

HDP 消息传递算法

王 杰,严建峰,刘晓升,杨 璐

(苏州大学 计算机科学与技术学院,江苏 苏州 215006)

摘 要: 分层狄利克雷过程(HDP)可以视为潜在狄利克雷分配(LDA)主题模型在无参方面的扩展,解决了传统主题模型中选择主题数目的问题. 消息传递算法则是从消息因子图模型的角度出发进而解决贝叶斯后验概率推断问题. 提出将消息传递算法应用到分层狄利克雷过程模型上的方案,并从最大期望算法的角度来证明该算法的收敛性,最终从混淆度的角度将该算法与传统算法进行对比. 实验结果表明消息传递算法在混淆度方面相比其他算法有明显的优势,且收敛速度较快.

关键词: 分层狄利克雷过程;消息传递算法;无参数主题模型;最大期望算法

中图分类号: TP3

文献标识码: A

文章编号: 1000-7180(2016)03-0142-05

Belief Propagation Algorithm for HDP

WANG Jie, YAN Jian-feng, LIU Xiao-sheng, YANG Lu

(School of Computer Science and Technology, Soochow University, Suzhou 215006, Ch,ina)

Abstract: The hierarchical Dirichlet process (HDP) model is an extension of the latent Dirichlet allocation(LDA) on the aspect of non-parametric in order to solve the problem of setting number of the topics. Belief propagation algorithm is an algorithm based on the factor graph model to inference the Bayesian posterior probability. In our paper, we propose to apply the belief propagation algorithm on the HDP model, and prove the convergence of the algorithm from the view of expectation maximization algorithm. Comparing with other algorithms, the belief propagation algorithm based on HDP is better than others in accuracy measured by perplexity

Key words: shierarchical Dirichlet process; belief propagation algorithm; non-parametric topic model; expectation maximize

1 引言

随着互联网的高速发展,网络数据正呈现出爆炸式的增长. 面对如此庞大的数据,如何管理这些数据并从中找出真正所需要的信息成为一大难题. 主题模型是解决该问题的有效手段之一,我们可以通过主题模型将一篇文档归纳为简单的几个主题,使得人们可以根据主题快速定位到所需要的相关信息,从而解决人们阅读大量信息的烦恼^[1].

直接确定主题的数量,即对于具体一篇文档我们要确定其究竟该有多少个主题,换句话说,该将数

据聚为多少类. 从传统主题模型中衍生出来的 HDP 模型很好地解决了这一难题. HDP 使用狄利克雷过程(Dirichlet Process, DP)取代了传统主题模型中的狄利克雷分布(Dirichlet Distribution, DD). 利用狄利克雷过程的维度为无限的特性实现模型的无参化,令模型自主地从数据中学习其对应的主题^[2].

传统主题模型 LDA 中所普遍使用的近似推理算法主要有三种:变分贝叶斯(Variational Bayes, VB)、吉布斯采样(Gibbs Sampling, GS)以及消息传递算法(Belief Propagation, BP),其中消息传递算法具有较明显的精度优势. 鉴于消息传递算法在 LDA

收稿日期: 2015-04-01; 修回日期: 2015-05-13

基金项目: 国家自然科学基金(61373092,61033013,61272449,61202029);江苏省教育厅重大项目(12KJA520004);江苏省科技支撑计划重点项目(BE2014005);广东省重点实验室开放课题(SZU-GDHPCL-2012-09)

模型中的优势,以及 HDP 模型与 LDA 模型的关系,本文将使用消息传递算法来优化 HDP 模型。

2 HDP 模型

HDP 模型是一种三层贝叶斯模型,为无参主题模型的一种。该模型假设整个文本集共有无穷个主题,每个主题 k 是单词表的概率分布,每篇文档 d 是主题的概率分布,一篇文档的生成过程如下所示,其中 DP 表示狄利克雷过程:

$$\begin{aligned} G_0 &| \gamma, H \sim DP(\gamma, H) \\ G_j &| \alpha_0, G_0 \sim DP(\alpha_0, G_0) \\ \theta_{ji} &| G_j \sim G_j \\ x_{ji} &| \theta_{ji} \sim F(\theta_{ji}) \end{aligned} \quad (1)$$

式中, $F(\theta_{ji})$ 表示给定主题 θ_{ji} 单词 x_{ji} 的分布。即从以 H 为基分布的狄利克雷过程中获得全局主题的分布 G_0 ,再以 G_0 为基分布的狄利克雷过程中获得每篇文档的主题分布 G_j ,从 G_j 中获得一个主题 θ_{ji} ,进而从主题单词分布 $F(\theta_{ji})$ 中获得一个单词 x_{ji} ,重复这样的过程直到得到所有的文档^[3]。图 1 即 HDP 的图模型表示。




图 1 HDP 图模型

狄利克雷过程与狄利克雷分布 (Dirichlet Distribution, DD) 有许多相似之处,都可以理解为分布的分布,即从狄利克雷过程中采出的每一个样本都是一个随机分布^[4]。不同之处在于狄利克雷过程的基分布可以为离散或连续的几乎任何分布,而狄利克雷分布的基分布则必须为固定维数的离散分布。故狄利克雷过程可以视为狄利克雷分布在连续空间上的扩展。

基于狄利克雷过程的 HDP 模型,其主要在顶层与第二层都采用狄利克雷过程作为其下一层的先验,对应于 LDA 模型中的狄利克雷分布。在 LDA 模型中我们只有一层狄利克雷分布,而在 HDP 中我们存在了两层 DP 先验,其主要原因在于要阻止不同文档之间共享主题。

狄利克雷过程主要有三种构造:Stick-breaking 构造、Chinese Restaurant 构造,Polya urn 构造,这三种构造均体现了狄利克雷过程良好的聚类性能。因 Chinese Restaurant 构造与 Polya urn 构造具有较强

的离散性可能导致消息丢失,而 Stick-breaking 构造的连续性可以保证消息的完整性,故在实现中我们采用了 Stick-breaking 构造。

折棒构造 (Stick-breaking Process) 基于独立同分布的变量序列 $(\beta_k)_{k=1}^{\infty}$ 和 $(\varphi_k)_{k=1}^{\infty}$:

$$\beta_k | \alpha_0, G_0 \sim \text{Beta}(1, \alpha_0), \varphi_k | \alpha_0, G_0 \sim G_0$$

折棒构造定义一个随机概率分布 G 如下:

$$\pi_k = \beta_k \prod_{l=1}^{k-1} (1 - \beta_l), G = \sum_{k=1}^{\infty} \pi_k \delta_{\varphi_k} \quad (2)$$

Sethuraman (1994) 证明如此构造的分布函数 G 是服从狄利克雷过程 $DP(\alpha_0, G_0)$ 分布的一个随机分布。式 (2) 中 $\pi = (\pi_k)_{k=1}^{\infty}$ 满足 $\sum_{k=1}^{\infty} \pi_k = 1$ 。通常用 $\pi \sim \text{GEM}(\alpha_0)$ 表示权重系数的构造关系 (GEM 分别是 Griffiths, Engen 和 McCloskey 的首字母)。折棒构造的示意图如图 2 所示。




图 2 Stick-breaking 构造示意图

3 分层狄利克雷过程之消息传递算法

消息传递算法与其他采样算法相比,在更新主题方面有较大的不同,已有的算法是利用离散的主题信息来进行更新,而消息传递算法采用单词完整的主题信息 (即当前单词的主题分布) 来更新其他因子,无需进行采样,故无法动态地增减主题数目,但可通过动态从大量主题中选择当前文档主题来实现。

本文对分层狄利克雷过程模型进行了针对于连续的消息进行了优化,在新的 HDP 模型中,我们认为整个语料库中存在着 K 个主题,而对于每篇文档存在着 T 个主题 ($K \gg T$)。鉴于这个特点,新 HDP 模型相对于传统 HDP 模型引进一个新变量 c_{dt}^k ,表示第 D 篇文档 T 个主题在语料库 K 个主题上的一个映射,即第 D 篇文档选择 K 个主题中的哪 T 个主题作为其主题。故每次迭代文档的 K 个主题可能会随着推断发生变化,最终收敛。

改进后的模型主要采用 Stick-breaking 构造的 DP 进行主题建模,其图模型如图 3 所示。

其生成过程^[5]可表示如下。

式中, $\theta'_{dt} = \theta_{dt} \prod_{i=1}^{t-1} (1 - \theta_{di})$, 其为一个折棒构造的狄利克雷过程, $\log$ 似然函数同样可表示为

$$\begin{aligned} l(\lambda) \propto & \sum_{d=1}^D \sum_{w=1}^W x_{dw} \\ & \left[\log \sum_{t=1}^T \mu'_{dw} \frac{\theta'_{dt} \sum_{k=1}^K c_{dt}^k \varphi_{kw}}{\mu'_{dw}} \right] + \\ & \sum_{k=1}^K \sum_{w=1}^W (\beta - 1) \log \varphi_{kw} + \\ & \sum_{d=1}^D \sum_{t=1}^T (\alpha - 1) \log(1 - \theta_{dt}) + \\ & \sum_{d=1}^D \sum_{t=1}^T \sum_{k=1}^K c_{dt}^k \log \sigma(v_k) \end{aligned} \quad (7)$$

式中, μ'_{dw} 表示索引 $\{w, d\}$ 单词上的主题分布, 其满足 $\sum_{t=1}^T \mu'_{dw} = 1, \mu'_{dw} > 0$, 根据 Jensen 不等式, 可以得到:

$$\begin{aligned} l(\lambda) > l(\mu, \lambda) = & \sum_{d=1}^D \sum_{w=1}^W \sum_{t=1}^T \mu'_{dw} x_{dw} \\ & \left[\log \frac{\theta'_{dt} \sum_{k=1}^K c_{dt}^k \varphi_{kw}}{\mu'_{dw}} \right] + \\ & \sum_{k=1}^K \sum_{w=1}^W (\beta - 1) \log \varphi_{kw} + \\ & \sum_{d=1}^D \sum_{t=1}^T (\alpha - 1) \log(1 - \theta_{dt}) + \\ & \sum_{d=1}^D \sum_{t=1}^T \sum_{k=1}^K c_{dt}^k \log \sigma(v_k) \end{aligned} \quad (7)$$

其给出了 $\log$ 似然函数的下边界, 根据 Jensen 不等式的特性可以得到:

$$\mu'_{dw} \propto \theta'_{dt} \sum_{k=1}^K c_{dt}^k \varphi_{kw} \quad (8)$$

式中, T 长度的 μ'_{dw} 表示单词索引 $\{w, d\}$ 来自第 t 个主题的概率, 其为 EM 算法中的 E 步骤。

在接下来的 M 步骤中, 通过最大化来更新参数集 λ , 下面是 M 步骤中关于参数 φ_{kw} 的更新过程。由于 φ_{kw} 是第 k 个主题上在单词 w 的分布, 故可以得到限定条件 $\sum_{w=1}^W \varphi_{kw} = 1$ 。根据与 φ_{kw} 相关的这些条件我们可以构建朗格朗日函数:

$$\begin{aligned} l(\varphi) = & \sum_{d=1}^D \sum_{w=1}^W \sum_{t=1}^T \log \mu'_{dw} x_{dw} \\ & \left[\log \frac{\theta'_{dt} \sum_{k=1}^K c_{dt}^k \varphi_{kw}}{\mu'_{dw}} \right] + \\ & \sum_{k=1}^K \sum_{w=1}^W (\beta - 1) \log \varphi_{kw} + \\ & \sum_{k=1}^K \delta_k \left[\sum_{w=1}^W \varphi_{kw} - 1 \right] \end{aligned} \quad (9)$$

式中, δ_k 为拉格朗日乘子, 对其求导我们可以得到:

$$\frac{\partial l(\varphi)}{\partial \varphi_{kw}} = \frac{\sum_{d=1}^D \sum_{t=1}^T c_{dt}^k \mu'_{dw} x_{dw} + (\beta - 1)}{\varphi_{kw}} + \delta_k \quad (10)$$

令其等于 0, 则:

$$\varphi_{kw} = \frac{\sum_{d=1}^D \sum_{t=1}^T c_{dt}^k \mu'_{dw} x_{dw} + (\beta - 1)}{-\delta_k} \quad (11)$$

根据限定条件 $\sum_{w=1}^W \varphi_{kw} = 1$, 我们可以得到 φ_{kw} 的更新公式:

$$\varphi_{kw} = \frac{\sum_{d=1}^D \sum_{t=1}^T c_{dt}^k \mu'_{dw} x_{dw} + (\beta - 1)}{\sum_{w=1}^W \left[\sum_{d=1}^D \sum_{t=1}^T c_{dt}^k \mu'_{dw} x_{dw} + (\beta - 1) \right]} \quad (12)$$

同理, 我们可以得到 c_{dt}^k 的更新公式:

$$c_{dt}^k = \sigma(v) \sum_{w=1}^W \mu'_{dw} x_{dw} \varphi_{kw} \quad (13)$$

我们发现 φ_{kw} 可视为分布 $\text{Dir}(\beta + \sum_{d=1}^D \sum_{t=1}^T c_{dt}^k \mu'_{dw} x_{dw})$ 的期望, 类推我们可以得到^[7]:

$$\begin{aligned} \theta_{dt} & \sim \text{Beta}(1 + \sum_{w=1}^W \mu'_{dw} x_{dw}, \alpha + \\ & \sum_{w=1}^W \sum_{j>t} \mu_{dw}^j x_{dw}) \\ v_k & \sim \text{Beta}(1 + \sum_{d=1}^D \sum_{t=1}^T c_{dt}^k, \omega + \\ & \sum_{d=1}^D \sum_{t=1}^T \sum_{j>k} c_{dt}^j) \end{aligned} \quad (14)$$

利用 EM 算法得到的参数更新公式, 可以得到以下算法。

算法 1 HDP 消息传递算法

初始化 θ_d, φ_k, μ

重复:

1. 从数据集中采样文档 w_d ;
2. For $t \in \{1, \dots, T\}$ set:

$$\gamma_{dt}^{(1)} = 1 + \sum_{w=1}^W \mu'_{dw} x_{dw}$$

$$\gamma_{dt}^{(2)} = \alpha + \sum_{w=1}^W \sum_{i=t+1}^T \mu'_{dw} x_{dw}$$
3.
$$\theta_{dt} = \frac{\gamma_{dt}^{(1)}}{\gamma_{dt}^{(1)} + \gamma_{dt}^{(2)}} \prod_{l=1}^{t-1} \frac{\gamma_{dt}^{(2)}}{\gamma_{dt}^{(1)} + \gamma_{dt}^{(2)}}$$

$$c_{dt}^k = \sigma(v) \sum_{w=1}^W \mu'_{dw} x_{dw} \varphi_{kw}$$
4. For $k \in \{1, \dots, K\}$ set:
5.
$$\sigma_k(v) = \frac{a_k}{a_k + b_k} \prod_{l=1}^{k-1} \frac{b_l}{a_l + b_l}$$
6. For $w \in \{1, \dots, W\}$ set:
7.
$$\mu'_{dw} \propto \theta'_{dt} \sum_{k=1}^K c_{dt}^k \varphi_{kw}, t \in \{1, \dots, T\}$$
8. For $k \in \{1, \dots, K\}$ set:
9.
$$a_k = 1 + D \sum_{t=1}^T c_{dt}^k$$

$$b_k = \omega + D \sum_{t=1}^T \sum_{l=k+1}^K c_{dt}^l$$
$$\sigma_k(v) = \frac{a_k}{a_k + b_k} \prod_{l=1}^{k-1} \frac{b_l}{a_l + b_l}$$
$$\varphi_{kw} = \beta + D \sum_{t=1}^T c_{dt}^k \sum_{w=1}^W \mu_{dw}^l x_{dw}$$

10. 归一化 φ_{kw}
直到收敛

4 实验分析

4.1 实验环境与数据集

本文使用的两个数据集是 NIPS 和 CORA, 具体统计如表 2 所示。

表 2 数据集信息

数据集	D	W	ntokens	nnz
NIPS	3 430	6 906	467 714	353 160
CORA	5 177	33 574	1 125 982	772 032

表 2 概括统计实验用的两个数据集, 这里 D 是文档的总数目, W 是单词表的大小, ntokens 是所有文档的单词总数, nnz 是各个文档里不相同单词的数目之和。

4.2 评价标准

本文采用主题模型领域通用的性能评价指标混淆度 (Perplexity) [8] 来评价算法的性能。混淆度经常被用在语言模型中, 是用来衡量语言模型对于测试语料库的建模能力的好坏, 即似然的大小。混淆度的计算公式如下:

$$\text{Perp} = \exp \left\{ - \frac{\sum_{w,d} x_{w,d} \log \left[\sum_t \theta_{dt} \sum_{k=1}^K c_{dt}^k \varphi_{kw} \right]}{\sum_{w,d} x_{w,d}} \right\} \quad (15)$$

越低的混淆度值表示了越好的泛化性能。

4.3 实验结果分析

我们使用 GS 算法学到的主题数目作为 BP 中文档的主题数目, 例如 NIPS 数据集中 GS 算法学习到的数目 $K=20$, 在 BP 算法中设置 $K=200, T=20$, BP 中的 K 代表的是语料库的主题数即全局的主题数, T 代表的是文档层的主题数, 即局部的主题数。设置实验先验参数初始化都设置 $\beta=0.01$ 。对比不同算法在混淆度上的效果, 如图 5、图 6 所示。

对于分层狄利克雷过程后验分布的推断, 吉布斯采样算法主要是基于马尔科夫蒙特卡罗 (Markov chain Monte Carlo, MCMC), 利用马尔科夫链的收敛性通过随机原子抽样来估算后验分布, 其缺点在于收敛速度较慢, 易陷入局部最优; 而变分贝叶斯算法

主要利用简单的变分分布 (variational distribution) 近似逼近分层狄利克雷过程复杂的后验分布, 通过最大化证据下边界 (Evidence lower bound, ELBO) 进而最小化两分布之间的 KL 散度 (Kullback-Leibler divergence) 将推断问题转化为优化问题, 其缺点在于逼近精度低, 计算复杂速度较慢, 优点在于收敛较快。

实验结果表明消息传递算法的混淆度最终趋于平稳, 即代表该算法在 HDP 模型上可以收敛且相比其他算法有较明显的优势, 尤其体现在短文本数据集上。消息传递算法保留了每个单词的所有主题信息, 而其他算法根据其特性均丢失了部分主题信息。




图 5 NIPS 数据集下不同算法混淆度




图 6 CORA 数据集下不同算法混淆度

5 结束语

本文介绍了分层狄利克雷过程模型及相关基础知识, 分析了该模型的因子图模型, 基于其提出了利用消息传递算法来解决非参主题模型参数估计的问题, 同时利用 EM 算法证明了该算法的收敛性。实验结果表明消息传递算法在混淆度上有较明显的优势, 且收敛速度更快。进一步的工作将围绕动态主题数目展开, 并分析其对聚类性能的影响。

参考文献:

[1] Blei D M, Ng A Y, Jordan M I. Latent dirichlet allocation [J]. The Journal of Uachine Learning Research, 2003, 3 (1): 993-1022.

[2] Gershman S J, Blei D M. A tutorial on Bayesian nonparametric models [J]. Journal of Mathematical Psychology, 2012, 56(1): 1-12.

一种全集成磁敏生物传感器模拟前端电路

李仲秋¹, 陈铖颖², 贺 瑛¹

(1 空军航空维修技术学院, 湖南 长沙 410000; 2 中国科学院 微电子研究所, 北京 100029)

摘 要: 提出一种全集成磁敏模拟前端电路, 包括读出电路和 10 bit/1 MHz 逐次逼近模数转换器两部分, 应用于巨磁阻生物传感器; 读出电路提供 300 mV 偏置电压加载至巨磁阻生物传感器阵列上, 将巨磁阻生物传感器阵列上的等效电阻变化转换为电流变化, 跨阻放大器将检测电流转换为电压并进行放大; 逐次逼近模数转换器将检测电压转换为数字码, 输出至数字电路进行信息处理, 完成检测. 模拟前端电路采用 SMIC 0.18 μm 1P6M CMOS 工艺实现, 工作电压 3.3 V. 后仿真结果表明, 在 1 MHz 时钟频率下, 模拟前端电路的输出信号有效精度达到 7.8 bit, 达到磁敏生物微弱信号的检测电路系统要求.

关键词: 全集成; 磁敏; 模数转换器; 模拟前端

中图分类号: TN492

文献标识码: A

文章编号: 1000-7180(2016)03-0147-05

A Fully-Integrated Analog Front-End for Magnetic-Sensitivity Biosensor

LI Zhong-qiu¹, CHEN Cheng-ying², HE Ying¹

(1 Air Force Aviation Repair Institute of Technology, Changsha 410000, China;

2 Institute of Microelectronics, Chinese Academy of Sciences, Beijing 100029, China)

Abstract: For Giant Magnetoresistance (GMR) Biosensor application an Analog Front-End (AFE) circuit is presented in this paper, which consists of readout circuit and 10 bit/1 MHz Successive Approximation Analog-to-Digital Converter (SAR ADC). The readout circuit provides 300 mV bias voltage for GMR biosensor array, which transfers the resistor change into current change. Then the current is transferred into voltage and amplified by Trans-Impedance Amplifier (TIA). Finally the digital code is output by SAR ADC and processed by DSP. The AFE is implemented in SMIC 0.18 μm 1P6M CMOS process. The power supply is 3.3 V. The measurement results show that, in 1 MHz clock frequency, the ENOB of circuit is 7.8 bit, meets the requirement for GMR biosensor detection.

Key words: fully-integrated; magnetic-sensitivity; ADC; analog front-end

1 引言

近年来, 作为病情实验分析的重要领域, 临床诊断具有快速分析、直接定位、精确度高以及多种选择性等特点. 而新兴的基于纳米技术的生物传感器因其尺寸小、换能灵敏度高以及与微系统芯片集成等优势, 逐渐成为了临床诊断未来发展的主要检测工

具. 而在各类生物传感器中, 磁敏生物传感器不仅具有以上优点, 还与大规模生产兼容, 具有更加巨大的发展潜力.

巨磁阻效应最早由 Baibich^[1] 于 1988 年发现. 当研究人员将一个外部磁场加载在三明治型的多层磁化阵列时, 该阵列的电阻值发生了百分之五十的变化. 这种巨大的磁化电阻变化就称为巨磁阻效应.




图 8 1 MHz 时钟时的输出频谱

4 结束语

本文提出的磁敏生物传感器模拟前端电路,采用 SMIC 0.18 μm 1P6M CMOS 厚栅氧工艺设计实现,采用电流型检测的方法. 后仿真结果显示在系统时钟 1 MHz 时,输入信号频率 400 kHz,峰峰值 3 V 时,整体电路输出频谱有效精度达到 7.8 位,可检测的最小电阻变化率为 8 ~ 16 Ω ,满足磁敏生物微弱信号的检测电路系统对巨磁阻传感器的性能要求.

参考文献:

- [1] Baibich M N, Broto J U, Fert A, et al. Giant magnetoresistance of FeCr magnetic superlattices[J]. Physical Letters, 1988, 61(21): 2472-2475.
- [2] Rife J C, Miller M M, Sheehen P E, et al. Design and
- [4] 周建英, 王飞跃, 曾大军. 分层 Dirichlet 过程及其应用综述[J]. 自动化学报, 2011, 37(4): 389-408.
- [6] Paisley J W, Zaas A K, Woods C W, et al. A stick-breaking construction of the beta process[C] // Proceedings of the 27th International Conference on Machine Learning. Haifa, Israel: IEEE, 2010.
- [7] Teh Y W, Kurihara K, Welling M. Collapsed variational inference for HDP[C] // Advances in neural information processing systems. [s. l.]: IEEE, 2007.
- [8] Hanna A M, Wallach M, David M Mimmo. Rethinking lda: Why priors matter[C] // Annual Conference on Neural Information Processing Systems. Vancouver: Cur-

performance of GMR sensors for the detection of magnetic microbeads in biosensors[J]. Sensor and Actuators, 2003, 107(3): 209-218.

- [3] Miller M M, Sheehen P E, Edelstein R L, et al. A DNA array sensor utilizing magnetic microbeads and magneto-electronic detection[J]. Journal of Magnetism and Magnetic Materials, 2001, 225(1-2): 138-144.
- [4] RAZAVI B. Design of analog CMOS and integrated circuit[M]. McGraw-Hill Company, Inc, 2001: 309-324.
- [5] Gilbert P. 12-bit Low-power fully differential switch capacitor noncalibrating successive approximation ADC with 1 MS/s[J]. IEEE Journal of Solid-State Circuit, 2001, 36(7): 1138-1143.
- [6] Siamak M, Edward L. A 1-V, 8-Bit successive approximation ADC in standard CMOS process[J]. IEEE Journal of Solid-State Circuits, 2000, 35(4): 642-646.
- [7] Huang G Y, Liu C C, Lin Y Z, et al. A10-bit 12-MS/s successive approximation ADC with 1.2-pF input capacitance[C] // IEEE Asian Solid-State Circuit Conference. Taipei: IEEE, 2009: 157-160.
- [8] Naveen V, Anantha C. An ultra low energy 12-bit rate-resolution scalable SAR ADC for wireless sensor nodes[J]. IEEE Journal of Solid-State Circuits, 2007, 42(6): 1196-1205.

作者简介:

李仲秋 男, (1962-), 高工, 研究方向为电子系统与集成电路. E-mail: gmailjjh@163.com.

(上接第 146 页)

- [4] 周建英, 王飞跃, 曾大军. 分层 Dirichlet 过程及其应用综述[J]. 自动化学报, 2011, 37(4): 389-408.
- [6] Paisley J W, Zaas A K, Woods C W, et al. A stick-breaking construction of the beta process[C] // Proceedings of the 27th International Conference on Machine Learning. Haifa, Israel: IEEE, 2010.
- [7] Teh Y W, Kurihara K, Welling M. Collapsed variational inference for HDP[C] // Advances in neural information processing systems. [s. l.]: IEEE, 2007.
- [8] Hanna A M, Wallach M, David M Mimmo. Rethinking lda: Why priors matter[C] // Annual Conference on Neural Information Processing Systems. Vancouver: Cur-

ran Associates, 2009: 1973-1981.

作者简介:

王杰 男, (1990-), 硕士研究生. 研究方向为机器学习. E-mail: wangjiect@163.com.

刘晓升 男, (1976-), 博士研究生. 研究方向为机器学习.

严建峰 男, (1978-), 副教授, 硕士生导师. 研究方向为机器学习.

刘晓升 男, (1976-), 博士研究生. 研究方向为机器学习.

杨璐 女, (1982-), 副教授、硕士生导师. 研究方向为机器学习与软件工程;