

数据流上的预测聚集查询处理算法*

李建中⁺, 郭龙江, 张冬冬, 王伟平

(哈尔滨工业大学 计算机科学与技术学院, 黑龙江 哈尔滨 150001)

Processing Algorithms for Predictive Aggregate Queries over Data Streams

LI Jian-Zhong⁺, GUO Long-Jiang, ZHANG Dong-Dong, WANG Wei-Ping

(Institute of Computer Science and Technology, Harbin Institute of Technology, Harbin 150001, China)

+ Corresponding author: Phn: +86-451-86415827, E-mail: lijzh@hit.edu.cn, <http://db.cs.hit.edu.cn>

Received 2004-05-17; Accepted 2005-02-03

Li JZ, Guo LJ, Zhang DD, Wang WP. Processing algorithms for predictive aggregate queries over data streams. *Journal of Software*, 2005,16(7):1252–1261. DOI: 10.1360/jos161252

Abstract: It is very important in a lot of applications to forecast future trend of data streams. For example, using predictive queries to a sensor network for monitoring environment, observers can forecast future average temperature and humidity in the area covered by the network to determine abnormal events. Recent works on query processing over data streams mainly focused on approximate queries over newly arriving data. To the best of the knowledge, there is nothing to date in the literature on predictive query processing over data streams. Adopting multivariable linear regression, a predictive mathematical model for forecasting the aggregate value over data streams is first proposed. Then, based on the model, a predictive aggregate query processing method over data streams is proposed in the paper. When the frequency of forecast failing is greater than a predefined threshold, an adaptive strategy for the predictive mathematical model is proposed. A mathematical model that characterizes the affects of the updating cycle of sliding window and data stream rate on predictive accuracy is also presented. Analytical and experimental results show that the proposed method is very effective, and the proposed algorithms have higher performance and provide better prediction of aggregate values over data streams to users. In experiments the TPC-H data and ocean air temperature data measured by TAO (tropical atmosphere ocean) are used to construct data streams.

Key words: data stream; future data window; multivariable linear regression; predictive aggregate queries

摘要: 实时数据流未来趋势的预测具有重要的实际应用意义.例如,在环境监测传感器网络中,通过对感知数据流进行预测聚集查询,观察者可以预测网络覆盖的区域在未来一段时间内的平均温度和湿度,以确定是否会发生异常事件.目前的研究工作多数集中在数据流上当前数据的查询,数据流上预测查询的研究工作还很少.采

* Supported by the National Natural Science Foundation of China under Grant No.60473075 (国家自然科学基金); the Key Project of the Natural Science Foundation of Heilongjiang Province under Grant No.ZJG03-05 (黑龙江省自然科学基金重点项目)

作者简介: 李建中(1950—),男,黑龙江哈尔滨人,博士,教授,博士生导师,CCF 高级会员,主要研究领域为数据库,并行计算技术;郭龙江(1973—),男,博士生,讲师,主要研究领域为数据库,数据流,传感器网络;张冬冬(1976—),男,博士生,主要研究领域为分布式数据流;王伟平(1975—),男,博士生,主要研究领域为并行数据流。

用多元线性回归方法,给出了数据流上的聚集值预测模型,提出了一种数据流预测聚集查询处理方法.当预测失败的次数大于预先给定的阈值时,给出了一种预测模型自动调整策略,以降低预测误差.还提出了滑动窗口的更新周期、数据流的流速对预测精度影响的数学模型.理论分析与实验结果表明,提出的预测聚集查询处理算法具有较高的性能,并且能够返回满足用户精度要求的预测查询结果.在实验中,采用 TPC-H 国际标准测试数据和 TAO(tropical atmosphere ocean)测量的海洋表面空气温度数据来构造数据流.

关键词: 数据流;未来数据窗口;多元线性回归;预测聚集查询

中图法分类号: TP311 文献标识码: A

近几年,数据流在股票交易、网络流量监控、网络安全监控、电信通信记录、传感器网络等许多领域有着广泛的应用.数据流不是存储在磁盘上的有限数据集合,而是无限的、连续的、快速的、实时的,以流的形式出现的数据集合.数据流中每个数据单元是一个元组,元组的个数是无穷的.由于这些特点,传统的数据库管理技术无法用于数据流的管理.人们目前已经研制了一些数据流管理系统(DSMS),如 STREAM^[1],Aurora^[2]和 TelegraphCQ^[3]以支持数据流上的连续查询^[4]和 Ad Hoc 查询^[5].

在数据流的连续查询中,用户通常需要限定数据流的查询范围.被限定的查询范围称为数据流上的窗口(window).例如,对股票交易数据流进行如下连续查询:SELECT AVG(price) FROM Trade WHERE type='bid' and sID='ACME' and volume>1000 BEGIN (NOW-90 SECONDS) END NOW.其中 Trade(sID,price,type,volume,tradeTimestamp)是股票交易数据流;sID 是股票描述符;price 是股票价格;type 是 price 的类型,包括:bid(出价)、ask(要价)和 trade(成交价);volume 表示股票成交量;tradeTimestamp 表示成交时间.NOW 是系统当前时间.BEGIN(NOW-90)END NOW 表示数据流 Trade 上从 NOW-90 到 NOW 这段时间内 Trade 的元组集合.该连续查询计算从 NOW-90 到 NOW 时间段内成交且成交量大于 1000 的 ACME 股票的平均出价.

为叙述方便,记关键字 BEGIN 后面的时间为 *begin_time*,END 后面的时间为 *end_time*.根据 *begin_time* 和 *end_time* 的取值将数据流上的查询窗口分为 3 类^[6]:(1) 如果 *begin_time* 和 *end_time* 均为固定值,则称这类窗口为快照窗口(snapshot window);(2) 如果 *begin_time* 是定值,而 *end_time* 是变化的值,则称这类窗口为界标窗口(landmark window).(3) 如果 *begin_time* 和 *end_time* 均为变化的值,则称这类窗口为滑动窗口(sliding window^[5]).目前的研究成果多数集中在数据流上的当前数据的聚集查询^[7-10]及历史数据的聚集查询^[11],人们还没有考虑数据流上未来数据窗口(*begin_time* 为系统当前时间,*end_time* 为未来时刻)上的预测聚集查询处理算法.预测聚集查询的一般形式为:SELECT AGG FROM stream WHERE \mathcal{E} BEGIN NOW END NOW+n SECONDS;其中 AGG 表示聚集函数 COUNT(计数),SUM(求和),AVG(平均值);stream 为数据流; \mathcal{E} 为含有数据流 stream 属性的条件谓词;[NOW,NOW+n]确定了数据流 stream 从系统当前时间到未来 n 秒的一个未来数据窗口.例如,如果希望预测出 ACME 这支股票从系统当前时间到未来 90s 之内成交量大于 1500 的平均要价,则预测聚集查询为:SELECT AVG(price) FROM Trade WHERE type='ask' and sID='ACME'and volume>1500 BEGIN NOW END NOW+90 SECONDS.本文提出了未来数据窗口的概念,并给出了数据流未来数据窗口上的预测聚集查询处理算法.

我们用 4 个例子来说明研究未来数据窗口上的预测聚集查询的意义和应用背景.

(1) 在一个股票电子交易中心,各个股票交易数据形成了源源不断的快速数据流.投资者希望根据现有的、已知的数据流中的数据去预测股票的未来走势.通过对股票交易数据进行预测聚集查询,使投资者能够抓住转瞬即逝的机遇,更好地指导投资者进行投资.

(2) 在无线传感器网络环境中,传感器感知的数据形成了感知数据流.例如,每个传感器节点都可以感知周围环境的温度和湿度,通过对感知数据流进行预测聚集查询,观察者可以预测网络覆盖的区域在未来一段时间内的平均温度和湿度,以确定网络覆盖区域在未来一段时间内是否会发生异常事件.

(3) 在电信行业中,通话记录以及各种行业事务数据形成了数据流.电信行业的管理者迫切需要在电信行业管理系统中开发出一套数据流预测系统,对行业事务数据流进行预测聚集查询,实时预测未来行业的发展,为行业决策者提供决策参考.

(4) 在移动对象信息管理系统中,移动物体连续不断地把自己的位置信息和速度信息发送给中心服务器,这些信息形成了一个数据流.用户希望知道某物体未来的位置和速度,这就需要移动物体信息管理系统具有预测的功能并能给出相应的预测聚集查询,例如查询未来某物体的平均速度.

在本文研究的基础上可以计算数据流上更宽窗口上的聚集值,这个窗口可以包括过去、现在和未来时刻.首先把这个大窗口分解成两个窗口(如图 1 所示):窗口 1 定义为从过去时刻 t_1 到系统当前时刻 t_2 ,窗口 2 定义为从 t_2 到未来时刻 t_3 .对于窗口 1 中的聚集值可以利用文献[7-11]中的算法计算,对于窗口 2 中的聚集值可以采用本文的算法计算,最后再把两个结果合并.

本文第 1 节讨论预测聚集查询处理模型;第 2 节提出 AVG 的预测聚集查询处理算法和调整策略;第 3 节是实验;第 4 节对本文的工作进行总结.




Fig.1 Decomposed figure of a wide window including history and future data windows

图 1 包括历史窗口和未来窗口的宽窗口的分解

1 预测聚集查询的处理模型

预测聚集查询处理模型如图 2 所示.滑动窗口(sliding window)主要用于保存最新到达的流数据.本文讨论的滑动窗口是基于时间戳的滑动窗口(timestamp-based sliding window)^[12],它保留最近 Δt 时间内到达的流数据, Δt 称为滑动窗口的更新周期(updating cycle of sliding window).滑动窗口内的元组数目是一个随机变量.滑动窗口在系统中实际上是一块内存缓冲区,新到达的数据进入这个缓冲区.经过 Δt 的时间间隔,滑动窗口内的数据被移到数据缓冲区(data buffers)中,滑动窗口继续接纳新的数据.预测查询执行器(predictive query executor)用数据缓冲区中的数据建立预测模型以响应用户的预测查询(predictive query),并给出查询结果(query results).执行预测查询的时间要小于 Δt .系统中有 s 个缓冲区,保存最近 s 个 Δt 时间间隔内到达滑动窗口中的数据.这 s 个缓冲区编号为 $1, 2, \dots, s$.编号越大表示缓冲区中的数据越新,数据缓冲区中的数据也需要周期性地更新.预测查询执行器(predictive query executor)维护一个数据结构,称为查询状态结构(query state structure),简称 QSS 结构.该结构包含 4 个域:预测聚集查询 ID(predictive query ID),预测聚集查询的谓词条件(qualification),预测方程的系数(coefficients of predictive equation)(预测方程将在第 2.1.2 节中提到),指针域(pointer field).指针域中的指针指向计数预测表(counting prediction table)^[13].QSS 结构如图 3 所示.

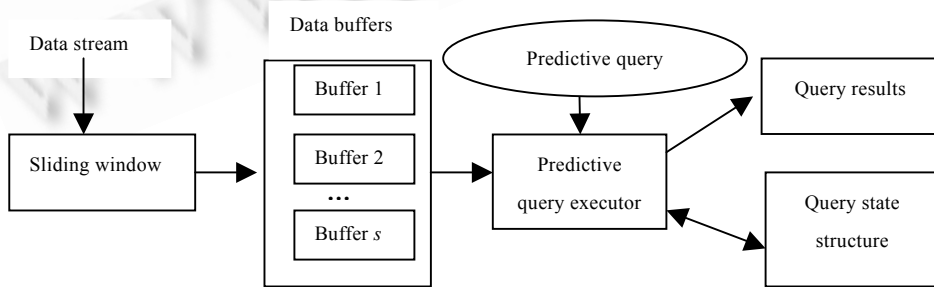


Fig.2 Processing model of predictable aggregate queries over data streams

图 2 数据流上的预测聚集查询处理模型




Fig.3 Query state structure

图 3 查询状态结构

2 AVG 的预测聚集查询处理算法和调整策略

设数据流的起始时刻为 t_1 , 系统的当前时刻为 t_2 . 把 $[t_1, t_2]$ 均分成 h 个长度为 Δt 的时间间隔, Δt 为滑动窗口的更新周期. 在第 k 个时间间隔内, 如果新到的数据满足预测聚集查询的谓词条件, 则进入滑动窗口. 在第 k 个时间间隔内, 滑动窗口内所有元组的 AVG 聚集属性 A 的取值为一个随机变量, 记为 X_k . 用滑动窗口上的随机抽样算法 priority-sample^[12] 获得 X_k 的 n 个样本点 $X_{1k}, X_{2k}, \dots, X_{nk}$. 这 n 个样本点关于属性 A 的平均值记为 $Y_k = \frac{1}{n} \sum_{i=1}^n X_{ik}$, Y_k 为一随机变量. Y_1, Y_2, \dots 是按时间次序排列的随机变量序列. 数据缓冲区中的第 i 个缓冲区里保留的是在第 $h-s+i$ 个时间间隔内滑动窗口中的数据 ($i=1, 2, \dots, s$), 其中 s 是数据缓冲区中缓冲区的个数. 利用第 i 个缓冲区中的数据, 可以计算出随机变量 Y_{h-s+i} 的 m 个样本的实际取值 $y_{k, h-s+i} (k=1, 2, \dots, m; i=1, 2, \dots, s)$. AVG 的预测聚集查询处理算法的基本思想是, 利用数据 $y_{k, h-s+i} (k=1, 2, \dots, m; i=1, 2, \dots, s)$ 建立预测方程, 预测出含有多个 Δt 的未来数据窗口上关于属性 A 的聚集值.

2.1 数学基础

本文提出的算法建立在预测模型的基础之上. 本节介绍我们提出的数据流上的预测模型和预测模型的显著性检验及预测误差估计.

2.1.1 预测模型

为叙述方便, 把随机变量序列 Y_1, Y_2, \dots 的最近 s 个随机变量 $Y_{h-s+1}, Y_{h-s+2}, \dots, Y_h$ 记为 Y_1, Y_2, \dots, Y_s . 于是可以用随机变量 Y_{s+1} 表示宽度为 Δt 的未来数据窗口上的 AVG 聚集值, 令 $Z = Y_{s+1}$. Y_1, Y_2, \dots, Y_s 为影响 Z 的 s 个因素. 假设 Y_1, Y_2, \dots, Y_s 和 Z 的估计值 \hat{Z} 有如下线性关系: $\hat{Z} = \beta_0 + \beta_1 Y_1 + \beta_2 Y_2 + \dots + \beta_s Y_s$, 其中 $\beta_0, \beta_1, \dots, \beta_s$ 是待计算的参数. 用 $\beta_0 + \beta_1 Y_1 + \beta_2 Y_2 + \dots + \beta_s Y_s$ 去预测 Z 可能有误差, 因此调整 Z 和 Y_1, Y_2, \dots, Y_s 的线性关系为 $Z = \beta_0 + \beta_1 Y_1 + \beta_2 Y_2 + \dots + \beta_s Y_s + \varepsilon$, ε 是不可观测的随机误差, 它也是一个随机变量.

定理 1. 当 $n \rightarrow \infty$ 时, $Y_k = \frac{1}{n} \sum_{i=1}^n X_{ik} (k=1, 2, \dots, s, s+1)$ 服从正态分布, 记 $Y_{s+1} = Z$, 则 Z 服从正态分布.

证明: 因为 $Y_k = \frac{1}{n} \sum_{i=1}^n X_{ik}$, $X_{1k}, X_{2k}, \dots, X_{nk}$ 都来自同一个总体 X_k 且相互独立, 它们就有相同的数学期望和方差.

记 X_k 的数学期望为 μ_k , 方差为 σ_k^2 . 由中心极限定理可知, 当 $n \rightarrow \infty$ 时, 有 Y_k 服从 $N\left(\mu_k, \frac{\sigma_k^2}{n}\right)$. 特别地, $Z = \frac{1}{n} \sum_{i=1}^n X_{i, s+1}$,

则 Z 服从 $N\left(\mu_{s+1}, \frac{\sigma_{s+1}^2}{n}\right)$. □

定理 2. 令 $\hat{Z} = \beta_0 + \beta_1 Y_1 + \beta_2 Y_2 + \dots + \beta_s Y_s$, 则 \hat{Z} 服从正态分布.

证明: 由定理 1 可知 $Y_k (k=1, 2, \dots, s)$ 服从正态分布. 由于 Y_k 表示第 k 个时间间隔内滑动窗口内随机取出的 n 个元组在属性 A 上的平均值, 因此 Y_1, Y_2, \dots, Y_s 相互独立. 如果 $\hat{Z} = \beta_0 + \beta_1 Y_1 + \beta_2 Y_2 + \dots + \beta_s Y_s$, 相互独立的正态随机变

量的线性组合仍然服从正态分布,故 \hat{Z} 服从 $N\left(\beta_0 + \sum_{k=1}^s \beta_k \mu_k, \frac{\left(\sum_{k=1}^s \beta_k^2 \sigma_k^2\right)}{n}\right)$. □

定理 3. ε 服从正态分布 $N(\mu, \sigma^2)$, 其中 $\mu = \mu_{s+1} - \beta_0 - \sum_{k=1}^s \beta_k \mu_k, \sigma^2 = \frac{\left(\sum_{k=1}^{s+1} \beta_k^2 \sigma_k^2\right)}{n}$.

证明:由定理 1 可知 $Y_k(k=1,2,\dots,s)$ 和 Z 均服从正态分布.由定理 2 可知 Y_1, Y_2, \dots, Y_s 相互独立.相互独立的正态随机变量的线性组合服从正态分布,故 $\varepsilon = Z - (\beta_0 + \beta_1 Y_1 + \beta_2 Y_2 + \dots + \beta_s Y_s)$ 服从正态分布, ε 服从 $N\left(\mu_{s+1} - \beta_0 - \sum_{k=1}^s \beta_k \mu_k, \frac{\left(\sum_{k=1}^{s+1} \beta_k^2 \sigma_k^2\right)}{n}\right), \sigma^2 = \frac{\left(\sum_{k=1}^{s+1} \beta_k^2 \sigma_k^2\right)}{n}, \beta_{s+1} = 1, \mu = \mu_{s+1} - \beta_0 - \sum_{k=1}^s \beta_k \mu_k, \varepsilon$ 服从 $N(\mu, \sigma^2)$. □

构造随机变量 $\varepsilon' = \varepsilon - \mu$, 由于正态随机变量的线性组合仍然服从正态分布,故 ε' 仍然服从正态分布且由定理 3 可知 $E(\varepsilon') = E(\varepsilon - \mu) = 0, D(\varepsilon') = \sigma^2$, 于是 $Z = (\mu + \beta_0) + \beta_0 + \beta_1 Y_1 + \beta_2 Y_2 + \dots + \beta_s Y_s + \varepsilon'$. 由于 $\mu + \beta_0$ 仍然是常数,因此不失一般性, Z 仍可以写成 $Z = \beta_0 + \beta_0 + \beta_1 Y_1 + \beta_2 Y_2 + \dots + \beta_s Y_s + \varepsilon$, 其中 ε 是不可观测的随机误差,且满足 ε 服从 $N(0, \sigma^2), E(\varepsilon) = 0, D(\varepsilon) = \sigma^2$. 设有 m 组独立的观察值,记为 $(z_i, y_{i1}, y_{i2}, \dots, y_{is}), i = 1, 2, \dots, m$, 则有如下方程:

$$\begin{cases} z_i = \beta_0 + \beta_1 y_{i1} + \dots + \beta_s y_{is} + \varepsilon_i \\ E(\varepsilon_i) = 0, D(\varepsilon_i) = \sigma^2, i = 1, 2, \dots, m \end{cases} \tag{1}$$

其中 $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_m$ 相互独立且服从 $N(0, \sigma^2)$. 式(1)的矩阵形式为

$$\tilde{Z} = \tilde{Y} \tilde{\beta} + \tilde{\varepsilon}, \text{ 其中 } \tilde{Z} = \begin{pmatrix} z_1 \\ z_2 \\ \vdots \\ z_m \end{pmatrix}, \tilde{Y} = \begin{pmatrix} 1 & y_{11} & y_{12} & y_{1s} \\ 1 & y_{21} & y_{22} & y_{2s} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & y_{m1} & y_{m2} & y_{ms} \end{pmatrix}_{m \times (s+1)}, \tilde{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_s \end{pmatrix}, \tilde{\varepsilon} = \begin{pmatrix} \varepsilon_0 \\ \varepsilon_1 \\ \vdots \\ \varepsilon_m \end{pmatrix},$$

其中 $m-s \geq 2$. 式(1)称为计算 AVG 预测聚集查询的预测方程. m, s 和样本数 n 称为预测方程的参数. Z 的预测误差平方和为 $Q(\tilde{\beta}) = \sum_{i=1}^m (z_i - \sum_{j=0}^s y_{ij} \beta_j)^2 = (\tilde{Z} - \tilde{Y} \tilde{\beta})^T (\tilde{Z} - \tilde{Y} \tilde{\beta})$, 其中 $y_{i0} = 1, i = 1, 2, \dots, m$. 利用最小二乘法求得 $\hat{\beta} = (\tilde{Y}^T \tilde{Y})^{-1} (\tilde{Y}^T \tilde{Z})$, 满足 $Q(\hat{\beta}) = \min_{\tilde{\beta}} Q(\tilde{\beta})$.

2.1.2 预测模型的显著性检验及预测误差

现在需要根据实际数据检验 Z 和 Y_1, Y_2, \dots, Y_s 是否有线性关系. 如果 Z 和 Y_1, Y_2, \dots, Y_s 有线性关系, 则 $\beta_1, \beta_2, \dots, \beta_s$ 不全为 0, 否则 $\beta_1, \beta_2, \dots, \beta_s$ 全为 0. 考虑两个统计量: $Q_e = \sum_{i=1}^m (z_i - \hat{z}_i)^2$ 和 $U = \sum_{i=1}^m (\hat{z}_i - \bar{z})^2$, 其中 \hat{z}_i 是 z_i 的预测值, $\bar{z} = \frac{1}{m} \sum_{i=1}^m z_i$. 统计量 $F = \frac{(U/\sigma^2)/s}{(Q_e/\sigma^2)/(m-s-1)} = \frac{U/s}{Q_e/(m-s-1)}$ 服从 $F(s, m-s-1)$. 给定显著水平 σ , 由概率论知可以

计算出 $F(s, m-s-1)$ 的分位点 $F_{1-\alpha}(s, m-s-1)$. 若 $F > F_{1-\alpha}(s, m-s-1)$, 则本文提出的预测模型成立^[14]. 若 Z 与 \hat{Z} 的绝对误差满足 $P\{|Z - \hat{Z}| \leq B_\alpha\} = 1 - \sigma$, 则认为预测成功. 由定理 1, 2 可知 Z 与 \hat{Z} 的分布, 用多元统计知识可以计算出^[14] $B_\alpha = t_{1-\alpha/2}(m-s-1) \sqrt{\frac{Q_e}{(m-s-1)}}$. Z 的置信水平为 $1 - \sigma$ 的置信区间为 $[\hat{Z} - B_\alpha \hat{Z}, \hat{Z} + B_\alpha \hat{Z}]$.

2.2 预测聚集查询处理算法

我们首先讨论宽度为 1 个 Δt 的未来数据窗口上的 AVG 聚集预测算法 $P_SmallWin$. 该算法分为 4 个阶段:

第 1 阶段. 用数据缓冲区和滑动窗口中的数据, 建立线性回归方程 $\tilde{Z} = \tilde{Y} \tilde{\beta} + \tilde{\varepsilon}$, 这里, \tilde{Y} 为 s 个缓冲区内的样本数据组成的矩阵, \tilde{Z} 为滑动窗口中的样本数据组成的 $m \times 1$ 矩阵. 计算 $\tilde{\beta}$ 的估计值 $\hat{\beta} = (Y^T Y)^{-1} (Y^T Z)$.

第 2 阶段.计算预测的绝对误差.用户给定显著水平 α ,计算绝对误差 B_α .

第 3 阶段.计算预测平均值.回归方程 $\hat{Z} = \hat{\beta}_0 + \hat{\beta}_1 Y_1 + \dots + \hat{\beta}_s Y_s$ 的系数 $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_s$ 已知.从前 s 个缓冲区中采样得到的样本值 $(y_{i1}, y_{i2}, \dots, y_{is})$,则预测平均值 $\hat{z}_i = \hat{\beta}_0 + \hat{\beta}_1 y_{i1} + \hat{\beta}_2 y_{i2} + \dots + \hat{\beta}_s y_{is}$.

第 4 阶段.判断预测是否成功.当新数据到达滑动窗口中时,计算真实平均值 z_i .若 $|z_i - \hat{z}_i| \leq B_\alpha$,则预测成功,否则预测失败.当预测失败的次数的累加值超过一个阈值时,则进行调整.第 2.3 节讨论了调整策略.

上述算法的第 1 阶段,计算 $\hat{\beta}$ 的复杂度为 $O(s^2 \times \max(s, m))$;第 2 阶段,计算统计量 F 的复杂度为 $O(m+s)$;第 3 阶段,计算预测值的复杂度为 $O(m \times s)$;第 4 阶段的复杂度为 $O(s^2 \times \max(s, m)) = O(s^2 \times m)$.总开销为 $O(s^2 \times m)$.如果 s 和 m 满足 $\xi \times s^2 \times m \leq \Delta t$,则可以在数据到达之前完成预测,其中 ξ 是计算机执行一个乘法的运算时间.

下边讨论带有 AVG 的预测聚集查询处理算法.考虑查询 Q_{avg} : SELECT AVG(R1.attr) FROM R1 WHERE \mathcal{E} BEGIN NOW END NOW+ μ .设 $p = \mu / \Delta t$,未来数据窗口包含 p 个长度为 Δt 的小窗口. Q_{avg} 的预测算法如下:

Procedure $P_AVG(QID, \mu, \Delta t, Pcount[1..p], Paverage[1..p])$

Input: QID : Q_{avg} 的查询 ID; μ : 当前到未来时刻的时间长度; Δt : 滑动窗口的更新周期;

Output: 1) 预测聚集查询的返回值

- 2) $Pcount[1..p]$: 保存预测未来的 p 个时间间隔内的元组数目.
- 3) $Paverage[1..p]$: 保存预测未来的 p 个时间间隔内的均值.

(1) $count \leftarrow P_COUNT(QID, \mu, \Delta t, Pcount[1..p]);$

(2) $sum \leftarrow 0$

(3) FOR $i=1$ TO p

(a) $Paverage[i] \leftarrow$ 调用 $P_SmallWin$, 计算未来第 i 个时间间隔内的均值.

(b) $sum \leftarrow sum + Pcount[i] \times Paverage[i]$

(4) ENDFOR

(5) 返回 $sum/count$;

算法中的 $P_COUNT^{[13]}$ 计算未来 p 个 Δt 时间内滑动窗口中的数据个数.预测算法执行之前,预测方程的回归系数已经计算好了,保存在 QSS 结构内.算法第(1)步的时间开销为 $O(p \times \log k)$, k 是计数预测表中区间的个数^[13].第(3)步的(a)需要 $O(s)$ 步加法和乘法,(b)的时间复杂度为 $O(1)$.因此,第(3)步的开销为 $O(p \times s)$.算法的时间复杂度为 $O(p \times (s + \log k))$.带有 SUM 的预测聚集查询处理算法与 P_AVG 类似,简记为 P_SUM ,本文不再介绍.

在建立预测方程 $\tilde{Z} = \tilde{Y} \tilde{\beta} + \tilde{\varepsilon}$ 时,计算 \tilde{Y} 的第 i 列的每个元素时需要总体 X_k 的容量为 n 的样本.计算 \tilde{Y} 的第 i 列的 m 个元素,则至少需要容量为 $m \times n$ 的样本.设 τ 为数据流的平均流速,则有 $m \times n \leq \tau \times \Delta t$.由第 2.1 节式(1)可知 $m - s \geq 2, m, s$ 和 n 满足如下联立方程组:

$$\begin{cases} \xi \times s^2 \times m \leq \Delta t \\ m \times n \leq \tau \times \Delta t \\ m - s \geq 2 \end{cases} \quad (2)$$

2.3 预测算法的自调整策略

当预测失败的次数累积超过一个阈值时,预测方程就需要调整.

策略 1.当新的数据到达后,覆盖最老的缓冲区中的数据.利用当前新的 $s+1$ 个时间间隔内的样本重新构造 \tilde{Z} 和 \tilde{Y} ,重新计算 $\hat{\beta}$ 取代旧的 $\hat{\beta}$.

策略 2.从所有对 Z 影响小的随机变量 Y_k 中剔除对 Z 影响最小的一个随机变量,建立剔除随机变量 Y_k 后的新的预测方程.不断重复这一过程,直到预测方程中所包含的随机变量都对 Z 有一定影响,这样同时也降低了预测方程的阶.

3 实验

我们使用 VC++ 和 Linux 环境下的 GNU C 实现了预测聚集查询处理算法 P_AVG 和 P_SUM .实验设备包括

两台计算机,一台是运行 Win2000 Server,具有 PIII866 处理器、128M 内存的 PC,它用来发送数据流.另一台是运行 Linux6.2,具有 PIII866 处理器、1G 内存的服务器,它接收数据流并执行预测聚集查询.表 1 列出了两种数据流,其中数据流 2 是 1996 年~2004 年 TAO^[15]浮标阵列测量的海洋表面空气真实温度.

本文的预测误差包括预测聚集查询的平均相对误差和平均绝对误差.假设在第 i 次查询实验中预测聚集值为 \hat{f}_i ,真实的聚集值为 f_i ,则 w 次预测聚集查询实验后的平均相对误差 MRD(mean relative deviation)为

$$\sum_{i=1}^w \frac{|f_i - \hat{f}_i|}{wf_i} .w \text{ 次预测聚集查询实验后的平均绝对误差 MAD(mean absolute deviation)为 } \sum_{i=1}^w \frac{|f_i - \hat{f}_i|}{w} .$$

Table 1 Data sets used in the experiment

表 1 实验数据

Data stream	Capacity	Description
1	450×10000	Tpc-h ^[16] :BENCHMARK H (Decision support) standard specification
2	18×10000	1996~2004 Ocean air temperature data from TAO

滑动窗口的更新周期 Δt ,平均流速 τ 以及未来数据窗口的宽度是影响本文预测算法准确度的 3 个重要因素.实验的主要目的是:(1) 考察滑动窗口的更新周期 Δt 对预测误差的影响;(2) 考察预测算法的成功率;(3) 考察数据流的流速 τ 对预测误差的影响;(4) 考察未来数据窗口的宽度对预测误差的影响;(5) 预测模型的适用情况.

(1) 考察滑动窗口更新周期 Δt 的大小对预测误差的影响.实验时多次测试数据流的流速,然后取均值作为数据流的平均流速.我们把数据流的平均流速控制在 467 个元组/秒.给定滑动窗口的更新周期 Δt 及数据流的平均流速 τ ,可由第 2.2 节中的式(2)确定 m, n 和 s .表 2 是 τ 为 467 个元组/秒的情况下, Δt 与 m, s 和 n 的对应关系.表 2 中不同的 $(\Delta t, m, s, n)$ 将对预测误差产生不同的影响, Δt 的单位是 ms.

Table 2 Mapping between Δt and m, s, n when τ is 467 tuples/second

表 2 数据流的平均流速为 467 个元组/秒时, Δt 与 m, s 和 n 的对应关系

Δt	m	s	n	Δt	m	s	n	Δt	m	s	n	Δt	m	s	n
80	6	2	10	840	21	7	35	2000	33	11	55	3670	45	15	75
290	12	4	20	1000	24	8	40	2370	36	12	60	4160	48	16	80
620	18	6	30	1660	30	10	50	3200	42	14	70	4690	51	17	85

图 4 所用的数据是表 1 中的数据流 1,显示了不同的滑动窗口更新周期 Δt 对平均相对误差之间的影响.平均相对误差随着 Δt 的增大而降低,但当 Δt 增大到一定程度时(当超过 2370ms 时),平均相对误差又有了增加的趋势.原因是,当 Δt 增大时,滑动窗口内将接纳更多的元组,样本数 n 增大,定理 1 易成立.当 Δt 增大到一定程度时,由表 2 可知, m, s 和 n 也增大. s 增得过大,使得前 s 个滑动窗口中的数据与第 $s+1$ 个滑动窗口内的数据的线性性质难以保持,因此平均相对误差又有了增加的趋势.




Fig.4 Effect of Δt on MRD based on stream 1
图 4 采用数据流 1 时 Δt 对相对误差的影响




Fig.5 Effect of Δt on MAD of AVG based on stream 1
图 5 采用数据流 1 时 Δt 对 AVG 的绝对误差的影响

图 5 和图 6 所用的数据是表 1 中的数据流 1.图 5 显示了 Δt 与 P_AVG 的平均绝对误差的关系. P_AVG 的平均绝对误差随着 Δt 的增大而降低,但当 Δt 增大到一定程度时其绝对误差又有增加的趋势,原因同上.图 6 显示了 Δt 与 P_SUM 的平均绝对误差之间的关系.当 Δt 增大时,其绝对误差也增大.当 Δt 增大到一定程度时,绝对误差陡然增加.误差增加的原因是,当 Δt 增大时, P_AVG 与 P_COUNT ^[13] 的绝对误差都增加,而 P_SUM 的计算又依赖于二者,因此误差增加.以上事实说明,滑动窗口的更新周期 Δt 是影响预测误差的主要因素.如果 Δt 增加,将使 P_SUM 平均绝对误差增加;如果 Δt 降低,将使 P_AVG 和 P_SUM 的平均相对误差增加.当用户给定一个误差上界

η 时,找到适当的 m, s 使 $B_{\sigma} = t_{1-\alpha/2}(m-s-1) \sqrt{\frac{Q_e}{(m-s-1)}} \leq \eta$,把得到的 m, s 代入第 2.2 节的式(2),可以计算出一个能够满足误差的滑动窗口的更新周期 Δt .




Fig.6 Effect of Δt on MAD of SUM based on stream 1

图 6 采用数据流 1 时 Δt 对 SUM 的绝对误差的影响




Fig.7 Effect of Δt on PSR based on stream 1

图 7 采用数据流 1 时 Δt 对预测成功率的影响

(2) 考察预测算法的成功率. 设 \hat{f} 是用预测算法产生的预测值, f 是真实值. η 是用户事先给定的误差容忍度. 如果 $\frac{|\hat{f}-f|}{f} \leq \eta$, 则认为预测成功, 否则认为预测失败. 在本文的实验中, η 取 5%. 预测成功的次数与总预测次数的比值定义为预测算法的成功率 PSR(prediction success ratio). 图 7 显示了滑动窗口更新周期与预测成功率之间的关系. 当 Δt 为 2 370ms 时 AVG 及 SUM 的准确率最大, 分别为 88.37%和 80.23%.

(3) 考察数据流的流速 τ 的大小对预测误差的影响. 实验中我们把数据流的平均流速 τ 分别控制在 5 个流速上, 它们分别为 467 个元组/秒, 579 个元组/秒, 682 个元组/秒, 941 个元组/秒和 1198 个元组/秒. 图 8 给出了 τ 与相对误差的关系, 当数据流流速增大时, 平均相对误差将增大. 原因是: 当数据流流速增大时, 滑动窗口会很快地被数据填满, 新到达的数据将不能进入滑动窗口. 因此很可能要丢失一些数据. 系统为了更快地处理数据, 滑动窗口的更新周期 Δt 要减小. 由表 2 可知, m, s 和 n 也将减少, 由图 11 知数据流 1 的线性性质不易保持, 很难建立起较好的预测方程. 因此当数据流流速增大时平均相对误差将增大. 基于同样的原因, 当数据流的流速增大时, 预测成功率将降低. 图 9 显示了数据流的流速与预测成功率之间的关系.




Fig.8 Effect of stream rate on MRD based on stream 1

图 8 数据流的流速对平均相对误差的影响




Fig.9 Effect of stream rate on PSR based on stream 1

图 9 数据流的流速对预测成功率的影响

(4) 考察未来数据窗口的宽度对预测聚集查询的预测误差的影响. 未来数据窗口的长度 $\mu = p \times \Delta t$, 图 10 显示了当数据流平均流速为 467 个元组/毫秒且 Δt 等于 2 370ms 时, p 与平均相对误差的关系. 通过观察我们发现, 当 p 增大时, 未来数据窗口的长度增大, 平均相对误差在增大. 原因在于, 算法中用预测出来的数据再去预测更远的的数据, 经过多步预测后累积误差将会增大.




Fig.10 Effect of width of future data window on MRD based on stream 1

图 10 未来数据窗口的宽度 p 对平均相对误差的影响

(5) 考察预测模型的适用情况.由于数据流中的数据是变化的,因此实验中每经过一个滑动窗口的更新周期 Δt ,就进行一次线性关系的检验.计算 F 统计量以及 $F(s,m-s-1)$ 的分位点 $F_{1-\sigma}(s,m-s-1)$, σ 是预先给定的显著水平.若 $F > F_{1-\sigma}(s,m-s-1)$,则认为系统当前数据缓冲区中的数据满足线性关系.满足线性关系的次数与检验的总次数比值称为线性显著率 LPR(linear prominence ratio).图 11 给出了在不同的 s 下,两种数据流显著率的变化情况.从图 11 可以看出,数据流 2 的显著率高于数据流 1.数据流 2 中的数据更加符合线性关系.图 12 采用的数据是数据流 2,显示了不同的滑动窗口更新周期 Δt 与预测聚集查询的平均相对误差之间的关系.尽管相对误差随着滑动窗口更新周期的增大而增大,但相对误差始终稳定在 10%以内,而图 4 采用的数据是数据流 1,相对误差最高达到 30%.因此,本文的预测模型更适合具有线性关系的数据流.




Fig. 11 Effect of number of data buffers on LPR

图 11 数据缓冲区的数目对线性显著率的影响




Fig. 12 Effect of Δt on MRD based on stream 2

图 12 采用数据流 2 时 Δt 对相对误差的影响

4 总 结

本文采用多元线性回归技术提出了 AVG 和 SUM 的预测聚集查询的处理算法,并且能够返回满足用户精度要求的查询结果.理论分析和实验结果表明,本文提出的算法具有很高的性能和精度,预测模型更适合具有线性关系的数据流.我们将继续考虑下列问题:(1) 如果数据不满足线性关系,考虑更好的预测方法;(2) 考虑带有连接操作的多数据流情况;(3) 考虑 MIN 和 MAX 的预测聚集查询处理算法.

References:

- [1] The STREAM Group. STREAM: The stanford stream data manager. IEEE Data Engineering Bulletin, 2003,26(1):19-26.
- [2] Daniel JA, Don C, Ugur C, Mitch C, Christian C, Sangdon L, Michael S, Nestime T, Stan Z. Aurora: A new model and architecture for data stream management. The Int'l Journal on Very Large Data Bases, 2003,12(2):120-139.
- [3] Sirish C, Owen C, Amol D, Michael JF, Joseph MH, Wei H, Sailesh K, Samuel RM, Fred R, Mehul AS. TelegraphCQ: Continuous dataflow processing. In: Alon YH, ed. Proc. of the 2003 ACM SIGMOD Int'l Conf. on Management of Data. New York: ACM Press, 2003. 668-668.
- [4] Shivanath B, Jennifer W. Continuous queries over data streams. SIGMOD Record, 2001,30(3):109-120.
- [5] Brian B, Shivanath B, Mayur D, Rajeev M, Jennifer W. Model and Issues in data stream systems. In: Michael JF, ed. Proc. of the 2002 ACM SIGMOD Int'l Conf. on Management of Data. New York: ACM Press, 2002. 1-16.
- [6] Sirish C, Franklin MJ. Streaming queries over streaming data. In: Bernstein PA, Ioannidis YE, Ramakrishnan R, eds. Proc. of the 28th Int'l Conf. on Very Large Data Bases. Hong Kong SAR: Morgan Kaufmann Publishers, 2002. 203-214.
- [7] Anna CG, Yannis K, Muthukrishnan S, Martin JS. Surfing wavelets on streams: One-Pass summaries for approximate aggregate queries. In: Peter MGA, ed. Proc. of the 27th Int'l Conf. on Very Large Data Bases. San Fransisco: Morgan Kaufmann Publishers, 2001. 79-88.
- [8] Alin D, Minos G, Johannes G, Rajeev R. Processing complex aggregate queries over data streams. In: Michael JF, ed. Proc. of the 2002 ACM SIGMOD Int'l Conf. on Management of Data. New York: ACM Press, 2002. 61-72.
- [9] Johannes G, Flip K, Divesh S. On computing correlated aggregates over continual data streams. In: Walid GA, ed. Proc. of the 2001 ACM SIGMOD Int'l Conf. on Management of Data. New York: ACM Press, 2001. 13-24.
- [10] Rohit A, Abhinandan D, Johannes G. Efficient approximation of correlated sums on data streams. IEEE Trans. on Knowledge and Data Engineering, 2003,15(3):569-572.

- [11] Zhang DD, Li JZ, Wang WP, Guo LJ. Algorithms for aggregating history of time-series data streams. *Computer Science*, 2003, 30(10):291-295 (in Chinese with English abstract).
- [12] Brain B, Mayur D, Rajeev M. Sampling from a moving window over streaming data. In: David E, ed. *Proc. of the 2002 Annual ACM-SIAM Symp. on Discrete Algorithms*. New York: ACM Press, 2002. 633-634.
- [13] Guo LJ, Li JZ, Wang WP, Zhang DD. Predictive continuous aggregate queries over data streams. *Journal of Computer Research and Development*, 2004,41(10):1690-1695 (in Chinese with English abstract).
- [14] Wu Y, Li YL, Hu QJ. *Statistics and Application*. 5th ed., Changsha: National University of Defense Technology Publisher, 2003. 161-196 (in Chinese).
- [15] Pacific Marine Environmental Laboratory. Tropical atmosphere ocean project. 2005. <http://www.pmel.noaa.gov/tao>
- [16] Transaction Processing Performance Council. TPC BENCHMARK H (Decision support) standard specification. 2005. <http://www.tpc.org/tpch/default.asp>

附中文参考文献:

- [11] 张冬冬,李建中,王伟平,郭龙江.时间序列数据流上历史数据的聚集算法. *计算机科学*,2003,30(10):291-295.
- [13] 郭龙江,李建中,王伟平,张冬冬.数据流上的连续预测聚集查询. *计算机研究与发展*,2004,41(10):1690-1695.
- [14] 吴翊,李永乐,胡庆军. *应用数理统计*.第5版,长沙:国防科技大学出版社,2003.161-196.

《中国计算机学会通讯》杂志创刊

近日,由中国科学院院士张效祥题写刊名的《中国计算机学会通讯》正式出版。这本杂志由中国计算机学会主办,高等教育出版社出版,面向计算机专业人士及信息领域的相关人士。杂志利用中国计算机学会的学术优势,组织信息技术各个领域最有影响的专家撰稿,全面介绍计算机科学技术发展的最新趋势,并预测未来一段的技术发展趋势,具有权威性和指导性,可以帮助读者更加开阔视野,了解IT最前沿的动态,把握IT发展方向,适合与计算机相关的科研、教学,以及产业和管理等各方面的人士阅读。

《中国计算机学会通讯》2005年为季刊,2006年为双月刊,2007年为月刊。杂志每期100页,开本200×273,全彩色铜版精美印刷。

杂志主编是中国计算机学会理事长、中国科学院计算技术研究所所长、中国工程院院士李国杰研究员;执行总编是中国计算机学会理事冀复生先生,有多名国内知名专家是该杂志的编委。目前,杂志的主要栏目有专题报道(封面故事)、展望、观点、会员园地等。其中专题报道就计算机科学的某一领域进行全面、深入的综合报道,使读者对于该领域有一个权威和整体的了解;展望报道计算机界的发展趋势的综述文章;观点就计算机技术和业界发展发表业界专家的独到见解;会员园地包括学会动态、学会和有关会议等活动的预报、职场信息、新书架等。杂志还将翻译《Communications of ACM》、《IEEE Computer》和《IEEE Spectrum》等外刊的优秀文章。

正如李国杰主编所指出的,我国目前已经有很大计算机类的学术刊物,但是关心这些刊物的主要是文章的作者,而《中国计算机学会通讯》作为学术与技术应用相结合的学术性会刊,其目的主要不是为研究室和科研人员提供一个新的发表文章的载体,而是让计算机科技工作者和关心计算机发展的各类人士更全面、更深刻地了解相关技术的发展趋势。因此,杂志将努力通过介绍和探讨IT领域的最新技术、观点和理论,传播IT技术的新知识和新进展,加强IT界的学术、技术与应用交流,促进IT领域科研、生产、教学和市场之间的密切结合,发掘和培养IT技术人才,促进国内IT技术水平的提高和IT产业的发展,促进IT和其他领域的交流。

《中国计算机学会通讯》杂志免费赠送学会会员(学生会员除外)(不零售),这是中国计算机学会本届理事会为加强会员服务的重要举措。

杂志编辑部欢迎专家、读者、会员踊跃投稿。相信本杂志将成为信息技术领域的一份重要学术刊物。

