



单项专利价值的评估与定量评估指标体系的构建

——基于邻域粗糙集与果蝇优化神经网络的单项专利价值评估*

□慎金花 刘玥 张更平

摘要 为提高专利价值预测的准确性,促进专利权的转让,围绕如何以专利权转移过程中的专利定价客观评价专利价值,构建了针对单项专利可定量评估的指标体系,克服了专利价值评估中的主观性,使用邻域粗糙集方法排除冗余属性,进行特征选择,采用果蝇算法优化 BP 神经网络,降低了 BP 神经网络容易陷入局部极小的风险。通过实证研究发现,构建的专利价值指标体系可对单项专利进行定量评价,果蝇算法优化后的 BP 神经网络具有比较快速和准确的预测能力,在实际预测中具有良好的泛化能力和有效性。

关键词 专利价值评估 邻域粗糙集 果蝇算法 BP 神经网络

分类号 G255.53

DOI 10.16603/j.issn1002-1027.2020.03.007

自 1985 年我国设立专利制度以来,专利事业已取得了长足发展。2017 年我国专利申请量达到 369.8 万件,其中发明专利申请量为 138.2 万件,同比增长 14.2%;共授权发明专利 42 万件,其中,国内发明专利授权 32.7 万件,同比增长 8.2%^[1]。2017 年的技术合同成交总额高达 1.3 万亿元,同比增长 17.68%^[2]。我国专利申请量和专利交易成交总额都有大幅度提升,专利交易活动日趋活跃。

然而,在专利成果数量急剧增长的背景下,我国的专利转移转化率却偏低,大量专利成果处于未转移或者未实施状态。由于供求信息不对称、缺乏资金投入、交易定价不合理等,顺利实现专利成果转化的项目不足 10%^[3-4],从而造成专利价值贬值,研发成本流失;另一方面,对于企业来说,知识产权等无形资产是企业的核心竞争力,为了占据市场份额,企业愿意花费资金进行专利交易活动,直接购买专利相比投入人力和资金进行自主研发效率更快,成本更低。因此,对于专利交易双方而言,合理评估专利价值是能否促成专利权转移转化的重要条件。

本文以专利权转移过程中的专利定价评估专利价值,基于前人的研究,构建了可定量评估某一专利

的价值评估指标体系,利用邻域粗糙集方法进行特征选择,设计了果蝇优化的 BP 神经网络(Back Propagation Neural Network, BPNN)对专利交易价格进行预测,对比其他模型的预测效果验证了果蝇优化 BPNN 的有效性。

1 研究背景

1.1 专利价值评价体系的国内外研究现状

国外对专利价值的关注始于 20 世纪 60 年代,诺德豪斯(Nordhouse W D)开始研究专利价值参数,提出了专利的生命周期作为专利价值的决定因素^[5]。此后,专利被引量成为备受学者关注的专利价值指标。贝森(Bessen J)认为被诉讼的专利、高引用量的专利都具有更高的价值^[6]。布雷兹曼(Breitzma A)阐述了专利引文的概念,并将其应用在企业并购的专利价值评估中^[7]。帕克(Park G)验证了专利前向引用量与专利价值之间存在正相关关系^[8]。菲什(Fisch C)研究了中国 60000 项专利数据集,利用 Cox 回归分析,发现与美国、欧洲、日本、韩国的专利相比,中国专利的被引滞后较大,专利价值较低^[9]。对于影响专利价值的其他指标,国外学

* 国家社会科学基金项目“需求和能力导向的大学图书馆专利情报服务机制研究”(批准号:15BTQ027)的研究成果之一。

通讯作者:慎金花,ORCID:0000-0002-5795-0432,邮箱:jhshen@lib.tongji.edu.cn。



者也有所研究。柯伦柏(Klemperer P)、吉尔伯特(Gilbert R)等学者研究认为专利广度是影响专利价值的另一个重要特征^[10-11]。加利尼(Gallini N T)认为发明过程的难度是决定专利价值的关键因素^[12]。费希尔(Fischer T)认为前向引用和专利族大小影响了专利价值^[13]。

与国外研究重点不同,国内学者对于专利价值指标的研究主要集中于指标体系构建而非对某一项指标的证实研究。万小丽主要针对发明专利构建了技术价值、市场价值、权利价值3个维度17个指标的指标体系,并用层次分析法获得了指标权重^[14]。肖国华对比分析了国家知识产权局出版的专利价值指标体系、专利质量评价记分牌法、Ocean Tomo300指数,提出了从法律价值度、经济价值度、技术价值度、学术价值度4个维度建立专利价值指标库的观点^[15]。汪雪峰等通过综述已有文献研究,提出了5个主要的专利价值评价指标,包括技术生命周期、专利引证、科学关联性、专利实施率和专利族大小^[16]。申文娇研究了拍卖场景中的专利价值评估指标,包括专利范围、专利族、被引次数、引文数量、权利要求、专利寿命和每件专利中的专利数量^[17]。李广凯等研究了输配电行业的专利价值指标特点,选取可定量分析的指标构建指标体系,通过输配电行业的已授权专利实证统计分析,发现权利要求、专利被引次数、同族专利数可以被用来评价专利价值,并且在使用时需要考虑行业特点^[18]。

实践中,国内外也有一些现行较为主流的专利价值评估综合指标体系,包括CHI指标、电气和电子工程师协会(Institute of Electrical and Electronics Engineers, IEEE)专利综合实力指数、经济合作与发展组织(Organization for Economic Co-operation and Development, OECD)指标等。20世纪70年代,美国知识产权咨询公司(CHI Research, Inc.)与美国国家科学基金会一起研发出全球第一个专利价值指标体系^[19],主要用7个指标评估公司、国家和地区的专利价值;2007年,IEEE SPECTRUM杂志综合考虑了专利组合的数量和技术价值,提出“专利综合实力指数=专利数量×专利增长指数×校正后的技术影响指数×技术原创指数×技术通用指数”,计算专利综合实力指数^[20];20世纪70年代后期,经济合作与发展组织为了保持国际专利数据的一致性,从国家、产业、企业三个层级设置了10个由

专家经验判断的专利评估指标体系^[21]。国内较为权威的专利价值评估体系是2011年中国技术交易所研究建立的专利价值分析工作体系,包括专利法律价值度、技术价值度和经济价值度3个维度18个评价指标,通过专家打分,加权汇总后形成专利价值度,对专利价值进行标准化的统一度量。

从整体来看,国内外研究各有特色。在专利价值评估实践方面,多以专利强度、被引次数等指标衡量专利价值,鲜有从专利定价角度来衡量其价值;国外侧重于基于评估的运维决策制定,如是否继续维持专利;国内平台的方法较为传统且使用门槛高。在专利价值评估方法方面,国内外较多使用期权模型,受主观因素影响较大;少量学者开始关注应用数据挖掘、机器学习等前沿技术评估。从专利价值指标研究方面,国外侧重于某一影响指标的验证研究,国内侧重于构建综合的评价指标体系。

1.2 研究思路

研究理论思路按照问题背景、分析问题、提出解决方案的逻辑顺序展开,如图1所示。

国内专利成果丰富,但专利价值评估难,学者多以指标体系来计算加权分值,受主观影响较大。本文旨在构建一个适用于机器学习方法的定量评估的专利价值指标体系,并利用邻域粗糙集方法进行特征选择,利用果蝇优化神经网络方法建立专利价值评估模型,期望达到误差较小的预测性能;在模型构建的基础上,以已有专利转让价格数据集作为样本进行训练,验证模型的有效性。




图1 研究思路

为解决专利评估问题,本文基于“扎根理论”构建了针对某一专利、可客观定量评估的专利价值指标体系,并应用邻域粗糙集方法进行属性约简及约



简效果评估。专利价值评估指标的选取对评估结果准确性具有较大影响。首先,高维数据变量之间相互关联,即多重共线性可能导致空间的不稳定;其次数据维度过高,可能导致神经网络的收敛时间呈指数级别增长,甚至不收敛,因此变量的选择对模型的泛化性能有至关重要的影响。邻域粗糙集方法可以发现隐藏在大量数据中的逻辑模式,识别高维冗余变量,保留优质变量,可以简化机器学习模型的训练和预测。

为了解决专利价值受多因素影响的难测度性及不确定性问题,本文引进了在解决复杂非线性问题中具有优越性的 BP 神经网络。它具有数据并行处理能力、高度非线性映射能力及良好容错性等优势,可以在专利价值评估中模拟人脑的信息处理方式。然而, BP 神经网络具有容易陷入局部极小及学习收敛速度慢的缺陷,因此,本文将参数少、计算量小、精度高的果蝇算法优化与 BP 神经网络结合,提出了用果蝇优化 BP 神经网络的算法流程,通过实证研究验证果蝇优化神经网络在专利价值预测应用中的可行性。

2 专利价值评估指标体系构建

纵观国内外现行的专利价值评估指标体系,存在以下不足:第一,大多用于评估公司或组织整体的专利价值,而不是针对单项专利;第二,指标应用主观性强,难以量化评定或计算复杂,指标得分因打分者的专业性、经验和理解不同而产生较大差异,在实际应用和数据处理中,结果会带有很强主观性和不确定性;第三,很多指标缺少数据支撑,如专利技术未来可能实现的销售收益、未来可能的市场份额、专利技术的投入等指标数据无法有效获得,导致指标利用不完整。

本文应用“扎根理论”,结合前人对专利价值评估的研究,基于 SMART 准则,从技术、法律、市场三个层次构建了针对单项专利、可客观定量评估的专利价值指标体系,共包括 14 个指标,各个维度指标的含义作用如表 1 所示。该指标体系一方面排除了评估过程中千人千面的主观性,另一方面,对于使用者而言,使用门槛较低,便于沿用。

如表 1 所示,专利价值指标体系包括 3 个维度,分别是技术、法律和市场,各个指标的测量方法需要提前界定。技术维度中,专利被引次数是指专利在申请并授权后,其他新的发明专利把其当作现有技

表 1 专利价值评估指标体系

维度	指标	意义
技术 维度	专利被引次数 C_1	反映专利在该技术领域的先进性和基础性
	技术关联度 C_2	体现技术之间的积累性和连续性
	科学关联度 C_3	反映了专利技术和科学研究之间的关联性
	技术应用范畴 C_4	说明了专利应用范围和扩张性
	权利要求 C_5	表明了专利权保护的范围
法律 维度	法律状态 C_6	意味着专利所经历过的不同阶段
	实质审查时长 C_7	衡量专利实质审查的复杂程度
	剩余保护期限 C_8	表明专利可获利的剩余期限
	专利缴费次数 C_9	体现专利权人对专利未来发展潜力的当时投入
市场 维度	专利权人属性 C_{10}	体现专利权人的研究能力和研究投入
	技术生命周期 C_{11}	衡量技术所处的发展阶段和面临的环境如何
	专利族规模 C_{12}	体现专利覆盖情况
	专利独立性 C_{13}	体现专利的基础性和从属性
	市场竞争强度 C_{14}	反映市场同类专利的竞争情况

术而进行引用的次数;技术关联度是指引用其他专利技术的数量,体现技术之间的积累性和连续性;科学关联度是专利引用科学文献或研究报告的数量,衡量专利技术和早先科学研究的关系;专利技术应用范畴用国际专利分类(International Patent Classification, IPC)号的数目衡量,表示专利的技术所属范围和可扩张性;权利要求用权利要求数衡量,体现专利权人所申请的专利保护范围。法律维度中,法律状态是指交易专利所处的法律流程;实质审查时长是指从专利公开到授权的周期时间;专利剩余保护期限是指专利自授权日起,得到法律保护的时间,衡量其可获利的年限;专利缴费次数体现了专利权人对专利的未来发展态度和获利能力的信任;专利权人属性可以分为企业、高等院校、大专院校、科研机构、政府机关和个人,不同的专利权人科研能力和科研投入不同。市场维度中,后向引证专利的年龄中位数标志为专利技术生命周期;专利族规模是指同族专利的数量;专利独立性是指通过专利说明书的背景技术和技术方案描述判断,该专利是否可以独立应用于产品还是需要依赖其他专利,或者经过技术组合才能实施;市场竞争强度定义为现有同类专利的数量,衡量专利的市场竞争强度和技术发展情况。



3 邻域粗糙集方法

帕夫拉克(Pawlak Z)提出的粗糙集方法是数据挖掘中一种知识发现的工具,能够发现隐藏在大量数据中的重要事实,对多维数据降维处理^[22]。胡清华教授提出的邻域粗糙集是为了解决传统粗糙集理论中处理连续型变量存在的弊端^[23]。传统粗糙集方法必须将连续型变量进行离散化处理,但不合理的属性离散化会影响原始属性的数据特征,难以获得最佳的约简属性集。在专利价值评估中,存在很多连续型数值属性,引入邻域粗糙集可进行属性约简。

3.1 邻域的上近似和下近似

在实数域中, $\Delta = R^N \times R^N \rightarrow R$, 则 Δ 为 R^N 上的一个度量(距离), 对于 $\forall x_1, x_2 \in R^N$, $\Delta(x_1, x_2)$ 为距离函数, 表示两个元素 x_1, x_2 之间的距离。对于给定实数空间 Ω 上的集合 $U = \{x_1, x_2, \dots, x_n\}$, 对 $\forall x_i$ 的邻域定义如式(1)所示, 其中 δ 是邻域半径。

$$\delta(x_i) = \{x \mid x \in U, \Delta(x, x_i) \leq \delta, \delta \geq 0\} \quad (1)$$

给定实数空间上的集合 $U = \{x_1, x_2, \dots, x_n\}$ 及其邻域关系 N , 即 $NS = (U, N)$ 。对 $\forall X \subseteq U$, X 在邻域空间 (U, N) 上的上近似意为可能属于 X 的最小集合, 即所有与 X 相交非空的元素, 如公式(2); 下近似为 X 的最大真子集, 如公式(3)所示; 由此可得 X 的边界, 即不确定是否属于 X 的元素, 如式(4)所示。其中, X 的下近似集 $\underline{NX}$ 为正域 $pos(X)$, 与 X 无关的区域 $(U - \overline{NX})$ 为负域 $neg(X)$ 。

$$\overline{NX} = \{x_i \mid \delta(x_i) \cap X \neq \emptyset, x_i \in U\} \quad (2)$$

$$\underline{NX} = \{x_i \mid \delta(x_i) \subseteq X, x_i \in U\} \quad (3)$$

$$BN(X) = \overline{NX} - \underline{NX} \quad (4)$$

在邻域决策系统 $NDS = (U, C \cup D)$, 决策属性 D 将对象集合 U 划分为 N 个等价类 $\{X_1, X_2, \dots, X_N\}$, 对于 $\forall B \subseteq C$, 则决策属性 D 关于子集在 B 的上近似集、下近似集分别如式(5)(6)所示。决策属性 D 对条件属性 B 的依赖度如式(7)所示, 衡量了条件属性 B 所确定的决策属性 D 的下近似集合占整体集合的比例。

$$\overline{N_B X} = \bigcup_{i=1}^N \overline{N_B X_i} \quad (5)$$

$$\underline{N_B X} = \bigcup_{i=1}^N \underline{N_B X_i} \quad (6)$$

$$\gamma_B(D) = \text{card}(\underline{N_B X}) / \text{card}(U) \quad (7)$$

3.2 基于邻域的属性约简

属性约简是粗糙集理论中的重要部分, 其本质

在于保持信息系统 IS 分类能力不变的情况下, 剔除冗余属性。属性的重要度定义为条件属性对决策属性的影响。对于条件属性集合 $B(\alpha \in B)$, 条件属性 α 对决策属性的重要度可以通过删除该属性计算:

$$\text{Sig}(\alpha, B, D) = \gamma_B(D) - \gamma_{B-\{\alpha\}}(D) \quad (8)$$

邻域粗糙集约简使用的是前向贪心算法^[24], 算法流程如图2, 约简过程如下。

S1. 输入邻域决策系统、邻域半径调和参数 λ 和重要度下限控制参数 SigCtrl ;

S2. 根据各个属性的标准差和邻域半径调和参数, 得到“邻域半径 = 属性标准差 / 邻域半径调和参数”, 进而得到各个属性子集下的各样本邻域;

S3. 计算决策子集在属性子集的上下近似, 根据式(5)(6)得到决策属性在属性子集的上下近似;

S4. 计算决策属性对条件属性子集的依赖度, 如式(7);

S5. 计算各个属性相对于决策属性 D 的重要度, 如(8)所示;

S6. 判断各个属性的重要度是否大于重要度下限控制参数 SigCtrl (一般接近于 0), 如果大于 SigCtrl , 则将属性加入约简集; 否则删除该冗余属性。




图2 前向贪心约简算法

4 果蝇算法优化的神经网络

4.1 BP神经网络

误差逆传播(Error Back Propagation, BP)算



法,也叫反向传播或者后向传播算法,是多层神经网络学习的代表,是迄今应用最为广泛的神经网络算法,BP算法大多应用于训练由一个输入层、一个或多个隐含层和一个输出层构成的多层前馈神经网络,而应用BP算法的多层前馈神经网络被称为BP神经网络^[25]。BPNN的学习流程以单隐层BPNN为例,具体过程如下:

S1.网络初始化。包括各层节点数、连接权重和各层阈值。

S2.隐含层的输出。输入层第 i 个神经元的输出为 $x_i(i \leq l)$,输入层第 i 个神经元指向隐层第 k 个神经元的权重为 w_{ik} ,隐层第 k 个神经元的输入 λ_k 如公式(9)所示;隐层第 k 个神经元的阈值为 α_k ,隐层第 k 个神经元的输出如公式(10)所示。

$$\lambda_k = \sum_{i=1}^l w_{ik} x_i \quad (9)$$

$$b_k = f(\lambda_k - \alpha_k) = f\left(\sum_{i=1}^l w_{ik} x_i - \alpha_k\right) \quad (10)$$

S3.输出层的输出。隐层第 k 个神经元指向输出层第 j 个神经元的权重为 v_{kj} ,输出层第 j 个神经元的输入 μ_j 如公式(11)所示;输出层第 j 个神经元的阈值为 β_j ,输出层第 j 个神经元的输出如公式(12)所示。

$$\mu_j = \sum_{k=1}^h v_{kj} b_k \quad (11)$$

$$\hat{y}_j = f(\mu_j - \beta_j) = f\left(\sum_{k=1}^h v_{kj} b_k - \beta_j\right) \quad (12)$$

S4.误差的计算。对于样本 (X_s, Y_s) ,用均方误差衡量预测值与实际值之间的偏差,公式如(13)所示,通过最小化输出值和期望值之间的误差,进行反向传播过程调整网络参数。

$$E_s = \frac{1}{2} \sum_{j=1}^d (\hat{y}_j^s - y_j^s)^2 \quad (13)$$

S5.权值和阈值的更新。基于误差梯度下降法对参数进行调整,隐层第 k 个神经元和输出层第 j 个神经元的连接权重更新为 $v_{kj} + \gamma \Delta v_{kj}$, γ 是学习率($0 < \gamma < 1$),控制算法的更新速度, Δv 是负梯度方向,则根据误差 E_k , v_{kj} 的更新方向如公式(14)所示。

$$\Delta v_{kj} = -\frac{\partial E_s}{\partial v_{kj}} = -\frac{\partial E_s}{\partial \hat{y}_j^s} \cdot \frac{\partial \hat{y}_j^s}{\partial \mu_j} \cdot \frac{\partial \mu_j}{\partial v_{kj}} = -\frac{\partial E_s}{\partial \hat{y}_j^s} \cdot \frac{\partial \hat{y}_j^s}{\partial \mu_j} \cdot b_k \quad (14)$$

对于Sigmoid激活函数,满足 $f'(x) = f(x)(1 - f(x))$,故有:

$$g_j = -\frac{\partial E_s}{\partial \hat{y}_j^s} \cdot \frac{\partial \hat{y}_j^s}{\partial \mu_j} = \hat{y}_j^s(1 - \hat{y}_j^s)(y_j^s - \hat{y}_j^s) \quad (15)$$

同理,可得各层阈值和隐含层权值。

S6.判断迭代是否到达指定的迭代次数。

BP神经网络具有非线性映射能力、自适应能力等优点,但是也存在一些缺点,主要是容易陷入局部极小和学习速度慢,尝试用果蝇算法进行BP神经网络优化。

4.2 果蝇算法

果蝇优化算法(Fruit Fly Optimization Algorithm,FOA)是2011年台湾潘文超教授从果蝇觅食行为中得到启发,提出的一种应用于全局寻优的群智能算法,与当前成熟的蚁群算法、遗传算法、粒子群算法等群智能算法相比,具有参数少、计算量小、精度高等优点^[26]。果蝇算法流程表述为以下步骤:

S1.随机初始化果蝇群体位置(X_index, Y_index),确定参数种群大小和最大迭代次数。

S2.初始迭代,赋予果蝇利用嗅觉随机搜索食物的方向和距离。

$$X_i = X_index + rand \quad (16)$$

$$Y_i = Y_index + rand \quad (17)$$

S3.由于食物的位置未知,首先估计果蝇与原点的距离 D_i ,再计算气味浓度的判定值:

$$D_i = \sqrt{X_i^2 + Y_i^2} \quad (18)$$

$$S_i = 1/D_i \quad (19)$$

S4.气味浓度判定值代入气味浓度判定函数,得到果蝇的味道浓度值 $Smell_i$ 。

$$Smell_i = f(S_i) \quad (20)$$

S5.寻找果蝇群体中浓度值 $Smell_i$ 最高的果蝇,作为最优个体。

$$[bestSmell, bestIndex] = \max(Smell_i) \quad (21)$$

S6.存储最优个体的味道浓度值和坐标,其他果蝇利用视觉向该位置前进。

$$Smellbest = bestSmell \quad (22)$$

$$X_index = X(bestIndex) \quad (23)$$

S7.迭代寻优,重复执行S2~S5,比较最优个体的味道浓度与上一代的最优味道浓度,保留比较后的最优浓度值和位置坐标。

4.3 果蝇算法优化的BP神经网络

为解决BPNN存在的不足之处,本文将果蝇算



法和 BPNN 二者相结合,可以充分利用果蝇算法全局寻优、计算量小等特点,克服 BPNN 学习过程中容易陷入局部最优、学习收敛速度慢等缺陷。果蝇算法优化 BPNN 的本质在于将网络权重和阈值视为果蝇个体进行寻优,结合果蝇算法流程,优化的 BPNN 算法流程如图 3 所示。




图 3 果蝇优化神经网络流程

5 实证研究

本研究所用的数据主要包括两部分:第一部分是专利交易价格数据,收集自国有成果交易公示系统、上海市知识产权局成交公示、专利拍卖交易资讯、专利交易网站等,包括了交易价格从 3000 至 380 万的共 755 条专利转让交易价格数据,时间范围为 2016—2018 年,由于样本量较小,未将时间作为影响因素考虑在内,随着交易量增加,在日后的研究过程中,需要将时间作为必要考虑因素进行拟合与验证。第二部分是交易专利的指标数据,主要来自同济大学专利信息服务平台和国家知识产权局专利检索分析网站。

5.1 邻域粗糙集属性约简

邻域粗糙集属性约简前,对数据进行归一化和决策特征离散化。本文利用 0—1 标准化对数据进行处理,去除数据单位和量纲的限制;使用 k—means 算法对专利交易价格进行分类,将交易价格分至 10 个区间。

邻域粗糙集进行专利价值评估特征约简过程中,主要有两个参数需要调整,分别是邻域半径调和参数和重要度下限控制参数。邻域半径是用来划分样本特征的邻域指标,邻域半径=标准差/调和参数 λ ,由于不同的属性数据波动不同,用调和参数调节不同属性的邻域半径标准。 λ 一般取值在 0.5~4 之间,如果样本量较多, λ 取值调大,一般为 2~4。重要度下限控制参数是特征重要度保留界限。特征的重要度关系到该特征是否被保留,如果特征的重要度大于重要度下限参数,该特征则会被保留下来。如果设置过大,可能造成特征过度约简,一般取值接近于 0。

为获得最优的专利价值评估约简属性集,组合半径调和参数 λ 和重要度下限控制参数,分别获得属性约简集。重要度下限控制参数选择 0.001 和 0.01,邻域半径调和参数 λ 选择 2~4,步长为 0.2,约简结果如表 2 所示。

表 2 参数组合约简属性集

	Sig = 0.01	Sig = 0.001
$\lambda = 2.0$	[3,5,6,7,10,11,12,14]	[1,2,3,4,5,7,9,10,11,13,14]
$\lambda = 2.2$	[2,3,6,7,9,11,13,14]	[2,3,4,5,7,8,10,11,14]
$\lambda = 2.4$	[3,5,7,8,10,11,14]	[2,3,5,6,8,9,10,14]
$\lambda = 2.6$	[2,5,6,7,9,11,14]	[3,6,8,9,10,11,12]
$\lambda = 2.8$	[7,10,11,13]	[4,7,8,10,11,13,14]
$\lambda = 3.0$	[8,9,10]	[3,5,8,9,10,12,13]
$\lambda = 3.2$	[8,10,14]	[2,5,10,11]
$\lambda = 3.4$	NAN	[5,8,11,14]
$\lambda = 3.6$	NAN	[4,6,10,12]
$\lambda = 3.8$	NAN	[8,10,11]
$\lambda = 4.0$	NAN	NAN

基于支持向量机 (Support Vector Machine, SVM) 对各参数组合生成的约简集进行决策属性分类,对比决策属性分类准确度选择最终的专利价值评估属性约简集,如图 3 所示。

由图 4 各参数组合产生专利价值评估约简集的分类准确率可知,当 $\lambda = 2.2$,Sig=0.001 时,约简集基于 SVM 的分类准确率最高,约简属性编号为[2,



3,4,5,7,8,10,11,14],即技术关联度、科学关联度、技术应用范畴、权利要求、实质审查时长、剩余保护期限、专利权人属性、技术生命周期和市场竞争强度为邻域粗糙集提取的约简属性集合。




图4 不同参数组合下约简集分类准确率

5.2 参数设置

本文建立含有输入层、隐层和输出层的三层前向神经网络,利用 Matlab 进行神经网络模型构建和训练,将单个专利拟合到已有价格的最相近专利邻域。BPNN 模型需要将邻域粗糙集约简的类别特征,即专利权人属性定量化处理,采用 one-hot 编码,将专利权人属性拆分为由 0 或 1 表示的多个变量。

根据特征选择和类别特征处理后的专利价值属性确定输入层节点数为 13,输出层节点数为 1。隐含层激活函数为 Sigmoid 型正切函数 tansig,输出层选择 Sigmoid 型线性函数 purelin,训练函数为 trainlm,迭代次数为 1000 次。目标精度研究应用中往往定为 10^{-3} ,本文为考察模型的误差收敛潜力,目标误差精度设为 10^{-4} ,误差超过 10^{-3} 为较好的训练模型。果蝇算法选择最大迭代次数 k 为 500,种群规模 s 为 25。

图 5 为不同隐含层节点数下神经网络的误差值。节点数过少,无法拟合数据,节点数过大,容易影响模型的泛化能力。将隐含层节点数从 10 增加至 30,选择误差最小的隐含层节点数,由图 5 可知选择节点数为 27 时,模型误差最小。

5.3 模型结果分析

果蝇寻优路径曲线如图 6,可知果蝇算法优化 BPNN 跳出了局部最优。果蝇算法在迭代至 50 代以前不断跳出局部最优,优化到 60 代以后跳出原来的局部最优,适应度函数达到全局最优,此时适应度函数值约为 0.0007。将果蝇算法寻得的最优阈值和

权值代入 BPNN 中,得到优化的 BPNN 模型。




图5 不同隐含层节点数下的神经网络误差




图6 果蝇算法寻优路径

使用训练数据集进行 BPNN 和果蝇优化 BPNN 的专利价值评估模型训练,将 BPNN 和果蝇优化神经网络同样迭代至 1000 次,如图 7、图 8 可知,BPNN 的误差达到了 0.00098,果蝇优化 BPNN 的误差达到了 0.00048,果蝇算法优化后的 BPNN 专利价值预测模型误差收敛更快。

利用测试数据进行专利价值测试数据进行神经网络模型预测,进一步检测模型应用专利价值预测的泛化能力。使用以下四个指标从误差角度的不同维度检验模型预测效果,指标值越小,用于专利价值预测的模型效果越好。

$$MAE = \frac{1}{m} \sum_{i=1}^m |\hat{y}_i - y_i| \quad (24)$$

$$MAPE = \frac{1}{m} \sum_{i=1}^m \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (25)$$




图7 BPNN 误差收敛过程




图8 FOA-BPNN 误差收敛过程

$$MSE = \frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2 \quad (26)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2} \quad (27)$$

表3表示专利价值测试数据的两种模型预测误差效果。从表中可以看出两种模型对专利价值均有一定的预测能力;对比FOA-BPNN和BPNN的专利价值预测效果,一方面从MSE和RMSE可以发现,FOA-BPNN预测总体样本误差更小,另一方面从MAPE和MAE可以发现,FOA-BPNN预测单个样本误差更小,总体而言,FOA-BPNN提升了BPNN对于专利价值的预测能力。

表3 模型预测误差效果

	MSE	RMSE	MAPE	MAE
BPNN	0.00106	0.0312	0.3843	0.0276
FOA-BPNN	0.00041	0.0202	0.2197	0.0174

图9、图10显示了两种模型的专利价值预测结果,BPNN专利价值预测值与实际交易价格仍有一定差距,相较之下,采用果蝇算法优化BPNN专利价值预测效果有所提升,虽然某些样本点的预测值与实际值相差较大,但总体而言预测结果与实际值拟合效果更好,可以判断模型的有效性。




图9 BPNN 专利价值预测效果




图10 FOA-BPNN 专利价值预测效果



6 结论

专利转移转化率低是我国专利市场的特性,构建充分体现专利内在价值的专利定价评估模型能在一定程度上促成专利权人和专利需求方的交易活动。本文关注专利价值评估指标体系的适用性和可操作性,探究神经网络方法应用专利价值预测的准确性,使用真实的专利交易数据,基于邻域粗糙集方法提取影响专利价值的核心属性,对比实验结果表明,果蝇寻优算法可以跳出局部最优,优化 BPNN 权重和阈值,一定程度上提升了专利价值预测精度并且提高了模型误差收敛速度。

本文针对专利权转移过程中的专利定价预测问题,创新之处在于:(1)构建了适用于单项专利定量评估的指标体系,去除了主观性因素,且弥补了主流专利价值评估指标体系对单项专利价值评估的空白。(2)将邻域粗糙集与果蝇算法优化 BPNN 方法结合,应用于解决专利价值评估,克服了传统 BPNN 存在的收敛速度慢和容易陷入局部极小的不足,提高了模型预测的准确性。

评价体系中虽然纳入了专利时效性相关因素,即考虑其受法律保护有效期长短的剩余保护期限,以及技术发展阶段的技术生命周期,但考虑到数据的可获得性,本文选取实证数据为近 3 年交易专利,此为本文不足,需待今后研究进一步扩充样本数量提升模型的训练和拟合效果。在样本量充足的前提下,将价格时效性纳入考量也是未来研究的方向之一。

参考文献

- 1 国家知识产权局. 国家知识产权局公布 2017 年专利统计数据 [EB/OL]. [2018-05-29]. <http://biaotianxia.com/article/4606.html>.
- 2 科学技术部火炬高技术产业开发中心. 关于公布 2017 年度全国技术合同交易数据的通知 [EB/OL]. [2018-05-29]. <http://www.china-torch.gov.cn/kjb/tzgg/201802/659740d817c9473c932616659a7587e4.shtml>.
- 3 刘斌,谢婷婷,赖举. 高校专利转化问题及对策研究 [J]. 中国高校科技, 2015(8): 50-51.
- 4 朱雪忠,陈荣秋,柳福东. 专利权的闲置及其对策 [J]. 研究与发展管理, 2000, 12(3): 39-42.
- 5 Nordhaus W D. The optimal life of a patent [J]. Cowles Foundation Discussion Papers, 1967.
- 6 Bessen J. The value of U.S. patents by owner and patent characteristics [J]. Research Policy, 2008, 37(5): 932-945.
- 7 Breitman A, Thomas P. Using patent citation analysis to target/

- value M & A candidates [J]. Research Technology Management, 2002, 45(5): 28-36.
- 8 Park G, Park Y. On the measurement of patent stock as knowledge indicators [J]. Technological Forecasting & Social Change, 2006, 73(7): 793-812.
- 9 Fisch C, Sandner P, Regner L. The value of Chinese patents: an empirical investigation of citation lags [J]. China Economic Review, 2017, 45: 22-34.
- 10 Klemperer P. How broad should the scope of patent protection be? [J]. Rand Journal of Economics, 1990, 21(1): 113-130.
- 11 Gilbert R, Shapiro C. Optimal patent length and breadth [J]. Rand Journal of Economics, 1990, 21(1): 106-112.
- 12 Gallini N T. Patent policy and costly imitation [J]. Rand Journal of Economics, 1992, 23(1): 52-63.
- 13 Fischer T, Leidinger J. Testing patent value indicators on directly observed patent value—an empirical analysis of Ocean Tomo patent auctions [J]. Research Policy, 2014, 43(3): 519-529.
- 14 万小丽,朱雪忠. 专利价值的评估指标体系及模糊综合评价 [J]. 科研管理, 2008, 29(2): 185-191.
- 15 肖国华,牛茜茜. 专利价值分析指标体系改进研究 [J]. 科技进步与对策, 2015, 32(5): 117-121.
- 16 汪雪峰,刘晓轩,朱东华. 专利价值评价指标研究 [J]. 科学管理研究, 2008, 26(6): 115-117.
- 17 申文娇. 一种新的专利交易方式——拍卖方式下的专利价值指标 [J]. 中国科技信息, 2012(23): 145, 152.
- 18 李广凯,郭晶,龙华中. 我国输配电行业专利价值评估可量化指标分析 [J]. 中国发明与专利, 2016(12): 59-62.
- 19 马慧民,王鸣涛,叶春明. 日美知识产权综合评价指标体系介绍 [J]. 商场现代化, 2007(31): 301-302.
- 20 凌赵华. 国内外主流“专利指数”探析 [EB/OL]. [2018-05-29]. http://www.medsci.cn/article/show_article.do?id=490b56e247f.
- 21 张丽玮,等. OECD 专利分析指标 [J]. 情报科学, 2009(1): 124-127.
- 22 Pawlak Z. Rough sets [J]. International Journal of Computer and Information Sciences, 1982, 11(5): 341-356.
- 23 Hu Q, Yu D, Xie Z. Eighborhood classifiers [J]. Expert Systems with Applications, 2008, 34(2): 866-876.
- 24 齐亚丽. 基于模糊粗糙集属性约简方法的研究 [D]. 辽宁: 渤海大学, 2016.
- 25 周志华. 机器学习 [M]. 北京: 清华大学出版社, 2016: 97.
- 26 赵建平. 基于主成分与果蝇神经网络的酒泉基地短期风电功率预测 [D]. 甘肃: 兰州交通大学, 2017.

作者单位: 慎金花、张更平, 同济大学图书馆, 上海, 200092

刘玥, 同济大学经济与管理学院, 上海, 200092

收稿日期: 2019 年 4 月 18 日

修回日期: 2019 年 12 月 26 日

(责任编辑: 关志英)

(转第 64 页)