山, 甄冉冉, 等. 融入罪名关键词的法律判决预测多任务学习模型 [J]. *清华大学学报: 自然科学版*, 2019, 59: 497.
- [10] 王业沛, 宋梦姣, 王譞, 等. 基于深度学习的判决结果倾向性分析 [J]. *计算机应用研究*, 2019, 2: 335.
- [11] 张虎, 王鑫, 王冲, 等. 面向法律裁判文书的法条推荐方法 [J]. *计算机科学*, 2019, 46: 211.
- [12] Han S Y, Zhang Y H, Ma Y S, *et al.* Thuocl: Tsinghua open Chinese lexicon [EB/OL]. [2020-01-10]. <http://thuocl.thunlp.org>.
- [13] Li D, Mei H, Shen Y, *et al.* Echarts: a declarative framework for rapid construction of web-based visualization [J]. *Visual Inform*, 2018, 2: 136.
- [14] 金玉, 崔兰兰, 孙界平, 等. 基于综合相似度迁移的协同过滤算法 [J]. *四川大学学报: 自然科学版*, 2018, 55: 477.

引用本文格式:

中文: 杨超群, 庞彦燕, 严若冰, 等. 基于迁移学习的适用法条推荐模型 [J]. *四川大学学报: 自然科学版*, 2021, 58: 021001.

英文: Yang C Q, Pang Y Y, Yan R B, *et al.* A model for recommendation of applicable law articles based on transfer learning [J]. *J Sichuan Univ: Nat Sci Ed*, 2021, 58: 021001.