

关系马尔可夫网综述^{*}

刘智祥^{1,2} 刘大有^{1,2} 刘 曜¹ 高俊华¹ 李景亮¹

(吉林大学计算机科学与技术学院 长春 130012)¹

(吉林大学符号计算与知识工程教育部重点实验室 长春 130012)²

摘 要 统计关系学习是人工智能领域一个新的研究方向。它通过概率推理模型与逻辑的结合,或概率推理模型与关系模式的结合,来达到更高的预测或分类的准确度。它在机器学习和数据挖掘领域具有广泛的应用前景。详细介绍了一种重要的统计关系模型——关系马尔可夫网的理论模型,并总结关系马尔可夫网当前的研究现状,分析了关系马尔可夫网目前存在的问题以及未来的研究方向。

关键词 关系马尔可夫网, 统计关系学习, 马尔可夫网, 机器学习

Survey of Relational Markov Networks

LIU Zhi-xiang^{1,2} LIU Da-you^{1,2} LIU Yao¹ GAO Jun-hua¹ LI Jing-liang¹

(College of Computer Science&Technology, Jilin University, Changchun 130012, China)¹

(Key Laboratory of Symbolic Computation&Knowledge Engineering for Ministry of Education, Jilin University, Changchun 130012, China)²

Abstract Tattistical relational learning is a new field of artificial intelligence research. Through the combination of probabilistic inference model and logic, or the combination of probabilistic inference model and relational schema, it aims to achieve greater accuracy of prediction or classification. Statistical relational learning has broad prospects in machine learning and data mining areas. This paper is a survey of the theory of an important one of statistical relational learning models——Relational Markov Networks. Summarized present research circumstances and analized existing problems and future research directions of it.

Keywords Relational markov networks, Statistical relational learning, Markov networks, Machine learning

1 引言

统计关系学习是人工智能领域一个新的研究方向,与假定数据是相互独立、等概率分布的传统机器学习和数据挖掘方法不同,它通过将概率推理模型和逻辑,关系模式结合起来,捕捉和利用数据间的依赖关系以求得到更高的预测或分类的准确度。在生物信息学、Web 应用、地理信息系统、信息提取、自然语言处理和社会网络方面取得了一些研究成果并具有广泛的应用前景^[6]。

关系马尔可夫网(Relational Markov networks, RMN)^[1]是一种重要的统计关系模型,它由马尔可夫网^[7]和关系模式结合而产生。通过使用关系马尔可夫网,可以充分利用判别学习和集体数据分析的优点,提高模型预测或分类的准确度。第 1 节介绍关系模式和马尔可夫网的基本概念,然后在第 2 节介绍关系马尔可夫网的提出,第 3 节总结关系马尔可夫网的研究现状,最后分析并指出关系马尔可夫网存在的问题和未来的研究方向。

2 基本概念

2.1 关系模式(Relational Schema)

定义 1 关系的描述称为关系模式(Relation Schema)。

它定义了一个实体类型的集合、实体的属性,以及属性之间的关系。

例如,通过关系查询语句(SQL)我们可以在数据库定义一个表的集合,每个表所拥有的属性,以及数据库表之间的参照关系,这就定义了一个关系模式。关系模式的实例指定了实体的集合,例如,在某一时刻,数据库中的数据就是一个实例。

2.2 马尔可夫网(Markov Networks)

马尔可夫网定义了 n 维离散随机变量的联合概率分布。

定义 2 马尔可夫网定义了一个拥有势函数集合 $\{\Phi_c\}$ 的无向图 $G=(V, E)$, V 表示图中节点的集合, E 表示图中边的集合。 V_c 为图 G 的一个团(clique), 团 V_c 的势函数(Clique Potential) $\Phi_c(V_c)$ 是在 V_c 上的非负函数。若 V 表示成 n 维变量 (V_1, V_2, \dots, V_n) , $v=(v_1, v_2, \dots, v_n) \in V$ 为变量 V 所取状态值, 马尔可夫网定义了概率:

$$P(V=v) = \frac{1}{Z} \prod_{c \in C(G)} \Phi_c(v_c)$$

其中, $Z = \sum_v \prod_c \Phi_c(v_c)$ 是标准化常量, 用来保证 $\sum_v P(V=v) = 1$, Φ_c 是一个值表, 定义了团中变量的值的相容性。

团势一般表示成 log-linear 的形式:

$$\Phi_c(v_c) = \exp\left\{\sum_i w_i f_i(v_i)\right\} = \exp\{w_c f_c(v_c)\}$$

^{*} 基金项目: 国家自然科学基金资助项目(60573073), 国家“863”计划资助项目(2003AA118020), 吉林省科技发展计划重大资助项目(20020303)。刘智祥 硕士, 主要研究方向为数据挖掘、机器学习; 刘大有 博导, 主要研究方向为知识工程与专家系统、分布式 AI 与多 Agent 系统、算法与数据结构、空间推理与 GIS 应用等; 刘 曜 硕士, 主要研究方向为分布式系统与网络软件; 高俊华 硕士, 主要研究方向为网络软件与通信协议; 李景亮 主要研究方向为嵌入式系统。

这样,我们可以把概率公式改写成:

$$\log P(v) = \sum_c w_c f_c(v_c) - \log Z = w \cdot f(v) - \log Z$$

w 和 f 分别是团势权重与特征的向量。

3 关系马尔可夫网的提出

在许多监督学习任务中,待分类的实体之间的联系不仅复杂而且相互影响。为了提高分类的准确度,一个方法是把相互关联的实体结合起来预测。例如,似然关系模型(Probabilistic Relational Models, PRM)用来定义相互关联实体集合上的联合概率分布模型。虽然似然概率模型在解决一些问题时展现出了很好的性能,但是它的应用也存在一些限制,如当网络的链接图存在很多环路,似然关系模型的应用可能会遇到一些问题。另外,似然概率模型经常被用来优化证据节点和目标节点的联合概率,而分类问题的目标是在给定证据节点值的情况下,建立目标节点的判别模型,因此,似然概率模型并不能满足判别学习的要求^[1]。

2002年,为了解决上述问题,Ben. Taskar等^[1]提出了关系马尔可夫网模型。其主要思想是:为了满足判别学习的要求,基于J. Lafferty^[5]的条件随机场(Conditional Random Fields, CRF)方法,构建一个使用条件马尔可夫网(Conditional Markov Networks)的判别概率模型,然后在条件马尔可夫网上引入关系团模板^[1](Relational Clique Templates)的概念,定义关系马尔可夫网^[1]。

定义3 条件马尔可夫网定义了条件概率, $P(y|x) = \frac{1}{Z(x)} \prod_{c \in C(x)} \Phi_c(x_c, y_c)$, 其中 y 和 x 分别表示目标随机变量和证据随机变量。 $Z(x) = \sum_y \prod \Phi_c(x_c, y'_c)$ $Z(x)$ 表示标准化函数,使 $\sum_y P(y'|x) = 1$ 。

定义4 一个关系团模板 $C = (F, W, S)$ 由三部分组成:

F 是实体变量的集合 $\{F_i\}$, 每个 F_i 可以是一个数据库表;

$W(F, R)$ 是一个布尔公式,如 $F_p, R_q = F_w, R_z, R_q$ 和 R_z 分别为表 F_q, F_w 的属性;

S 是选择实体变量属性的子集,如 $F, S \subseteq F, Y$;

关系团模板使用关系查询语言定义了实例 Γ 一组相似的团,

$$C(\Gamma) = \{c = f, S : f \in \Gamma(F) \wedge W(f, r)\}$$

定义5 一个关系马尔可夫网 $M = (CT, \Phi)$, 通过指定了一个关系团模板集合 CT 和相应的势 $\Phi = \{\Phi_c\}_{c \in CT}$ 来定义条件概率分布

$$P(\Gamma, y | \Gamma, x, \Gamma, r) = \frac{1}{Z(\Gamma, x, \Gamma, r)} \prod_{c \in CT} \prod_{c \in C(\Gamma)} \Phi_c(\Gamma, x_c, \Gamma, y_c)$$

其中 $Z(\Gamma, x, \Gamma, r) = \sum_{y, y'} \prod_{c \in CT} \prod_{c \in C(\Gamma)} \Phi_c(\Gamma, x_c, \Gamma, y'_c)$ 是标准化参数。

若使用团势的 log-linear 型表示方法:

$$\begin{aligned} \log P(\Gamma, y | \Gamma, x, \Gamma, r) &= \sum_{c \in CT} \sum_{c \in C(\Gamma)} (w_c \cdot f_c(\Gamma, y_c)) - \log Z(\Gamma, x, \Gamma, r) \\ &= \sum_{c \in CT} w_c \cdot f_c(\Gamma, x, \Gamma, y, \Gamma, r) - \log Z(\Gamma, x, \Gamma, r) \\ &= w \cdot f(\Gamma, x, \Gamma, y, \Gamma, r) - \log Z(\Gamma, x, \Gamma, r) \end{aligned}$$

其中 $f_c(\Gamma, x, \Gamma, y, \Gamma, r) = \sum_{c \in C(\Gamma)} f_c(\Gamma, x_c, \Gamma, y_c)$ 是模板 C 在关系模式实例 Γ 中所有出现的总和, f 是全部 f_c 的向量。

4 研究现状

关系马尔可夫网模型为判别训练和联合预测提供了有效的方法。关系马尔可夫网提出后,许多学者都开展了这方面的研究,并取得了一些研究成果,促进了关系马尔可夫网的研究。

2002年,B. Taskar等^[1]使用关系马尔可夫网(RMN)来解决 Web 页面的分类问题。在模型训练方面,通过使用最大后验概率方法(maximum a posteriori, MAP)定义目标函数。

目标函数的对数形式为:

$$L(w, \Gamma) = \log(\Gamma, y | \Gamma, x, \Gamma, r) - \frac{w^2}{2\sigma^2} + C$$

然后使用梯度下降法^[14]对目标函数进行优化。

目标函数 $L(w, \Gamma)$ 的梯度为

$$\nabla L(w, \Gamma) = f(\Gamma, y, \Gamma, x, \Gamma, r) - E_{P_w} [f(\Gamma, Y, \Gamma, x, \Gamma, r)] - \frac{w}{\sigma^2}$$

其中 $E_{P_w} [f(x_d, Y_d)] = \sum_{\Gamma, y'} f(\Gamma, y', \Gamma, x, \Gamma, r) P_w(\Gamma, y' | \Gamma, x, \Gamma, r)$ 。这样,沿着梯度 $\nabla L(w, \Gamma)$ 的方向迭代地更新团势权重,最后会得到最优解。

在推理算法方面, Ben. Taskar 等使用了信度传播算法^[7,10,11](belief propagation, BP)作为关系马尔可夫网的推理算法。信度传播算法(Pearl, 1988)是一种局部消息传播算法,可以保证单连通网络中的每个节点都收敛到正确的概率,不仅如此,一些试验^[29]也说明了信度传播算法在有环网络也可以很好地工作。该算法的主要思想是每个节点都向它的邻居节点发送消息-概率传播向量。当某节点收到来自邻居节点的消息时,它将来自邻居节点的消息和本地消息相结合并进行标准化,然后把标准化的消息发送给它的邻居节点。所有的初始化消息向量为 $(1, \dots, 1, 1)$ 。证据节点只发送消息(证据节点与邻居节点的团势),而不接收消息。消息传播过程在网络的所有节点并行地迭代执行,直至整个网络中的消息收敛到稳定的状态。目标节点的信度函数由来自邻居节点消息的稳定状态值和本地证据得到。

通过 Web 页面分类试验比较发现,采用关系马尔可夫网模型的程序不但能捕捉非关系模型(logistic regression)可以利用的有用信息,如页面中出现的词以及元数据——标题中的词,链接锚等,还能捕捉关联页面标签之间的有用信息,如学生页面大多数链接到课程页面,这些关系信息降低了关系模型分类的错误率。

2003年, Ben. Taskar等^[2]在链接预测领域上应用 RMN 框架,使用关系马尔可夫网框架在整个连接图上定义了一个联合概率模型,关系马尔可夫网算法在子图结构上定义了概率模式。在两个关系数据集(分别涉及大学网页和社会网)上进行了试验,结果表明:RMN 的共同分类方法和连接标记上的子图模式比扁数据分类在预测精度上有显著的提高。

2003年, E. Segal 等人^[3]在生物信息学领域使用 RMN 框架建立统一的概率模型用来发现分子路径,该方法将朴素贝叶斯模型和马尔可夫网结合起来构建了统一的概率模型,用来把基因表现和蛋白交互的信息结合起来以提高准确率。在两组整合了二元蛋白交互数据集的 *Saccharomyces cerevisiae* 基因表现数据集上的试验结果证明,该方法比其它同类方法在发现一致的功能组和整体蛋白复合物上更有效。

2004年, R. Bunescu等^[5]基于 RMN 模型提出了新的信

息提取方法。关系马尔可夫网模型可以用来表达任意的提取间依赖,该方法允许用共同信息提取来利用可能提取间的相互影响,利用关系马尔可夫网建立全局团模板来捕捉同一个文件中的重复信息(缩写词和完整形式的软关系)。通过从生物医学文本中抽取蛋白名称的试验表明,使用关系马尔可夫网的信息提取方法比同类方法有更好的性能。

2005年,Lin Liao等^[4]在活动识别领域扩展了RMN,并提出在RMN上使用MCMC方法进行学习和推理。在Lin Liao^[4]的RMN模型中,不仅可以使⽤SQL查询语句定义团模板,而且还可以使⽤元组上的聚集函数来定义团模板,另外,还通过在Where子句中使用标记的方法定义了一类新的“特殊标记团”,用来建立同一类活动上的约束。在目标函数最优化方法上,Lin Liao等提出使⽤quasi-Newton技术来最优化目标函数。在推理方法上,尽管消息传播算法在网络规模比较小的情况下能很好地工作,并显示出不错的性能^[1];但是,当网络规模比较大,甚至是由于实际需要在⽤学过程中网络结构需要变更时,消息传播算法就不再是有很⽤效率的算法了,因此,为了解决这个问题,Lin Liao等提出了基于MCMC(Markov Chain Monte Carlo)方法^[13,15]的近似推理算法。Lin Liao^[4]等人在解决基于位置的活动识别问题时,通过对活动施加额外的约束——同一地点发生的活动具有相同的标签,提出了MCMC Gibbs抽样和Metropolis-Hasting(MH)抽样混合方法,该方法独立地使⽤Gibbs抽样和MH抽样来估计条件概率的值,然后按照 γ 与 $1-\gamma$ 的比例把Gibbs和MH结合起来作为最后的条件概率。通过使⽤近似推理算法MCMC方法,使关系马尔可夫网在网络结构很复杂的情况下也能很好地工作。

5 存在的问题和研究方向

在关系马尔可夫网络规模比较小的情况下,RMN模型广泛使⽤的信度传播方法(Belief Propagation,BP)可以很好地工作^[1],但由于所要解决的问题往往比较复杂,以及RMN模型的优点是利⽤数据库中实体之间的关系来提高预测、分类或者其它应⽤的性能,当建立的全局团模板较多或数据量比较大时,RMN的网络规模往往比较大^[4],有些情况甚至会出现环路(Loopy Path),使⽤标准的信度传播方法运行时间比较长或者不收敛,这将导致BP方法的适⽤性受到局限。虽然文献^[4]提出了基于MCMC方法的近似推理算法,但由于施加了很强的约束,并不能很好地解决这一问题,因此,需要找到更快更有效的近似推理方法。

另外,目前还没有适⽤于不完全数据的学习和推理算法,因此,应提出关系马尔可夫网上的适⽤于不完全数据集上的学习和推理算法把关系马尔可夫网推广到不完全数据集上。可以考虑把关系马尔可夫网和实际应⽤中广泛使⽤的解决不完全数据问题的EM算法^[30]相结合,提出一种新的学习或推理算法。

最后,当今世界已经出现了很多其它统计关系学习模型,如基于Bayesian网的似然逻辑程序模型^[16,17](Probabilistic Logic Programs,PLPs)、贝叶斯逻辑程序模型^[18,19](Bayesian Logic Programs,BLPs)、似然关系模型^[20-22](Probabilistic Relational Models,PRMs)、Markov网和一阶逻辑结合的Markov逻辑网^[23-28](MLN)等。每一种模型都有各自的优点,因此,比较分析各个模型之间的优缺点并相互借鉴,将会更好地促进关系马尔可夫网和统计关系学习领域的研究与

应⽤。

结束语 本文详细介绍了—种重要的统计关系模型——关系马尔可夫网的理论模型,总结并分析当前提出的关系马尔可夫网学习和推理算法以及取得的应⽤成果,指出了目前关系马尔可夫网仍存在的问题,并提出未来的研究方向。

参考文献

- [1] Taskar B, Abbeel P, Koller D. Discriminative probabilistic models for relational data[C]//Proceedings of Eighteenth Conference on Uncertainty in Artificial Intelligence (UAI02). Edmonton, Canada, 2002
- [2] Taskar B, Wong M-F, Abbeel P, et al. Link prediction in relational data[C]//Neural Information Processing Systems Conference. Vancouver, Canada, December 2003
- [3] Segal E, Wang H, Koller D. Discovering molecular pathways from protein interaction and gene expression data[J]. Bioinformatics, 2003, 19: 264-272
- [4] Liao L, Fox D, Kautz H. Location-based activity recognition using relational Markov networks[C]//Proc. of the International Joint Conference on Artificial Intelligence (IJCAD). 2005
- [5] Bunescu R, Mooney R J. Relational markov networks for collective information extraction[C]//Proceedings of the ICML-2004 Workshop on Statistical Relational Learning (SRL-2004). Banff, Canada, July 2004
- [6] 刘大有,齐红,孙舒杨,等.统计关系学习综述[A]//中国人工智能学会第11届全国学术年会论文集:中国人工智能进展[c].北京:北京邮电大学出版社,2005,241-253
- [7] Pearl J. Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference[M]. San Francisco: Morgan Kaufmann, 1988
- [8] Lafferty J, McCallum A, Pereira F. Conditional random fields: Probabilistic models for segmenting and labeling sequence data [C]//Proc. ICML01. 2001
- [9] Chen S F, Rosenfeld R. A Gaussian prior for smoothing maximum entropy models[R]. Technical Report CMUCS-99-108. Carnegie Mellon University, 1999
- [10] Murphy K, Weiss Y, Jprdan M. Loopy belief propagation for approximate inference: an empirical study[C]//Proc. Uncertainty in AI. 1999
- [11] Weiss Y. Belief propagation and revision in networks with loops [R]. Technical Report 1616. MIT AI lab, 1997
- [12] Mitchell T M. 机器学习(Machine Learning)[M]. 曾华军,长银奎,等译.北京:机械工业出版社,2003
- [13] Gilks W R, Richardson S, Spiegelhalter D J. Markov Chain Monte Carlo in Practice[M]. Chapman and Hall/CRC, 1996
- [14] 张肇祺,张学工,等.模式识别(第二版)[M].北京:清华大学出版社,1999
- [15] Russell S, Norvig P. Artificial Intelligence: A Modern Approach, seconded[M]. Prentice Hall Series in Artificial Intelligence. Prentice Hall, Englewood Cliffs, NJ, 2003
- [16] Ngo L, Haddawy P. Answering Queries from Context-sensitive Probabilistic Knowledge Bases[J]. Theoretical Computer Science, 1997, 171: 147-177
- [17] Haddawy P. Generating Bayesian Networks from Probabilistic Logic Knowledge Bases[A]//Proceedings of the 10th Annual Conference on Uncertainty in Artificial Intelligence[c]. Seattle, Washington, USA: Morgan Kaufman, 1994: 262-269
- [18] Kersting K, De Raedt L. Adaptive Bayesian Logic Programs[A]

- //Proc. of the 11th Conference on Inductive Logic Programming, vol. 2157 of LNCS[C], Strasbourg, France; Springer, 2001; 104-117
- [19] Kersting K, De Raedt L. Bayesian Logic Programs[D]. University of Freiburg, Institute for Computer Science, 2001
- [20] Friedman N, Getoor L, Koller D, et al. Learning Probabilistic Relational Models[A]//Proceedings of the 16th International Joint Conferences on Artificial Intelligence[c]. Stockholm, Sweden; Morgan Kaufmann, 1999; 1300-1309
- [21] Getoor L, Koller D, Taskar B, et al. Learning Probabilistic Relational Models with Structural Uncertainty[A]//Proceedings of the AAAI2000 Workshop on Learning Statistical Models from Relational Data[C]. Menlo Park, CA; AAAI Press, 2000; 13-20
- [22] Getoor L, Friedman N, Koller D, et al. Learning Probabilistic Models Of Relational Structure[A]//Proceedings of the 18th International Conference on Machine Learning[c]. Williamstown, MA, USA; Morgan Kaufmann, 2001; 170-177
- [23] Richardson M, Domingos P. Markov Logic Networks[D]. Seattle, Washington, USA; Department of Computer Science and Engineering, University of Washington, 2004
- [24] Domingos P, Richardson M. Markov Logic: A Unifying Framework for Statistical Relational Learning[C]//Proceedings of the ICML-2004 Workshop on Statistical Relational Learning and its Connections to Other Fields. Banf, Canada, 2004; 49-54
- [25] Kok S, Domingos P. Learning the Structure of Markov Logic Networks[A]//Proceedings of the 22nd International Conference on Machine Learning[C]. Bonn, Germany; ACM Press, 2005; 441-448
- [26] Singla P, Domingos P. Discriminative Training of Markov Logic Networks[A]//Proceedings of the 20th National Conference on Artificial Intelligence[C]. Pittsburgh, PA; AAAI Press, 2005; 868-873
- [27] 孙舒杨, 刘大有, 孙成敏, 等. 统计关系学习模型 Markov 逻辑网综述[J]. 计算机应用研究, 2007(2): 1-3
- [28] 孙舒杨, 刘大有, 孙成敏. 基于后验概率的 Markov 逻辑网参数学习方法[J]. 吉林大学学报: 理学版, 2006, 44(6): 946-950
- [29] Murphy K P, Weiss Y, Jordan M I. Loopy belief propagation for approximate inference: an empirical study [C] // Proc. UAI99. 1999; 467-475
- [30] Dempster A P, Laird N M, Rubin D B. Maximum Likelihood from Incomplete Data via the EM Algorithm[J]. Journal of the Royal Statistical Society. Series B (Methodological), 1977, 39(1): 1-38
-
- (上接第 12 页)
- [31] Wang X, Xing G, Zhang Y, et al. Integrated Coverage and Connectivity Configuration in Wireless Sensor Networks//Proceedings of First ACM Conference on Embedded Networked Sensor System (SenSys'03). 2003; 28-39
- [32] Zhang H, Hou J C. Maintaining Sensing Coverage and Connectivity in Large Sensor Networks//NSF International Workshop on Theoretical and Algorithmic Aspects of Sensor, Ad Hoc Wireless and Peer-to-Peer Networks. Feb. 2004
- [33] Slijepcevic S, Potkonjak M. Power Efficient Organization of Wireless Sensor Networks // Proceedings IEEE International Conference on Communications (ICC'01). Helsinki, Finland, 2001; 472-476
- [34] Charkrabarty K, Iyengar S, Qi H, et al. Grid Cover for Surveillance and Target Location in Distributed Sensor Networks. IEEE Transactions on Computers, 2002(2)
- [35] Zhou Zongheng, Das Samir, Gupta H. Fault Tolerant Connected Sensor Cover with Variable Sensing and Transmission Ranges. IEEE SECON, 2005
- [36] Huang C, Tseng Y. The Coverage Problem in a Wireless Sensor Network//WSNA'03. San Diego, California, USA, 2003
- [37] Wu J, Yang S. Energy - efficient Node Scheduling Models in Sensor Networks with Adjustable Ranges. International Journal of Foundations of Computer Science, Feb. 2005
- [38] Zhou Zongheng, Das S, Gupta H. Connected K - Coverage Problem in Sensor Networks. ICCCN, 2004; 373-378
- [39] Li Deying, Cao Jiannong, Liu Ming, et al. K - connected Target Coverage Problem in Wireless Sensor Networks//First International Conference on Combinatorial Optimization and Applications, LNCS 4616. 2007; 20-31
- [40] Li Deying, Cao Jiannong, et al. Algorithms for the m-coverage Problem and k-connected m-Coverage Problem in Wireless Sensor Networks. NPC, LNCS 4672, 2007
- [41] 蒋杰. 无线传感器网络覆盖控制研究. 博士学位论文. 国防科技大学工学
- [42] Meguerdichian S, Koushanfar F, Qu G, et al. Exposure in Wireless Ad Hoc Sensor Networks//Proceedings of 7th Annual International Conference on Mobile Computing Networking (MobiCom'01). July 2001; 139-150
- [43] Li N, Hou J C. FLSS: A Fault-tolerant Topology Control Algorithm for Wireless Networks // Proceedings of MobiCom. 2005; 275-286
- [44] Li X - Y, Wan P - J, Wang Y, et al. Fault Tolerant Deployment and Topology Control in Wireless Networks // Proceedings of MobiHoc. 2003; 117-128
- [45] Jaggi N, Abouzeid A A. Energy-efficient Connected Coverage in Wireless Sensor Networks. AMOC, 2006; 85-100
- [46] Hedetniemi S M, Hedetniemi S T, Liestman A L. A Survey of Gossiping and Broadcasting in Communication Networks. Networks, 18(4): 319-349
- [47] Heinzelman W R, Kulik J, Balakrishnan H. Adaptive Protocols for Information Dissemination in Wireless Sensor Networks//Proceedings of the 5th Annual Joint ACM/IEEE International Conference on Mobile Computing and Networking (MOBI-COM'99). Seattle, WA, USA, New York, NY; ACM Press, 1999; 174-185
- [48] Intanagonwiwat C, Govindan R, Estrin D, et al. Directed Diffusion for Wireless Sensor Networking. IEEE/ACM Transactions on Networking, 2003, 11(1): 2-16
- [49] Braginsky D, Estrin D. Rumor Routing Algorithm for Sensor Networks//Proceedings of the 1st ACM International Workshop on Wireless Sensor Networks and Applications. Atlanta, GA, United States; ACM Press, 2002; 22-31
- [50] Ye W, Heidemann J, Estrin D. An Energy-Efficient MAC Protocol for Wireless Sensor Networks // INFOCOM 2002. June 2002