电子商务中价格战问题的研究*)

Research on Price War of Electronic Commerce

周 晋 卢增祥 路海明 李衍达

(清华大学自动化系 北京100084)

Abstract With the rapid development of Internet and electronic commerce, the trade of information resource in electronic commerce has received the high recognition of many researchers abroad recently. During the process of trade of information resource, the myopic pricing policies of broker Agents lead to that price war emerged. The price war hurts brokers' profits and consumers' satisfaction. In this paper, in order to conquer price war, brokers' earning goal is changed from short-time to long-time by reinforcement learning. Incooperative and cooperative brokers' reinforcement learning model is brought forward. The simulation shows that reinforcement learning conquers the price war effectively and makes market steady. Reinforcement learning improves not only profit of brokers, but also satisfaction of consumers.

Keywords Price war, Electronic commerce, Reinforcement learning, Broker, Information resource

1 引言

随着互联网和电子商务的飞速发展,人们深刻地认识到信息资源的重要性,但事实上,许多重要信息不能在网公开出来。目前的情况是,一些人拥有某种信息,并且希望以此获利;另一些人渴望得到这些信息,并且愿意付出一定的代价。合理的解决之道便是进行信息资源的交易。

现在,在电子商务中,信息资源的交易是一个十分重要的研究领域,越来越多的学者投入到这方面的研究中。IBM研究机构的 Jeffrey O. Kephart 等人提出的信息过滤经济模型(Information Filtering Economy Model)^[1]是描述信息资源交易的典型模型之一。

和众多电子商务系统一样,信息过滤经济模型也是一个多 Agent 系统。在系统中,Agent 代表它们的拥有者,与其他人或者其他 Agent 进行信息资源的交易,这些 Agent 可以代表生产者、中间商以及消费者。交易的信息资源可以是:文章、新闻、音频、视频等等。

Jeffrey O. Kephart 的初步研究表明,在中间商 Agent 的定价过程中,出现了价格战现象(即:两个或者多个 Agent 为了各自利益,相互攀比地交错降低价格)。价格战使得中间商 Agent 的赢利大打折扣,同时,消费者 Agent 的需求无法得到完全的满足,对信息经济的充分发展十分不利。Jeffrey O. Kephart 提出的随机搜索最优定价策略可以在一定程度上缓和价格战,但在本质上,没有解决价格战的问题,并且效果改进有限。更关键的是,在现实中无人会采用随机的定价策略。

本文认为,中间商 Agent 在定价过程中的短视行为是造成价格战的根本原因,故将中间商 Agent 的赢利目标从短期改为长期,从而达到长期赢利和最大的目标,同时,也在更广泛的范围内,满足了顾客 Agent 的需求。算法采用 MDP(马尔可夫判定过程)模型中的强化学习算法,从中间商 Agent 合作、非合作两种情况下,分别进行了探讨。

2 信息过滤经济

2.1 信息过滤经济模型

信息过滤经济模型由三种 Agent 组成:生产者(source) Agent、中间商(broker) Agent 和顾客(consumer) Agent。

生产者 Agent(下简称生产者)代表信息资源生产者,它将生产出来的资源(不妨假设是一篇文章)公布到网上;中间商 Agent(下简称中间商)代表中间商,它有选择地从生产者处买进文章,再将它们卖给有此需求的顾客 Agent;顾客 Agent(下简称顾客)代表消费者,从中间商处购买自己感兴趣的文章。此外,系统环境为 Agent 的传输和计算两种服务。图1表明了整个系统的结构。

图1 信息过滤经济模型(实线代表文章的传输,虚线代表费用的支付)

1)符号含义 有关符号、含义、取值范围如表1所示。

2)计算公式 中间商 b 的赢利公式如下:

$$W_b = \sum_{c=1}^C \sum_{j=1}^J \alpha_c S_{bc} \beta_{bc} [P_b \gamma_{cj} (\prod_{v=1}^b (1 - S_{bv} \beta_{bv} \theta (P_b - P_v))) - P_r] - \sum_{j=1}^J \alpha_j (\beta_j P_s + P_c) \quad (1)$$

顾客 c 的赢利公式如下:

*)国家自然科学基金(60003004)项目。周 晋 博士生,研究方向为网络信息服务,人工智能,MAS。卢增祥 博士,讲师,研究方向为网络信息服务,人工智能,MAS。路海明 博士,讲师,研究方向为网络信息服务,人工智能,MAS。李衍达 教授,博士生导师,中国科学院院士,研究方向为网络信息服务,生物信息学,智能信号处理等。

$$U_c = \frac{\sum_{b=1}^B \sum_{j=1}^J \alpha_j S_{bc} \beta_{bj} \prod_{v=1}^B (1 - S_{bv} \beta_{bv} \theta(P_b - P_v))}{[(V - P_b) \gamma_{cj} - P_c]} \quad (2)$$

表1 符号含义汇总

符号	含义	取值范围
J	文章类别的总数	1, 2, ...
B	中间商个数	1, 2, ...
C	顾客个数	1, 2, ...
P_T	Agent 传输文章时, 向系统环境缴纳的传输费用	(0, 1)
P_C	Agent 进行计算时, 向系统环境缴纳的计算机费用	(0, 1)
Δ	价格调整的最小变化量	(0, 1)
α_j	文章属于第 j 类的概率	[0, 1]
β_{bj}	中间商 b 对第 j 类文章的购买概率	0 或 1
γ_{cj}	顾客 c 对第 j 类文章的购买概率	[0, 1]
P_s	资源对文章的定价	[0, +∞]
P_b	中间商对文章的定价	[0, 1]
V	顾客对文章的估价	[0, 1]
S_{bc}	中间商 b 与顾客 c 进行交易的可能性	0 或 1
$\theta(x)$	阶跃函数: 若 $x > 0$, 则 $\theta(x) = 1$; 否则, $\theta(x) = 0$	0 或 1

3) 一个完整的交易流程(图2)

图2

2.2 myopic 策略

由公式(1)可以看出, 每个时刻, 中间商 b 可以通过调整参数 P_b 和 β_{bj} ($0 \leq j \leq J$) 使自己的赢利 W_b 最大化。为简化模型, 假设在每一时刻只允许一个中间商(随机抽取)调整参数(事实上, 在现实中两个中间商同时调整参数的可能性极小), 其他中间商的参数在这一时刻保持不变。

调整参数所依据的策略, 也就是定价策略, 是由中间商 Agent 的拥有者事先人为设定的, 定价策略设定的好坏, 直接导致中间商 Agent 赢利的多少。在众多定价策略中, 最简单

也是最常用的一种策略便是 myopic 策略(myopically optimal strategy)。

myopic 策略的思想是: 通过调整参数, 使自己在当前时刻的赢利达到最大。这种策略只考虑当前时刻的赢利, 而不考虑长期赢利的积累情况, 是一种短视的策略。

myopic 策略的实现是通过遍历可调参数的每一种情况, 计算出每种参数情况对应的赢利, 从中找出最大者, 从而确定当前时刻下的参数值。

2.3 价格战现象

1) 实验一: Myopic-Myopic 考虑信息过滤经济模型的简单情形, 即: 系统中只有两个中间商($B=2$), 文章只有一种分类($J=1$)。其余的参数取值: $C=100, \alpha_1=1, \gamma_{c1}$ 满足 $[0, 1]$ 之间的均匀分布, $P_T=0.3, P_C=0.3, V=1, \Delta=0.02, P_s=0$ (因为 P_s 所起作用仅仅是决定中间商们的顾客群的大小), 中间商参数初始值 $P_b=0.48, \beta_1=1$ (说明: 参数取值均参照 Jeffrey O. Kephart 的试验^[1])。

设每个中间商定价策略为 myopic 策略, 仿真 100 个时刻, 得出价格曲线和 W_1 曲线分别如图 3、图 4 所示。

图3 价格曲线(Myopic-Myopic)

图4 W_1 曲线(Myopic-Myopic)

在图3中, 两个中间商为了争取当前时刻赢利最大化, 攀比降低自己的价格, 当价格降低到一定程度时, 由于交易价格 P_T, P_C 的存在, 价格不会稳定在这个极小值上, 而是又回升到一个极大的价格值上, 重新开始新一轮的降价比赛。这点不同于常规经济中价格战, 常规经济价格战的结果是双方的价格稳定在一个不能再低的价格上, 这是因为在常规经济中, 交易若没有达成, 不会损失任何花费。而在信息过滤经济模型中, 中间商需要预测顾客群、发送信息产品给顾客预览, 也就是前面所提到的交易价格, 无论交易是否达成, 交易价格都将花费掉, 这导致了不同的定价面临的不同的顾客群。由于交易价格

的缘故,中间商的低定价会损失掉一部分顾客,因此并不一定低定价就能抢走高定价的所有顾客。当定价低到一定程度时,某个较高定价反而能赚到更多钱。总之,交易价格使得价格战周而复始地进行。关于信息交易中价格战的经典理论,可参见文[2]。

图4是中间商1的赢利 W_1 随时间变化的曲线,参照图3,可以看出,当中间商2定价时,中间商1的赢利几乎为0。同样,当中间商1定价时,中间商2的赢利也几乎为0。这是说明 myopic 是一种非合作策略,为了使自己赢利最大,调整价格抢占了对手的大部分顾客。

2) 价格战产生的原因 在 $B=2, J=1$ 的情况下,两个中间商必然都会选择第1类进行经营,即 $\beta_{11}=\beta_{12}=1$,所以中间商的参数调整实际上就是价格上的调整。对于中间商1,除对手的价格外,系统环境中各个参量不随时间变化而改变,故中间商1的定价 P_1 由 P_2 而定。定义 P_1 的最优定价函数 $P_1^*(P_2)$ 为:当中间商2的价格为 P_2 时,使 W_1 最大的价格为 P_1^* 。同样,可以定义出 P_2 的最优定价函数 $P_2^*(P_1)$ 。根据仿真数据,画出 $P_1^*(P_2)$ 与 $P_2^*(P_1)$ 曲线,如图5所示。

图5 myopic 策略下的 $P_1^*(P_2)$ 与 $P_2^*(P_1)$

在图5中,我们可以通过做图法,得到价格战的过程。例如:首先,任选一点 (P_1, P_2) ,从该点出发,由中间商1先定价,平行于 P_1 轴,向曲线 $P_1^*(P_2)$ 投影,得到当前 P_2 下,中间商1的 myopic 策略;然后中间商2定价,平行于 P_2 轴,向曲线 $P_2^*(P_1)$ 投影,得到当前 P_1 下,中间商2的 myopic 策略;如此交替定价下去,……,最终,在 $P_1^*(P_2)$ 曲线上的 $(0.400, 0.425)$ 点,价格战转向 $P_2^*(P_1)$ 曲线的 $(0.400, 0.517)$ 点,再转回 $P_1^*(P_2)$ 曲线上的 $(0.485, 0.517)$ 点,这样,新一轮的价格战又开始了。

从本质上说,价格战产生的原因是:由于交易价格的存在,在边缘价值模型 (Edgeworth's model)^[1] 中,最大赢利存在多个峰,导致系统最优解在多个峰之间跳来跳去,不能稳定下来。

3) 价格战的危害 价格战对于中间商的赢利和顾客的需求满足程度都有很大的危害^[3]。

由于中间商采取了短视的 myopic 定价策略,只追求当前赢利最大化,而不考虑长期赢利和,不考虑自己的定价对其它竞争者的影响,事实上,它的定价极大地削减了其它竞争者的赢利;相对地,其它竞争者在定价时,也削减了它的赢利。从长远来看,价格战给所有的中间商都带来了赢利上的损失,或者说,中间商们的长期赢利之和没有达到最大化。

从顾客的角度看,由于中间商采用 myopic 策略,中间商常常会选择热门类别的文章去经营,经营范围集中在很少的几个类别里,而其它类别则遭到冷落,这样,对这些类别的文章有需求的顾客便得不到满足,所以价格战也给顾客的满意

度带来了危害。

3 强化学习算法

如前所述,中间商的短视行为是导致自己的长期赢利非最大化的直接原因,自然地,我们希望中间商树立长远的目标,强化学习算法可以帮助中间商以长期赢利和最大化为目标来调整自己的定价。因此,我们将强化学习算法引入到中间商的定价过程中来。下面先介绍一下强化学习的知识。

强化学习是从动物学习、参数扰动自适应控制等理论发展而来。其基本原理是:如果 Agent 的某个行为策略导致环境正的奖赏(强化信号),那么 Agent 以后产生这个行为策略的趋势便会加强。很多强化学习问题可以形式化为马尔可夫判定过程(MDP),其定义如下:

定义1 马尔可夫判定过程(MDP):离散的动作集 A , 奖赏函数 $R: S \times A \rightarrow R$ 和状态转移函数 $T: S \times A \rightarrow PD(S)$ 。Agent 的目标是在每个离散状态发现最优策略以使期望的折扣奖赏和最大。

定义 Q 值为状态-动作对的估计,根据对 MDP 的定义,显然有:

$$Q(s, a) = R(s, a) + \gamma \sum_{s' \in S} T(s, a, s') \max_{a'} Q(s', a') \quad (3)$$

其中 $s \in S, a \in A, s' \in S, s'$ 是 s 经过动作 a 后的下一状态。 γ 为折扣因子,且 $0 < \gamma < 1$ 。在已知 R 和 T 条件下,可以解(3)式得到最终的 Q 值。然而在实际应用中, R 和 T 函数是未知的,因此 Agent 学习面临时间信度分配的困难,传统强化学习采用时间差分法 (Temporal Difference, TD) 来解决时间信度分配,如下式所示:

$$Q(s, a) = (1 - \alpha)Q(s, a) + \alpha(r + \gamma \max_{a'} Q(s', a)) \quad (4)$$

其中, α 为学习率, r 为在状态 s 下,采取动作 a 得到的奖赏。这时的强化学习算法称为 Q 算法。根据 Markov 理论和随机逼近理论,可以证明在一定条件下, Q 算法收敛在 MDP 得最优解。

4 强化学习在价格战中的应用

一般在设计 Q 算法时,首先需要考虑:如何表示状态空间 S 、动作空间 A 以及奖赏 r 。此处,在整个定价过程中,环境中发生变化的只有对手的定价,对环境的学习也就是对对手价格变化的学习。所以,我们把对手上一次的定价设为当前中间商面临的状态 s ,所有状态 s 构成的集合为状态空间 S ;定义当前中间商的定价为动作 a ,所有动作 a 构成的集合为动作空间 A 。当前中间商定价后,对手的再次定价便是下一状态 s' ;定义中间商在这两步中的赢利和 $W_1^{(1)} + W_1^{(2)}$ 为奖赏 r 。

下面给出信息过滤经济模型中,中间商定价的 Q 学习算法:

- ①初始化: $\forall s \in S, \forall a \in A, Q_0(s, a) = 1; \alpha_0 = 1; \gamma = 0.5$ 。
- ②随机选择状态动作对 (s, a) 。
- ③学习:在 t 时刻,中间商得到经验 (s, a, s', r) , 则 $\alpha_t =$

$$\frac{\alpha_0}{n_t(s, a)}, \text{ 其中 } n_t(s, a) \text{ 为到 } t \text{ 时刻为止,中间商得到的经验 } (s, a) \text{ 的次数。调整 } Q \text{ 值: } Q_t(s, a) = (1 - \alpha_t)Q_{t-1}(s, a) + \alpha_t(r + \gamma \max_{a'} Q_{t-1}(s', a))$$

- ④若所有 Q 值均收敛,则结束;否则,跳回②。

待中间商完成对环境的学习后,便可根据 Q 值表进行定价。定价时,根据对手的定价 s ,在 Q 值表中,选择最大的 $Q(s, a)$ (其中 a 任选)对应的动作 a' 为新的定价。这样,便能使长期赢利和达到最大。

4.1 非合作的决策过程

在上面所述的 Q 学习算法中, r 取为中间商自己的赢利

和,这表明中间商只以自己的期望折扣奖赏和最大化为目标,并不考虑对手的赢利情况,这时的决策过程是一个非合作的博弈过程。在非合作情况下,为了比较 Q 学习与 myopic 的优越性,我们设计了以下两个实验。

1) 实验二: Q 学习-Myopic 中间商1采取 Q 学习策略,中间商2采取 myopic 策略,实验结果如图6所示。

2) 实验三: 非合作的 Q 学习-非合作的 Q 学习 中间商1、2均采用 Q 学习策略,实验结果如图7所示。

4.2 合作的决策过程

如果我们认为整个系统的最优策略是使整体赢利最大的策略(即:整体赢利 = $\sum_{b=1}^B W_b$),由“组合谬误”理论知道:每个 Agent 的最优策略的组合不一定是整个系统的最优策略。欲使整体赢利最大,那么每个中间商不仅要考虑自己的赢利状况,还应兼顾他人的赢利,这样,整个定价决策过程便是一个合作的博弈过程。对于采取合作 Q 学习策略的中间商,重新定义奖赏 r:

$$r = \lambda(W_b^{(1)} + W_b^{(2)}) + (1 - \lambda)(W_b^{(1)} + W_b^{(2)}) \quad (5)$$

其中 λ 为比例因子,且 $0 < \lambda < 1$; $b' \neq b$; $W_b^{(1)}$ 、 $W_b^{(2)}$ 分别表示中间商 b 的第一步和第二步赢利。在上式中,该中间商目标是自己与他人的长期加权赢利和最大化。

为了比较合作与非合作情况下 Q 学习的优越性,我们设计了以下三个实验。

图6 价格曲线(Q 学习-Myopic)

图7 价格曲线(非合作的 Q 学习-非合作的 Q 学习)

1) 实验四:合作的 Q 学习-非合作的 Q 学习 中间商1采用合作的 Q 学习策略($\lambda=0.7$),中间商2采取非合作的 Q 学习策略,实验结果如图8所示。

2) 实验五:合作的 Q 学习-合作的 Q 学习($\lambda=0.7$) 中间商1、2均采用有合作倾向的 Q 学习策略($\lambda=0.7$),实验结果如图9所示。

3) 实验六:合作的 Q 学习-合作的 Q 学习($\lambda=0.5$) 中间商1、2均采用有合作倾向的 Q 学习策略($\lambda=0.5$).此时,奖

赏 r 是准确意义上的整体赢利。实验结果如图10所示。

图8 价格曲线(合作的 Q 学习-非合作的 Q 学习)

图9 价格曲线(合作的 Q 学习-合作的 Q 学习, $\lambda=0.7$)

图10 价格曲线(合作的 Q 学习-合作的 Q 学习, $\lambda=0.5$)

4.3 实验数据结果及分析

六组实验的数据结果见表2。

表2 效益比较

实验	中间商定价策略	W_1	W_2	整体赢利	交易率	顾客总赢利
一	1、2: myopic	1.194	1.195	2.389	19.7%	4.654
二	1: 非合作的 Q 学习; 2: myopic	1.554	1.228	2.782	20.5%	4.381
三	1、2: 非合作的 Q 学习	1.438	1.594	3.032	20.7%	4.145
四	1: 合作的 Q 学习; 2: 非合作的 Q 学习	1.081	2.680	3.761	20.1%	2.981
五	1、2: 合作的 Q 学习($\lambda=0.7$)	2.079	2.221	4.300	19.7%	2.750
六	1、2: 合作的 Q 学习($\lambda=0.5$)	5.405	-0.127	5.278	15.5%	1.521

注:交易率=实际交易总量/可能交易总量,表中结果均为100步数据的平均值。

1) 非合作的决策过程 在实验二中,中间商1采用 Q 学习策略,从而预先考虑到自己的定价给对手带来的影响,从长远出发,以自己长期赢利和最大为目标,定出了合理的价格,减小了价格战的幅度,故 W_1 比实验一时增加了 30.2%,可见 Q 算法在定价过程中,很好地发挥了效果;另外,我们还发现,作为中间商1的对手,虽然中间商2依然采取 myopic 策略,但是它的赢利较实验一时也有提高,这也是由于价格战幅度减小的缘故,可以说,中间商1采取 Q 学习策略是一种对整个集体都有利的行为。同时,由于价格战的减弱,整个系统的交易率也随之提升,交易率的提高代表了顾客满意度的提高。当然,在交易率变化不大的前提下,中间商赢利提高,必然导致顾客总赢利的下降,但这并不是一件坏事,因为在市场中,对于顾客而言,需求被满足是更关键的事情。

在实验三中,与实验一相比,Q 学习策略使得 W_1 提高了 20.4%, W_2 提高了 33.4%,整体赢利提高了 26.9%,更加有效地克服了价格战的危害。此外,实验三与实验二相比,整体赢利和交易率也都有提高。

综上所述,在非合作的决策过程中,强化学习可以有效地遏制价格战,稳定市场,既增加了中间商的盈利,也提高了顾客的满意度。

2) 合作的决策过程 在实验四中,与实验三相比,由于中间商2采取了非合作策略,中间商1从它这里得不到任何好处,相反,由于中间商1采取了合作策略,把本属于自己的一部分顾客群也奉献给了中间商2,所以, W_1 下降了 24.8%, W_2 提高了 68.1%。此外,中间商1的合作行为使得整体赢利有所提高,但我们发现,这也导致了交易率的下降。

在实验五中,由于两个中间商均采取合作策略,因此每个中间商的赢利以及整体赢利都大大提高了,即使相对于实验四,整体赢利也提高了 14.3%,这充分体现了合作的优点。但是,中间商们的合作行为导致交易率下降到 19.7%,这是因为这里的合作类似于现实经济中的垄断行为。由于中间商的垄断,使得平均价格比以前四种情况的平均价格高出了许多(见图9),从而使得交易率下降。从图9还可以看出,中间商采取了合作的 Q 学习策略之后,价格战的幅度与周期比前面三种情况都有所减小,即更有效地削弱了价格战现象。此外,由于每个中间商的目标是以自己赢利最大化为主要,兼顾考虑对手的赢利,也就是说,中间商们的目标并不一致,所以价格战仍然存在。

在实验六中,两个中间商的目标一致,价格稳定在定值,

彻底结束了价格战,使得整体赢利达到最优。但是 $W_2 < 0$,这会使得中间商2不愿意与中间商1合作,所以在这种情况下,往往需要合作双方事先定下规则,交易结束后,按照规则重新划分赢利。但在现实世界中,这种完全合作很难达成。

综上所述,在合作的决策过程中,强化学习可以进一步遏制价格战,稳定市场,大幅度地提高中间商的盈利。但由于中间商的合作是一种垄断行为,因此导致消费者的满意度有所降低。

另外,值得强调的是,无论是合作情况还是非合作情况,通过在不同的折扣因子 γ 下进行仿真实验,我们发现:随着 γ 的增大,若 Q 函数收敛,整体赢利单调递增。

结束语 本文针对电子商务中信息资源交易的价格战问题展开讨论,在中间商 Agent 的定价过程中,利用强化学习算法,将中间商 Agent 的赢利目标从短期改为长期,并提出中间商非合作、合作两种情况下的强化学习模型。仿真试验表明了该方法的有效性,在非合作情况下,学习算法有效地遏制了价格战,提高了中间商的赢利与顾客的满意度;在合作情况下,学习算法可以为中间商进一步提高赢利,但顾客的满意度有所下降。

本文所依据的信息过滤经济模型在应用时,也有一定的限制。主要原因是:信息过滤经济模型假设中间商能够清楚地知道全局信息,而在现实世界中,实现起来有所困难,需要花费一定的咨询费用。因此,在下一步的研究中,可能包括的研究内容有:①在中间商仅了解到非完全信息的情况下,如何设计最优定价策略;②考虑咨询费用的情况下,如何设计最优定价策略。

参考文献

- 1 Kephart J O, Hanson J E, Skirmish J. Price-War Dynamics in a Free-Market Economy of Software Agents. Proceedings of ALIFE VI, UCLA, Los Angeles, CA, USA, MIT Press, Cambridge, MA, USA, UCLA, 1998. 26~29
- 2 Tirole J. The Theory of Industrial Organization. The MIT Press, Cambridge, MA, 1988
- 3 Kephart J O, Hanson J E, Skirmish J. Price and Niche Wars in a Free-Market Economy of Software Agents, MIT Press, Sep. 1998
- 4 Kaelbling L P, Littman M L, Moore A W. Reinforcement learning: A survey. Journal of Artificial Intelligence Research, 1996, 4: 237~285

(上接第62页)

- 10 Garcia-Molina H, Ullman J, Widom J. Database System Implementation Prentice-Hall, 2000
- 11 Hosoya H, Pierce B C. XDuce: A Typed XML Processing Language. <http://www.cis.upenn.edu/~hahosoya/xduce.html>, 2000. Full version
- 12 <http://www.w3.org/TR/query-algebra/>
- 13 Paredaens J, Gucht D V. Converting nested relational algebra expressions into flat algebra expression. ACM Transaction on Database Systems, 1992, 17(1): 65~93
- 14 Quass D, et al. Lore: A lightweight object repository for semistructured data. In: Proc. of the ACM SIGMOD Intl. Conf. on Management of Data, Montreal, Canada, June 1996. 549
- 15 Deutsch A, et al. XML-QL: a query language for XML. W3C Note NOTE-xml-ql-19980819. See <http://www.w3.org/TR/NOTE-xml-ql>.
- 16 Christophides V, Cluet S, Simeon J. On wrapping query languages and efficient XML integration. In: Proc. of ACM Conf. on Management of Data (SIGMOD), Dallas, Texas, May 2000
- 17 Robie J, Lapp J, Schach D. XML query Language (xql). Workshop on XML Query Languages, W3C Dec. 1998
- 18 Beech D, Malhotra A, Rys M. A Formal Data Model and Algebra for XML. W3C XML Query working group note, Sep. 1999
- 19 Fankhauser P, et al. The XML Query Algebra, W3C Working Draft, 15 February 2001. <http://www.w3.org/TR/2001/WD-query-algebra-20010215/>
- 20 Beerl C, Tzaban Y. SAL: An algebra for semistructured data and XML. In: Informal Proc. of Workshop on The Web and Databases, ACM SIGMOD, June 1999
- 21 World Wide Web Consortium. <http://www.w3.org/>
- 22 <http://www.haskell.org/>
- 23 Ives Z G, Levy A Y, Weld D S. Efficient Evaluation of Regular Path Expressions on Streaming XML Data: [Technical Report UW-CSE-2000-05-02]. University of Washington
- 24 Goldman R, Chawthe S, Crespo A, McHugh J. A Standard Textual Interchange Format for the Object Exchange Model (OEM). Department of Computer Science, Stanford University, California, USA, 1996
- 25 Fernandez M, Suciu D. Optimizing Regular Path Expressions Using Graph Schemas. In: Proc. ICDE, 1998