

核方法驱动的本体函数迭代算法

兰美辉¹, 高 炜²

(1. 曲靖师范学院 信息工程学院, 云南 曲靖 655011; 2. 云南师范大学 信息学院, 云南 昆明 650500)

摘要: 机器学习算法在本体中的运用集中在本体最优函数的学习, 即通过本体样本点和适当的学习策略得到最优实值函数. 核函数由于其在再生性和重构函数上的诸多优点, 而被广泛运用于机器学习算法中. 在本体函数的优化学习过程, 将核方法融入迭代策略中, 进而可得到最优的本体函数. 实验结果表明, 该方法对特定领域本体相似度的计算和本体映射的构建具有较高的准确率.

关键词: 本体; 相似度计算; 本体映射; 核矩阵

中图分类号: TP393.092 **文献标识码:** A **文章编号:** 1674-5639 (2019) 06-0097-06

DOI: 10.14091/j.cnki.kmxyxb.2019.06.018

Kernel Method-driven Ontology Function Iterative Algorithm

LAN Meihui¹, GAO Wei²

(1. College of Information Engineering, Qujing Normal University, Qujing, Yunnan, China 655011;

2. College of Information Science and Technology, Yunnan Normal University, Kunming, Yunnan, China 650500)

Abstract: The application of machine learning algorithms in ontology focuses on the learning of ontology optimal functions, that is, the optimal real-valued functions are obtained through ontology sample points and appropriate learning strategies. Kernel functions are widely used in machine learning algorithms due to their many advantages in regenerative and reconstruction functions. In the optimization learning process of ontology function, the kernel method is integrated into the iterative strategy to obtain the optimal ontology function. The experimental results show that the proposed method has higher accuracy for the calculation of ontology similarity and the construction of ontology mapping in specific domains.

Key words: ontology; similarity measure; ontology mapping; kernel matrix

本体这一术语源自哲学, 用于描述事物间的本质关联. 在计算机领域中, 本体是一种结构化的数据存储模型, 并附加了信息处理、计算和关联查询等多种功能, 可以看成是一本现代化的智能字典. 由于本体的强大功能, 现已被广泛应用于计算机各个领域以及 GIS、生物基因科学、植物学、神经科学、社会学、教育学等诸多领域. 目前, 本体相似度计算和不同本体之间映射算法的研究已成为知识表示和语义相似度领域研究的核心内容, 其中相似度计算是本体各类算法的灵魂. 而本体相似度计算算法通过适当转换后即可成为本体映射算法.

在信息检索中, 用本体顶点代表概念, 用边代表概念之间的相互关联. 通过相关领域的专家给出阈值参数 M , 将满足 $Sim(A, B)$ 大于 M 的所有本体顶点 B 构成的概念集合作为顶点 A 对应概念的查询扩展结果返回给用户. 而对于本体映射而言, 设图 G_1, G_2, \dots, G_m 分别对应本体 O_1, O_2, \dots, O_m . 对于每个 $A \in V(G_i)$, 其中 $1 \leq i \leq m$, 在 $G-G_i$ 中找出所有满足 $Sim(A, B) > M$ 的顶点 B 对应概念的集合返回给用户作为顶点 A 对应概念的查询扩展. 此外, 为了数学化表示本体的概念和对应顶点的信息, 总是用向量来表示概念和本体图上对应这个概念的顶点. 这个向量封装了对应概念的所有信息, 也包括对应顶点在整个本

收稿日期: 2019-08-28

基金项目: 国家自然科学基金资助项目 (61262071); 云南省教育厅科学研究基金资助项目 (2014C131Y).

作者简介: 兰美辉 (1982—), 女, 云南宜良人, 讲师, 硕士, 主要从事信息检索、机器学习和人工智能方面研究.

体图中的结构信息.

本体作为一种工具而被应用于各个领域. 例如在生物领域, GO 本体 (<http://www.geneontology.org>) 包含生物过程、分子功能和细胞成分这3个方面的概念信息, 一共收集了约23 700条术语, 同时对超过20个生物数据库中超过1 600万条基因进行解释说明. 通过对该本体的分析可帮助生物学家了解不同生物数据库之间基因的相互关联特征.

近年来, 有关本体在许多领域的应用研究已有大量报道. 例如: Przydzial 等^[1]将本体应用于制药学中的蛋白质检索; Koehler 等^[2]将本体应用于分子和疾病之间的表征数据库; Ivanovic 和 Budimac^[3]将本体在医学领域的应用进行了综述; Hristoskova 等^[4]将本体应用于个人医护系统的创建中; Kabir 等^[5]利用本体数据结构建立了有效的社会信息管理平台; Lasiera 等^[6]提出本体可以应用于建筑物的设计, 并将该技术应用于病人之家的设计和维护; Carlini 和 Makowski^[7]将基因学 GO 本体应用于优选密码字在昆虫同源问题中的研究; Nicolai^[8]阐述了通货紧缩理论以及其本体表示方法; Corrae 等^[9]将本体方法融入于基于模块化技术的注释科学文件系统中, 并将其应用于药物和传染疾病控制领域.

目前, 机器学习相关技术和方法被大量应用于本体相似度计算和本体映射的获取. 其核心思想是通过本体样本的学习得到本体函数: $f: V \rightarrow \mathbb{R}$, 它的作用是将整个本体图转化为一维实数轴, 而原来高维空间上的本体图的顶点就被映射成一维实数轴上的实数. 由此, 原先高维空间上的向量距离计算就转化为一维区间大小的比较. 即两概念对应实数之间的区间越大, 则该两个概念的相似度越小; 反之, 两概念对应实数之间的区间越小, 则说明这两个概念之间有很高的相似度. 此外, 诸多文献报道了基于机器学习方法的本体算法的研究, 并得到一些理论上相关的结果. 文献[10]给出了半监督 k -部排序框架下的本体学习算法; 文献[11]研究了基于正则化瑞利系数的半监督 k -部排序本体学习算法; 文献[12]通过在排序框架下引入梯度下降迭代策略来得到最优本体函数; 文献[13]通过矩阵优化来获取本体函数; 文献[14]从理论的层面对基于 k -部排序学习的本体算法进行了可学习性分析; 文献[15]给出基于距离测度计算的本体学习策略.

基于上述分析, 本文利用核函数相关理论给出一类本体函数迭代计算方法, 并将此本体优化算法运用于两个本体工程领域来分别验证其对植物学本体概念相似度计算和在大学本体之间建立本体映射的有效性.

1 新算法描述

在不引起混淆的前提下, 设 $v = \{v_1, \dots, v_p\}$ 同时表示本体概念、本体顶点 v 以及它对应的 p 维向量. 设 $\{(v_i, y_i)\}_{i=1}^n \subset \mathbb{R}^p \times \mathbb{R}$ 为本体样本集, 其中 v_i 和 y_i 分别表示输入和输出, n 为本体样本容量, 并设 $V = (v_1, v_2, \dots, v_n)$ 为本体数据矩阵. 设 f 为本体函数, $l: f \times V \times Y \rightarrow \mathbb{R}$ 为本体亏损函数, H 为希尔伯特空间. 在本文中, 假定特征空间即为希尔伯特空间 H , 即 H 中的元素为本体函数 $f: V \rightarrow Y$, 且设 $\langle \cdot, \cdot \rangle_H$ 为 H 空间的希尔伯特内积. 设 $K: V \times V \rightarrow \mathbb{R}$ 是 H 关联的半正定核函数, 即对于任意 $v \in V$ 有 $f(v) = \langle f, K(v, \cdot) \rangle_H$ 和 $H = \overline{\text{span}\{K(v, \cdot)\}}$, 对任意 $v, v' \in V$ 有 $K(v, v') \geq 0$. 根据上述核函数的性质描述, 可得 $K(v, v') = \langle K(v, \cdot), K(v', \cdot) \rangle_H$. 由此存在线性特征映射 φ 使其满足 $K(v, v') = \langle \varphi(v), \varphi(v') \rangle_H$. 由经典核函数表示定理, 有

$$f(v) = \sum_{i=1}^n w_i K(v_i, v),$$

其中 n 为基数, w_1, w_2, \dots, w_n 是权重参数, 且 $\mathbf{w} = (w_1, \dots, w_n)^T \in \mathbb{R}^n$ 为权重向量. 常用的核函数选择有 (任意 $v, v' \in V$): 多项式核 $K(v, v') = (v^T v' + a)^b$, $K(v, v') = \exp\{-\frac{\|v - v'\|_2^2}{2c^2}\}$, 其中 a, b, c 为参数.

给定本体样本集 S , 本体亏损函数 l , 最优本体函数可以用如下经验模型来表示:

$$f^* = \arg \min_{f \in H} \left\{ \frac{1}{n} \sum_{i=1}^n l(f(v_i), y_i) + \frac{\lambda}{2} \|f\|_H^2 \right\},$$

其中对应的期望误差本体优化模型可表示为:

$$f^* = \arg \min_{f \in H} \left\{ E_{v,y} [l(f(v), y)] + \frac{\lambda}{2} \|f\|_H^2 \right\}.$$

设格拉姆矩阵 $\mathbf{K}_{V,V} \in \mathbb{R}^{n \times n}$ 其元素为 $(\mathbf{K}_{V,V})_{ij} = K(v_i, v_j)$, $\mathbf{K}_V(\cdot) = (K(v_1, \cdot), K(v_2, \cdot), \dots, K(v_n, \cdot))^T$, 则有 $\mathbf{K}_{V,V} = (\mathbf{K}_V(v_1), \mathbf{K}_V(v_2), \dots, \mathbf{K}_V(v_n))$. 将表示理论应用于上述模型, 可得

$$\begin{aligned} f^* &= \arg \min_{w \in \mathbb{R}^n} \left\{ \frac{1}{n} \sum_{i=1}^n l\left(\sum_{j=1}^n w_j K(v_j, v_i), y_i\right) + \frac{\lambda}{2} \left\| \sum_{j=1}^n w_j K(v_j, \cdot) \right\|_H^2 \right\} \\ &= \arg \min_{w \in \mathbb{R}^n} \left\{ \frac{1}{n} \sum_{i=1}^n l(\mathbf{w}^T \mathbf{K}_V(v_i), y_i) + \frac{\lambda}{2} \mathbf{w}^T \mathbf{K}_{V,V} \mathbf{w} \right\}. \end{aligned} \quad (1)$$

上述转化说明本体函数的学习可以转化为权重向量的学习.

设 $l(f(v_i), y_i)$ 的导数为 $l'(f(v_i), y_i) = \frac{\partial l(f(v_i), y_i)}{\partial f(v_i)}$, 对应的随机函数梯度 (也称为 Frechet 导数) 表示为:

$$\nabla_f l(f(v_i), y_i)(\cdot) = \frac{\partial l(f(v_i), y_i)}{\partial f(v_i)} \frac{\partial f(v_i)}{\partial f}(\cdot).$$

此外, 利用核函数的性质还可以得到:

$$\frac{\partial f(v_i)}{\partial f} = \frac{\partial \langle f, K(v_i, \cdot) \rangle_H}{\partial f} = K(v_i, \cdot).$$

设 $t \in \mathbb{N}$ 为计数参数, $\eta_t > 0$ 为每次迭代的步长参数, f_t 为第 t 步得到的本体函数, $\lambda > 0$ 为平衡参数, 则原本体模型的迭代步骤可简单归纳为:

$$f_{t+1} = (1 - \eta_t \lambda) f_t - \eta_t \nabla_f l(f_t(v_i), y_i) = (1 - \eta_t \lambda) f_t - l'(f_t(v_i), y_i) K(v_i, \cdot).$$

设 $\mathbf{V}_t = (v_1, \dots, v_{t-1}) \in \mathbb{R}^{p \times (t-1)}$ 且 $\mathbf{K}_{V_t}(\cdot) = (K(v_1, \cdot), \dots, K(v_{t-1}, \cdot))^T$. 根据表示定理, 可知

$$f_t(v) = \sum_{i=1}^{t-1} w_i K(v_i, v) = \mathbf{w}_t^T \mathbf{K}_{V_t}(v),$$

其中 \mathbf{V}_{t+1} 和 \mathbf{w}_{t+1} 的更新规则可以表示为 $\mathbf{V}_{t+1} = (\mathbf{V}_t, v_t)$ 和 $\mathbf{w}_{t+1} = ((1 - \eta_t \lambda) \mathbf{w}_t - \eta_t l'(f_t(v_i), y_i))$. 设 M_t 为 t 时刻本体数据点的个数, 即 \mathbf{V}_t 的列数. 若每次迭代增加一个本体样本, 那么 $M_t = t - 1$.

设 $\mathbf{D} = (\mathbf{d}_1, \dots, \mathbf{d}_M) \in \mathbb{R}^{p \times M}$ 为本体数据集, 在机器学习中也称为字典, $H_D \subseteq H$ 为数据集 \mathbf{D} 生成的 H 的子空间, 即 $H_D = \text{span}\{K(\mathbf{d}_i, \cdot)\}_{i=1}^M = \{f: f(\cdot) = \sum_{i=1}^M w_i K(\mathbf{d}_i, \cdot) = \mathbf{w}^T \mathbf{K}_D(\cdot)\}$, 其中 $\mathbf{K}_{D,D}$ 表示由本体数据集 \mathbf{D} 得到的核矩阵, $\mathbf{K}_D(\cdot) = (K(\mathbf{d}_1, \cdot), \dots, K(\mathbf{d}_M, \cdot))$. 在众多学习算法中, 可以通过 \mathbf{D} 的选择使得 $M_t \ll t$, 即通过少量的本体数据来获取高效的优化函数. 在选取 $\mathbf{D} = \mathbf{V}_{t+1}$ 的条件下, 有

$$\begin{aligned} f_{t+1} &= \arg \min_{f \in H} \|f - ((1 - \eta_t \lambda) f_t - \eta_t \nabla_f l(f_t(v_i), y_i))\|_H^2 \\ &= \arg \min_{f \in H_{\mathbf{V}_{t+1}}} \|f - ((1 - \eta_t \lambda) f_t - \eta_t \nabla_f l(f_t(v_i), y_i))\|_H^2. \end{aligned}$$

设 $H_{D_{t+1}} = \text{span}\{K(\mathbf{d}_i, \cdot)\}_{i=1}^{M_{t+1}}$, 则有

$$f_{t+1} = \arg \min_{f \in H_{D_{t+1}}} \|f - ((1 - \eta_t \lambda) f_t - \eta_t \nabla_f l(f_t(v_i), y_i))\|_H^2,$$

定义在子空间 $H_{D_{t+1}} \subset H$ 上的映射算子 P , 使得

$$\begin{aligned} f_{t+1} &= \arg \min_{f \in H_{D_{t+1}}} \|f - ((1 - \eta_t \lambda) f_t - \eta_t \nabla_f l(f_t(v_t), y_t))\|_H^2 \\ &= P_{H_{D_{t+1}}} [(1 - \eta_t \lambda) f_t - \eta_t \nabla_f l(f_t(v_t), y_t)]. \end{aligned}$$

由于固定本体数据集 $D_{t+1} \in \mathbb{R}^{p \times M_{t+1}}$, 设 $\tilde{D}_{t+1} = (D_t, v_t)$, $\tilde{w}_{t+1} = ((1 - \eta_t \lambda) w_t, -\eta_t l'(f_t(v_t), y_t))$ 和 $\tilde{M} = M_t + 1$. 则本体权重向量学习模型 (1) 中的迭代可以进一步表示为:

$$\begin{aligned} w_{t+1} &= \arg \min_{w \in \mathbb{R}^{M_{t+1}}} \frac{1}{2\eta_t} \left\| \sum_{i=1}^{M_{t+1}} w_i K(d_i, \cdot) - \sum_{j=1}^{\tilde{M}} \tilde{w}_j K(\tilde{d}_j, \cdot) \right\|_H^2 \\ &= \arg \min_{w \in \mathbb{R}^{M_{t+1}}} \frac{1}{2\eta_t} \left(\sum_{i,j=1}^{M_{t+1}} w_i w_j K(d_i, d_j) - 2 \sum_{i,j=1}^{M_{t+1}, \tilde{M}} w_i \tilde{w}_j K(d_i, \tilde{d}_j) + \sum_{i,j=1}^{\tilde{M}} \tilde{w}_i \tilde{w}_j K(\tilde{d}_i, \tilde{d}_j) \right) \\ &= \arg \min_{w \in \mathbb{R}^{M_{t+1}}} \frac{1}{2\eta_t} (w^T K_{D_{t+1}, D_{t+1}} w - 2w^T K_{D_{t+1}, \tilde{D}_{t+1}} \tilde{w}_{t+1} + \tilde{w}_{t+1}^T K_{\tilde{D}_{t+1}, \tilde{D}_{t+1}} \tilde{w}_{t+1}) \\ &= K_{D_{t+1}, D_{t+1}}^{-1} K_{D_{t+1}, \tilde{D}_{t+1}} \tilde{w}_{t+1}. \end{aligned}$$

由此得到本体优化模型的近似解.

2 实验

2.1 本体相似度计算实验

采用植物学本体 PO 来验证本文本体算法对相似度计算的有效性, 而该数据是植物学中经典数据, 常被植物学家当作词典来查询. 此外, 对植物本体 PO 的研究还有助于帮忙植物学家和相关领域专家了解植物学相关概念之间的相互联系和各个阶段变化的关联性. 其 PO 本体 O_1 的总体结构可概括为图 1, 数据来源于 <http://www.plantontology.org>. 本文使用 $P@N$ 准确率来衡量相似度计算的准确率, 同时为了显示本文本体算法的有效性, 所采用的其他 3 类已知经典本体学习算法也同时作用于 PO 本体: 基于快速排序学习的本体算法^[16]、基于一般排序学习方法的本体算法^[17]、基于 NDCG 测度计算的本体算法^[18]. 将 4 种算法得到的结果进行对比, 表 1 显示了部分数据, 即当 $N=3, 5, 10$ 时 4 类本体学习算法准确率对比.

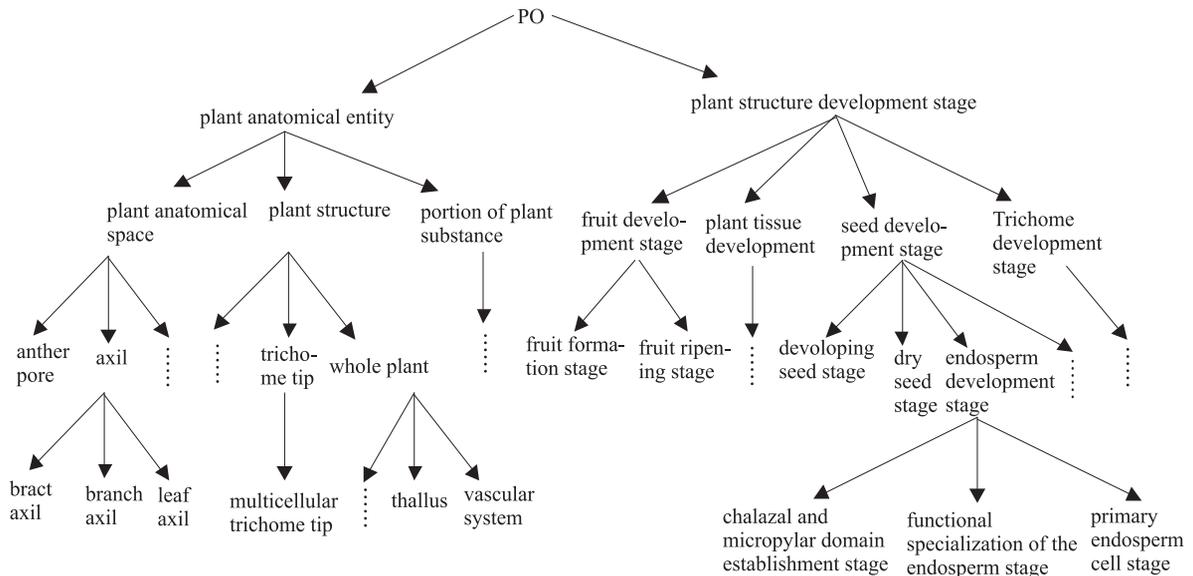


图1 PO本体 O_1

表 1 实验 1 部分数据

算法名称	$P@3$ 平均准确率	$P@5$ 平均准确率	$P@10$ 平均准确率
本文算法	0.468 4	0.574 1	0.740 7
快速排序算法	0.428 2	0.484 9	0.563 2
一般排序算法	0.454 9	0.511 7	0.585 9
NDCG 本体算法	0.483 1	0.563 5	0.687 1

通过表 1 中准确率对比可知, 本文本体学习算法得到的 $P@N$ 准确率要明显高于另外 3 类经典本体学习算法, 且这种准确率上的优势是随着 N 值的逐渐增加而增加. 从中可得到结论, 新本体算法对于植物学 PO 本体而言, 在此数据集上进行相似度计算是高效的.

2.2 本体映射实验

第 2 个实验将验证本文算法对特殊领域构建本体映射的有效性. 本文选取的是常用的大学本体 O_2 和 O_3 , 如图 2 和图 3 所示. 该本体数据包含了大学的一些基本组织构建, 由于本体顶点的总数比较少, 本文选取的样本也只能选取少量的顶点. 在评判数据的优劣上, 继续沿用 $P@N$ 准确率. 同时为了有所比较, 本文将基于 ADAL 方法的本体学习算法^[19]、基于距离计算的本体算法^[20]、基于边际方法的本体算法^[21]应用于大学本体, 并比较由这 4 类本体算法得到的 $P@N$ 准确率. 当 $N=1, 3, 5$ 时的数据见表 2.

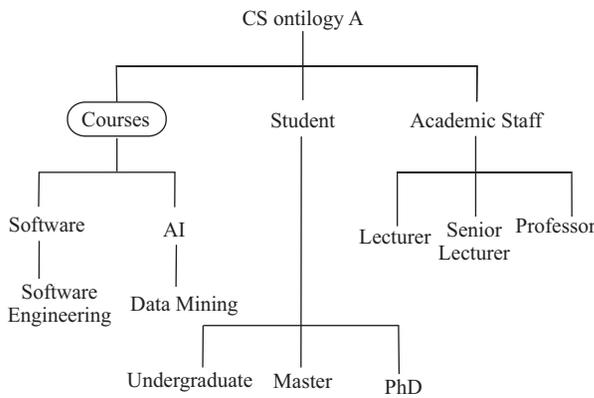


图2 “大学” 本体 O_2

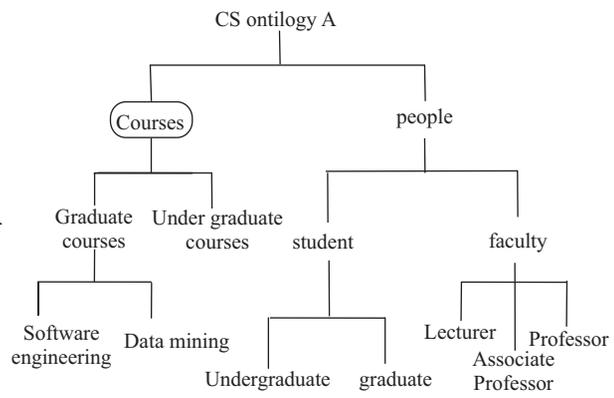


图3 “大学” 本体 O_3

表 2 实验 2 部分数据

T 算法名称	$P@1$ 平均准确率	$P@3$ 平均准确率	$P@5$ 平均准确率
本文算法	0.535 7	0.619 0	0.714 3
ADAL 本体算法	0.500 0	0.596 2	0.685 7
基于距离本体算法	0.464 3	0.571 4	0.664 2
基于边际本体算法	0.428 6	0.523 8	0.592 9

由表 2 中的数据分析可知, 本文所给出的基于核方法的本体迭代算法对于在“大学”本体 O_2 和 O_3 间建立基于相似度的本体映射而言, 相较其他 3 类传统本体学习算法, 本文算法得到的 $P@N$ 准确率更高. 由于本实验样本数量和本体中顶点的总数量都相对较少, 因此 N 取 1, 3, 5 时的准确率已经可以充分说明问题, 同时 $P@1, P@3$ 和 $P@5$ 分别体现了 top1, top3 和 top5 的命中率, 它们也是用户最关心的最相似前 N 个概念的命中率.

3 结语

相似度计算是信息科学研究的重点内容, 而本体相似度计算是本体算法各种应用的核心. 本文利用核函数的表示原理得到本体函数的迭代策略, 同时将本体函数的学习转化为权重向量的计算. 最后通过两个

具体实例来说明算法对 PO 本体相似度计算和大学本体间映射构建的有效性.

[参考文献]

- [1] PRZYDZIAL M J, BHHATARAI B, KOLETI A, et al. GPCR ontology: development and application of a G protein-coupled receptor pharmacology knowledge framework [J]. *Bioinformatics*, 2013, 29 (24): 3211–3219.
- [2] KOEHLER S, DOELKEN S C, MUNGALL C J, et al. The human phenotype ontology project: linking molecular biology and disease through phenotype data [J]. *Nucleic Acids Research*, 2014, 42: 966–974.
- [3] IYANOYIC M, BUDIMAC Z. An overview of ontologies and data resources in medical domains [J]. *Expert Systems and Applications*, 2014, 41 (11): 5158–5166.
- [4] HRISTOSKOVA A, SAKKALIS V, ZACHARIOUDAKIS G, et al. Ontology-driven monitoring of patient's vital signs enabling personalized medical detection and alert [J]. *Sensors*, 2014, 14 (1): 1598–1628.
- [5] KABIR M A, HAN J, YU J, et al. User-centric social context information management: an ontology-based approach and platform [J]. *Personal and Ubiquitous Computing*, 2014, 18 (5): 1061–1083.
- [6] LASIERRA N, ALESANCO A, GARCIA J. Designing an architecture for monitoring patients at home: ontologies and web services for clinical and technical management integration [J]. *IEEE Journal of Biomedical and Health Informatics*, 2014, 18 (3): 896–906.
- [7] CARLINI D B, MAKOWSKI M. Codon bias and gene ontology in holometabolous and hemimetabolous insects [J]. *Journal of Experimental Zoology Part B-Molecular and Developmental Evolution*, 2015, 324 (8): 686–698.
- [8] NICOLAI C. Deflationary truth and the ontology of expressions [J]. *Synthese*, 2015, 192 (12): 4031–4055.
- [9] CORREAE C G P, MOURA A M C, CLAUDIA C M. A multi-ontology approach to annotate scientific documents based on a modularization technique [J]. *Journal of Biomedical Informatics*, 2015, 58: 208–219.
- [10] 高伟, 梁立, 徐天伟, 等. 半监督 k -部排序算法及在本体中的应用 [J]. *中北大学学报 (自然科学版)*, 2013, 34 (2): 140–146.
- [11] 高伟, 梁立, 徐天伟. 基于正则化瑞利系数的半监督 k -部排序学习算法及应用 [J]. *西南师范大学学报 (自然科学版)*, 2014, 39 (4): 124–128.
- [12] 彭波, 徐天伟, 高伟. 排序框架下梯度下降迭代本体算法 [J]. *科学技术与工程*, 2015, 15 (15): 77–81.
- [13] 吴剑章, 朱林立, 高伟. 本体算法中相似度矩阵的学习 [J]. *小型微型计算机系统*, 2015, 36 (4): 773–777.
- [14] 兰美辉, 甘健侯, 任友俊, 等. k -部排序学习算法的可学习性分析 [J]. *西南大学学报 (自然科学版)*, 2016, 38 (3): 177–183.
- [15] 王燕, 高伟. 基于距离测度计算的本体学习算法 [J]. *西南师范大学学报 (自然科学版)*, 2018, 43 (1): 40–46.
- [16] HUANG X, XU T W, GAO W, et al. Ontology similarity measure and ontology mapping via fast ranking method [J]. *International Journal of Applied Physics and Mathematics*, 2011, 1 (1): 54–59.
- [17] WANG Y, GAO W, ZHANG Y G, et al. Ontology similarity computation use ranking learning method [C] //The 3rd International Conference on Computational Intelligence and Industrial Application. 2010: 20–22.
- [18] GAO W, LIANG L. Ontology similarity measure by optimizing NDCG measure and application in physics education [J]. *Future Communication, Computing, Control and Management*, 2011, 142: 415–421.
- [19] GAO W, ZHU L L, WANG K Y. Ontology sparse vector learning algorithm for ontology similarity measuring and ontology mapping via ADAL technology [J]. *International Journal of Bifurcation and Chaos*, 2015, 25 (14): 349–351.
- [20] GAO W, FARAHANI M R, ASLAM A, et al. Distance learning techniques for ontology similarity measuring and ontology mapping [J]. *Cluster Computing*, 2017, 20 (2): 959–968.
- [21] GAO W, BAIG A Q, ALI H, et al. Margin based ontology sparse vector learning algorithm and applied in biology science [J]. *Saudi Journal of Biological Sciences*, 2017, 24 (1): 132–138.