

基于深度信念网络的个性化信息推荐

王兆凯^{1a}, 李亚星^{1a}, 冯旭鹏^{1b}, 刘利军^{1a}, 黄青松^{1a,2}, 刘晓梅³

(1. 昆明理工大学 a. 信息工程与自动化学院; b. 教育技术与网络中心, 昆明 650500;

2. 云南省计算机技术应用重点实验室, 昆明 650500; 3. 昆明佳谦科技有限公司, 昆明 650500)

摘 要: 为在信息推荐过程中挖掘出更多的信息关系, 提出一种基于深度信念网络的信息推荐方法。利用模糊聚类进行预处理以达到跨类推荐的目的, 根据用户浏览记录通过网络计算高分信息, 并结合用户兴趣, 使用潜在狄利克雷分配模型对高分信息进行权值调整, 从而提高推荐准确率。在整个推荐过程中网络会根据用户行为对推荐信息权值进行相应调整。实验结果表明, 该方法的推荐成功率比 BP 神经网络提高 5.7%。

关键词: 信息推荐; 深度学习; 深度信念网络; 潜在狄利克雷分配模型; 模糊聚类

中文引用格式: 王兆凯, 李亚星, 冯旭鹏, 等. 基于深度信念网络的个性化信息推荐[J]. 计算机工程, 2016, 42(10): 201-206.

英文引用格式: Wang Zhaokai, Li Yaxing, Feng Xupeng, et al. Personalized Information Recommendation Based on Deep Belief Network[J]. Computer Engineering, 2016, 42(10): 201-206.

Personalized Information Recommendation Based on Deep Belief Network

WANG Zhaokai^{1a}, LI Yaxing^{1a}, FENG Xupeng^{1b}, LIU Lijun^{1a}, HUANG Qingsong^{1a,2}, LIU Xiaomei³

(1a. Faculty of Information Engineering and Automation; 1b. Educational Technology and Network Center,

Kunming University of Science and Technology, Kunming 650500, China;

2. Yunnan Key Laboratory of Computer Technology Applications, Kunming 650500, China;

3. Kunming Jiaqian Science and Technology Co., Ltd., Kunming 650500, China)

[Abstract] In order to mine more information relationship in information recommendation, this paper puts forward an information recommendation method based on the Deep Belief Network (DBN). It uses fuzzy clustering to do some pretreatment in order to achieve the aim of cross-category recommendation. According to the user browsing history, it works out high-mark information through the Internet, and then uses Latent Dirichlet Allocation (LDA) model combining the interests of users to do some weight value adjustments. So as to improve the accuracy of recommendation. In the process of recommendation, the Internet will adjust the weight value of recommended information according to the action of users. Experimental results show that the recommendation accuracy of this method can be improved by 5.7% than BP neural network.

[Key words] information recommendation; deep learning; Deep Belief Network (DBN); Latent Dirichlet Allocation (LDA) model; fuzzy clustering

DOI: 10.3969/j.issn.1000-3428.2016.10.035

1 概述

如今互联网发展迅速, 上网成了人们获取信息的主要手段, 但爆炸式的数据增长使用户在短时间内从海量信息中获取需要的信息成了一大难题。信息推荐技术可解决此类问题, 主要运用信息检索、信息过滤、数据挖掘、人工智能等方法帮助用户在海量信息中筛选符合其个性化需求的信息资源。目前信

息推荐方式主要有 4 种: (1) 基于统计的推荐方式; (2) 基于内容的推荐方式^[1-2]; (3) 协同过滤方式; (4) 混合推荐方式。基于统计的推荐方式由于计算过于简单, 因此推荐效果不太理想。基于内容的推荐方式只考虑了内容相关一方面, 许多潜在关系无法直接学习得到, 只有结合社会经验, 进一步推理才能获得, 其推荐能力有限。协同过滤只有针对数据量相对较小且更新不太频繁的信息进行推

基金项目: 国家自然科学基金资助项目(81360230); 科技部科技型中小企业技术创新基金资助项目(13C26215305404)。

作者简介: 王兆凯(1991—), 男, 硕士, 主研方向为机器学习、自然语言处理; 李亚星、冯旭鹏, 硕士; 刘利军, 讲师、硕士; 黄青松(通讯作者), 教授; 刘晓梅, 工程师。

收稿日期: 2015-08-06

修回日期: 2015-10-23

E-mail: sanxianwei@163.com

荐时才有较好的效果,其可适用的处理对象范围过于狭窄。

目前,对神经网络应用研究不断成熟,利用神经网络进行信息推荐也逐渐成为主流。文献[3]采用神经网络训练得到目标用户的偏好模型进行内容推荐。

相比于声音和图像,语言是唯一的非自然信号,是完全由人类大脑产生和处理的符号系统,所以,模仿人脑结构的深度学习网络在处理自然语言上相比浅层机器学习有明显优势^[4-5]。深度学习是一类新兴的多层神经网络学习算法,可缓解传统训练算法的局部最小性^[6]。其可以利用高纬度的空间向量模型^[7]作为辅助,对自然语言处理达到理想的效果。文献[8]利用深度学习来做中文微博情感分析的可行性,采用递归神经网络来发现与任务相关的特征。

文献[9]提出了深度信念网络(Deep Belief Network, DBN)和对此网络的训练方式。深度信念网络模型是一种概率生成模型,其通过调整神经元间的权重,使整个神经网络按照最大概率来生成数据。由于 DBN 是一种深度神经网络,因此很难用传统的梯度下降算法进行训练,非监督贪婪逐层训练方法是目前主流的训练方式。DBN 及其训练方法被广泛应用到于图像识别和语音识别领域,目前在文本处理领域也有一些研究成果,文献[10]利用 DBN 模型进行基于特征的实体关系抽取的研究,文献[11]利用 DBN 模型进行基于语义特征的代词消解的研究,文献[12]利用 DBN 模型进行情感分类研究。

高维特征的深度学习有利于挖掘出更多的文本信息,在此基础上结合用户的信息反馈使得训练内容不受限于文本,可以获得更多的潜在信息。本文提出一种基于 DBN 的信息推荐方法。首先利用模糊聚类对信息进行预处理,以使 DBN 能适用于信息推荐。然后通过潜在狄利克雷分配(Latent Dirichlet Allocation, LDA)模型对不同用户的 DBN 推荐结果做进一步信息匹配度调整,从而达到提升推荐效果的目的。

2 预处理

为了使推荐冷启动阶段也能有较好的推荐效果且减少推荐计算量,推荐前先对信息进行聚类。聚类时考虑到信息涵盖多种主题,为了使不同主题间的信息能产生跨类推荐的效果,所以,预处理用模糊聚类^[13]的方式来对信息进行处理。

令 u_i 表示第 i 个信息文本对象,即: $X = \{u_1, u_2, \dots, u_n\}$, 其中, $u_i = \{x_{i1}, x_{i2}, \dots, x_{im}\}$, x_{ij} 表示第 i 个信息文本对象的第 j 个特征词。

设 u_i 和 u_j 的相似关系为 $R(u_i, u_j) = r_{ij}$, 相似关系函数 $R(u_i, u_j)$ 的计算方式有多种。本文的计算方式是先利用计算信息增益的方式对每篇文本进行特征提取,再用相互比较特征值的方式计算文本间的相似度。如果 2 篇文本相同的特征向量数为 n , 则相似度为 $\frac{n}{N}$, $N = \max(y, z)$, 变量 y, z 分别为 u_i 和 u_j 的特征向量数。有了文本之间的相似度就可以建立起一个相似系数矩阵 $L = \{r_{ij}\}_{n \times n}$ 。

本文利用传递闭包法进行聚类。传递闭包法是利用相似系数矩阵进行自相乘,以求得一个最小模糊等价矩阵,可表示为:

$$L' = T(L) = L \times L \quad (1)$$

更新模糊相似矩阵的计算方式为:

$$t_{iz} = \max_j(\min(t_{ij}, t_{jz})) \quad (2)$$

这样传递闭包会在传递 t 次后得出收敛的模糊相似矩阵,且 $t < n$ 。设定一个阈值 P , 收敛的模糊相似矩阵里小于 P 的值为 0, 大于 P 的值为:

$$p = \frac{r - p}{1 - p} \quad (3)$$

在聚类过程中会出现孤立的文本,处理方式是选择一个和孤立文本 r 最大且非孤立的文本 T 。将 T 和其他文本的相似度 r 除以一个相对大的值 W , 再一一赋值给孤立文本的对应相似度位置上。

3 基于 DBN 模型的信息推荐方法

3.1 深度信念网络

DBN 由若干层受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)和一层反向传播(Back Propagation, BP)神经网络组成的深度神经网络。由于深度神经网络层数相比浅层学习的神经网络多,因此利用传统反向传播的训练方式会造成容易陷入局部最优且训练过程较慢的问题。

DBN 将文本特征细分到词,甚至是字,本文选用词作为最小特征量。通过词与词之间的训练进行特征降维,计算出高维的抽象特征。网络每层的维度越高逼近能力越强,但是会降低网络的泛化能力,所以,网络维度应逐层降维,提高网络泛化能力。降维幅度不宜过大,否则会使降维过程在降低噪声信息的同时损失重要的信息,导致结果剧烈震荡^[10]。如图 1 所示,目前训练深度神经网络模型权值一般选用非监督贪婪逐层方法。




图1 DBN网络结构

此方法主要分两步:

(1) 从下至上分别对每一层RBM网络进行无监督单独训练,下一层的输出是上一层的输入。

(2) DBN的最后一层为BP神经网络,其接收RBM输出的抽象特征向量作为自己的输入,再利用BP算法进行有监督学习。

在设计面向信息推荐的RBM神经网络时,考虑到信息推荐要对大量数据请求进行处理,同时为了使每一层RBM达到整体最优,需将第(2)步BP训练分为系统调优和用户调优。系统调优是利用已收集的数据进行网络整体调优,用户调优是在推荐过程中利用用户反馈进行仅对BP神经网络层的调优。通过上述非监督贪婪逐层方法训练深度神经网络,可以克服网络训练易陷入局部最优和训练时间过长的缺点。

DBN的输入层选用推荐文本的特征词为输入单元,抽取推荐文本TF-IDF(Term Frequency-Inverse Document Frequency)值最大的前2000个特征词,作为输入层的2000个神经元。取用户最近浏览的前3条信息,将信息分词后作为输入数据,输入神经元的赋值策略如式(4)所示,如果输入层有该词则将此神经元赋值为1,否则为0。该输入即为RBM神经网络首层的初始输入。

$$E(v, h | \theta) = \frac{1}{2} (v^T w h + b^T v + c^T h) \quad (4)$$

3.2 DBN中的RBM网络设计

RBM由一层可见层 V 和一层隐含层 H 组成,

如图2所示,其中两层之间的神经元都是全连接的,但层内神经元是互不相连的。RBM的神经元值一般取0或1。




图2 RBM网络结构

这里 v 表示可见节点状态矩阵, h 表示隐藏节点状态矩阵, θ 表示要求的参数矩阵 w, b 和 c, b 和 c 分别为可见层和隐藏层的偏置向量, w 为2层连接边的权值矩阵。通过上式可以得到 (v, h) 的联合概率分布:

$$P(v, h | \theta) = \frac{e^{-E(v, h | \theta)}}{z(\theta)} \quad (5)$$

其中, $Z(\theta)$ 为:

$$Z(\theta) = \sum_{v, h} e^{-E(v, h | \theta)} \quad (6)$$

从而可以得到可见层节点的条件概率为:

$$P(v_i = 1 | h) = \frac{1}{1 + \exp(-c_i - \sum_j h_j w_{ji})} \quad (7)$$

隐藏层节点的条件概率为:

$$P(h_j = 1 | v) = \frac{1}{1 + \exp(-b_j - \sum_i v_i w_{ij})} \quad (8)$$

对比散度是一种快速训练RBM的方法,其主要思想是利用可见层状态计算出隐藏层状态(见式(8))。再通过计算出来的隐藏层状态计算出新的可见层状态(见式(7))。如果新计算出来的可见层状态和原状态相同,则表示隐藏层能很好地抽象出可见层的特征。但大多数情况下需要不断地调整误差,使得原状态和计算后的状态误差尽量小。

对比散度的训练步骤如下:

(1) 初始化 θ ,并设定训练的迭代次数。

(2) 输入 v^0 ,利用式(7)和式(8)计算出 h^0, v^1, h^1 。

(3) 对RBM网络的系数进行调整。

w 权值调整公式如下:

$$w = w + \eta (P(h^0 = 1 | v^0) v^{0T} - P(h^1 = 1 | v^1) v^{1T})$$

偏置向量 b 和 c 调整:

$$b = b + \eta (v^0 - v^1)$$

$$c = c + \eta (P(h^0 = 1 | v^0) - P(h^1 = 1 | v^1))$$

(4) 如果未满足迭代次数,则跳转到步骤(2)。如果满足迭代次数或数据收敛,结束训练。

3.3 用于信息推荐的 BP 神经网络设计

BP 神经网络是一种按误差反向传播的前馈网络。通常 BP 神经网络有一个输入层、一个隐藏层和一个输出层。反向传播的训练主要分两步:(1)正向传播,将抽象特征从输入层输入,在隐藏层计算出被触发的节点值,传向输出层。在输出层把现行输出和期望输出进行比较,如果现行输出不等于期望输出,则进入反向传播过程。(2)反向传播,把误差信号按原来正向传播的通路反向传回,并对每层的各个神经元的权重系数进行修改,使误差趋向最小。为了控制系数变换的步长,需加入学习速率这一系数。

DBN 的末层是一层 BP 神经网络,为了使整个网络可用于个性化信息的推荐,BP 神经网络层的设计起到决定性的作用。这里的 BP 神经网络各层的设计策略如下:(1)输入层输入的数据为经过 RBM 网络抽象出来的抽象特征值;(2)隐藏层神经元个数为文本经过模糊聚类出来的类个数;(3)输出层的每个神经元代表一个推荐文本。输出层的神经元仅与其文本所聚类的隐藏层神经元相连接。

BP 神经网络正向传播的公式为:

$$X_j^k = \sum_i W_{ij}^{k-1} X_i^{k-1} \quad (9)$$

$$X_j^{k'} = \begin{cases} X_j^k & X_j^k \geq \varphi \\ 0 & X_j^k < \varphi \end{cases} \quad (10)$$

其中, W_{ij}^{k-1} 表示在第 $(k-1)$ 层上连接本层第 i 个神经元与下一层的第 j 个神经元边的权值; X_i^k 表示第 k 层第 i 个神经元的计算值; $X_j^{k'}$ 为第 k 层第 j 个神经元经过阈值 φ 筛选后的值。

输出层到隐藏层的反向传播误差计算方式为:

$$e_i = \eta(Y_i - X_i) = (1 - X_i \cdot X_i)(Y_i - X_i) \quad (11)$$

隐藏层到输入层的反向传播误差计算方式为:

$$e_i = \eta \sum_j e_j W_{ij} = (1 - X_i \cdot X_i) \sum_j e_j W_{ij} \quad (12)$$

其中, e_i 表示输出层第 i 个神经元的误差值; Y_i 表示输出的期望值; X_i 表示输出的实际值; η 表示学习速率,计算方法如下:

$$\eta = 1 - X_i \cdot X_i \quad (13)$$

X_i 的取值范围为 $[-1, 1]$,这里利用式(13)的计算方式是让倾向性越大的值越难改变,也就是越倾向 -1 或 1 两边的值学习速率值越小,这模拟了人对事物的认知。一般人对某件事物越肯定越难改变其对某事物的看法,也就是学习速率越小。

计算出每层神经元的误差,最后再对每层神经元权值进行更新,更新方式为:

$$W'_{ij} = W_{ij} + e_i \quad (14)$$

4 LDA 模型推荐信息个性化增强

由于信息文本本身有多个内容属性且每个人的兴趣倾向又不同,因此造成通过 DBN 推荐出来权值最高的信息不一定是用户最想要的,这样的推荐的内容仅与用户的浏览记录有关,缺少对用户群体的变化产生变化的考虑。本文解决方式是利用 DBN 筛选出的前几条信息文本进行特征提取,再结合用户的兴趣进行更精确的推荐。利用 LDA 分析用户浏览记录,提取用户的兴趣^[14]。为了获取更有代表性的主题,在进行主题提取前需要对用户浏览的信息记录进行特征提取。由于用户的兴趣可分为短期兴趣和长期兴趣,而且用户兴趣会随着时间发生变化,因此本文对用户浏览记录的前 N 篇文本进行 LDA 分析,提取用户的短期兴趣词。对用户浏览记录的前 M 篇文本进行 LDA 分析,提取用户的长期兴趣词,这里 N 远小于 M 。有了用户的兴趣词,将其与经过 BP 神经网络筛选出来的文本进行特征词加权计算:

$$f = \frac{\alpha \times k_1 + \beta \times k_2}{W} + R \quad (15)$$

其中, k_1 表示文本特征词与短期兴趣相匹配的词数; k_2 表示文本特征词与长期兴趣相匹配的词数; W 表示文本的特征词数; R 表示 BP 神经网络输出层神经元的权值; α 和 β 分别为短期兴趣和长期兴趣的系数,对于信息推荐来说短期兴趣要比长期兴趣更重要,所以 $\alpha > \beta$ 。最后根据 f 加权函数计算出最终的推荐结果。

5 实验与结果分析

本文共进行了 5 个实验,目的分别为:(1)测试模型推荐成功率的增长速度;(2)测试 DBN 层数对推荐成功率的影响;(3)对比模糊聚类与 k-means 聚类的推荐成功率;(4)测试 LDA 个性化过程对推荐成功率的影响;(5)对比此模型与其他推荐模型的推荐成功率。

实验 1 请 24 位志愿者参与,以新闻为测试文本。实验开始前要求志愿者进行自由浏览,其目的是获取志愿者的兴趣。获取一定量的志愿者兴趣后开始进入测试阶段。测试阶段系统结合志愿者浏览记录和兴趣推荐出前 5 篇得分最高且未浏览

过的新闻,显示它们标题和前 200 字的正文内容,若志愿者对推荐的新闻不感兴趣可点击跳过,系统对这 5 篇新闻进行反向传播调整权值,再继续推荐,若志愿者点击其中一篇进行正文浏览表示推荐成功,系统对被点击的新闻进行反向传播调整权值,其他 4 篇新闻权值不变,志愿者浏览完后系统继续推荐。选取 600 篇新闻作为推荐文本,共收集点击次数 4 502 次,其中包括 1 628 次失败推荐和 2 874 次成功推荐。网络的 RBM 节点分别为 2 000-1 600-1 200。

实验前对 600 篇文本经过模糊聚类处理后共聚了 64 个类,模糊聚类的阈值取 0.5。在对用户进行兴趣提取时,取用户浏览的前 10 条新闻作为计算短期兴趣的文本,取用户浏览的前 100 条新闻作为计算长期兴趣的文本,如果用户浏览新闻记录数量不足则取全部值。用 LDA 对浏览记录进行处理时,需要预先设定主题数,即长期或短期兴趣数目。本实验预设定的主题数为:

$$n = \left\lfloor \frac{k}{5} \right\rfloor \quad (16)$$

其中, n 表示长期或短期兴趣数目; k 表示用户浏览新闻记录个数。

实验结果如表 1 和表 2 所示。从表 1 中可以观察到,随着点击次数的增加,推荐成功率也随之增加。特别是点击率从 1 000 增加到 2 000 时,推荐成功率有明显提高。表 2 对最近 1 000 次点击成功率进行平均值统计。从表中能看到在点击 2 000 后成功率已达到了 64.7%,可见本文方法在实时训练时能快速达到令人满意的效果。

表 1 推荐成功率 %

点击次数	推荐成功率
1 000	43.7
2 000	54.2
3 000	59.4
4 000	62.7
4 500	63.8

表 2 最近 1 000 次平均推荐成功率 %

点击次数	推荐成功率
1 000	43.7
2 000	64.7
3 000	69.8
4 000	72.6
4 500	72.9

实验 2 不同深度的 DBN 网络训练的误差是不同的^[15],为测试 RBM 层数对推荐效果的影响,将一层 RBM 和两层 RBM 做实验进行对比。实验 1 已经获得了两层 RBM 的推荐效果。本实验在与实验 1 相同的实验条件下进行实验,一层 RBM 的节点数为 2 000~1 200,BP 神经网络层不变。实验结果如图 3 所示。可以看出,两层 RBM 比一层 RBM 有更好的推荐效果。通过对图 3 分析可以推测,一层 RBM 和两层 RBM 前期推荐效果没有太大的差别,主要由于推荐文本没有和抽象特征有较好对应,即 BP 层权值还没训练完全。而后面推荐效果拉开差距主要原因是两层 RBM 比一层 RBM 有更好的特征抽象能力。




图 3 不同 RBM 模型的成功率

实验 3 为对比模糊聚类与 k-means 聚类的推荐成功率,将推荐文本用 k-means 聚类成与模糊聚类相同的类个数后,在与实验 1 相同的条件下进行实验。实验结果如图 4 所示。可以看出,k-means 聚类收敛速度和模糊聚类相近,但成功率相比模糊聚类偏低。从而可以得出过于封闭的聚类方式会降低推荐系统的内容质量,相比之下相关信息的不同类内容对用户更有吸引效果。




图 4 不同聚类的方法的成功率

实验 4 为测试 LDA 个性化过程对推荐效果的影响,将模型去掉最后一步 LDA 计算,同时在与实验一同等条件下进行实验,实验结果如图 5 所示。




图 5 有无 LDA 过程的成功率

可以看出,一开始 LDA 过程对成功率的影响不大,这是由于网络权值还处于冷启动状态。当网络权值经过一定训练后,LDA 过程对推荐产生了较大的影响,成功率的差值开始拉大。从而可以证明推荐过程中,考虑用户兴趣对系统推荐成功率提升有一定促进作用。

实验 5 将该推荐模型和其他推荐方式进行对比。取基于内容主题标签的推荐方式和 BP 神经网络的推荐方式作为基准实验,结果如表 3 所示。可以看出,两层 RBM 的推荐效果分别优于基于内容主题标签 18.2%,BP 神经网络 5.7%。并且一定量 RBM 层数的增加有助于推荐效果进一步提高。

表 3 推荐成功率对比

推荐方法	成功率 %
一层 RBM 的 DBN	69.7
两层 RBM 的 DBN	72.9
基于内容主题标签	54.7
BP 神经网络	67.2

6 结束语

本文提出一种基于深度信念网络的信息推荐算法。首先利用模糊聚类对信息进行跨类预处理,然后通过深度信念网络计算出高分信息,并在此基础上结合用户兴趣对高分信息进行权值调整,最终推荐出用户比较感兴趣的内容。深度信念网络可对输入特征进行更好的抽象化表示,发现特征中主要影

响因素并降低特征的维度。实验结果表明,深度信念网络经过多次实时训练后较其他方法有更高的推荐点击量,推荐成功率比 BP 神经网络提高了 5.7%。DBN 层数和每层的神经元个数设计还有很大的改进空间,这将是下一步的研究方向。

参考文献

- [1] 陈宏,陈伟.基于多主题追踪的网络新闻推荐[J]. 计算机应用,2011,31(9):2426-2428.
- [2] 陶永才,何宗真,石磊,等.基于加权动态兴趣度的微博个性化推荐[J]. 计算机应用,2014,34(12):3491-3496.
- [3] 辛菊琴,蒋艳,舒少龙.综合用户偏好模型和 BP 神经网络的个性化推荐[J]. 计算机工程与应用,2013,49(2):57-60.
- [4] LeCun Y, Bengio Y, Hinton G. Deep Learning [J]. Nature,2015,521(7553):436-444.
- [5] 余凯,贾磊,陈雨强,等.深度学习的昨天、今天和明天[J]. 计算机研究与发展,2013,50(9):1799-1804.
- [6] 孙志军,薛磊,许阳明,等.深度学习研究综述[J]. 计算机应用研究,2012,29(8):2806-2810.
- [7] Mikolov T, Yih W, Zweig G. Linguistic Regularities in Continuous Space Word Representations [C]//Proceedings of NAACL-HLT'13. Atlanta, USA:[s.n.],2013:746-751.
- [8] 梁军,柴玉梅,原慧斌,等.基于深度学习的微博情感分析[J]. 中文信息学报,2014,28(5):155-161.
- [9] Hinton G E, Osindero S, Teh Y W. A Fast Learning Algorithm for Deep Belief Nets[J]. Neural Computation, 2006,18:1527-1554.
- [10] 陈宇,郑德权,赵铁军.基于 Deep Belief Nets 的中文名实体关系抽取[J]. 软件学报,2012,23(10):2572-2585.
- [11] 奚雪峰,周国栋.基于 Deep Learning 的代词指代消解[J]. 北京大学学报:自然科学版,2014,50(1):100-110.
- [12] Zhou Shusen, Chen Qingcai, Wang Xiaolong. Active Deep Learning Method for Semi-supervised Sentiment Classification[J]. Neurocomputing,2013,120:535-546.
- [13] 马光志,倪国元.一种增量式模糊聚类算法[J]. 微计算机应用,2005,26(1):5-7.
- [14] 邸亮,杜永萍. LDA 模型在微博用户推荐中的应用[J]. 计算机工程,2014,40(5):1-6.
- [15] 潘广源,柴伟,乔俊飞. DBN 网络的深度确定方法[J]. 控制与决策,2015,30(2):256-260.

编辑 金胡考