
Non-Standard-Datenbanken und Data Mining

Stromdatenbanken

Prof. Dr. Ralf Möller


Universität zu Lübeck

Institut für Informationssysteme

Übersicht

- Semistrukturierte Datenbanken (JSON, XML) und Volltextsuche
- Information Retrieval
- Mehrdimensionale Indexstrukturen
- Cluster-Bildung
- Einbettungstechniken
- First-n-, Top-k-, und Skyline-Anfragen
- Probabilistische Datenbanken, Anfragebeantwortung, Top-k-Anfragen und Open-World-Annahme
- Probabilistische Modellierung, Bayes-Netze, Anfragebeantwortungsalgorithmen, Lernverfahren,
- Temporale Datenbanken und das relationale Modell, SQL:2011
- Probabilistische Temporale Datenbanken
- SQL: neue Entwicklungen (z.B. JSON-Strukturen und Arrays), Zeitreihen (z.B. TimeScaleDB)
- **Stromdatenbanken, Prinzipien der Fenster-orientierten inkrementellen Verarbeitung**
- Approximationstechniken für Stromdatenverarbeitung, Stream-Mining
- Probabilistische raum-zeitliche Datenbanken und Stromdatenverarbeitungssysteme: Anfragen und Indexstrukturen, Raum-zeitliches Data Mining, Probabilistische Skylines
- Von NoSQL- zu NewSQL-Datenbanken, CAP-Theorem, Blockchain-Datenbanken

Motivation: Telefondatenauswertung



Anfrage 1 (**SELF-JOIN**)

- Find all **outgoing calls** longer than **2 minutes**

```
SELECT O1.call_ID, O1.caller
FROM   Outgoing O1, Outgoing O2
WHERE  (O2.time - O1.time > 2
        AND O1.call_ID = O2.call_ID
        AND O1.event = START
        AND O2.event = END)
```

- Ergebnis wächst **ohne Begrenzung**
- Ergebnis **als Datenstrom** bereitstellbar
 - **Transaktionszeit** vergeben, wenn Ausgabe bekannt
- Frühestmögliche Ergebnisbereitstellung:
Für Einzelverbindung steht Ergebnis nach 2 min fest,
auch ohne END

Anfrage 2 (**JOIN**)

- Pair up **callers** and **callees**

```
SELECT O.caller, I.callee  
FROM   Outgoing O, Incoming I  
WHERE  O.call_ID = I.call_ID
```

- **Ergebnis** kann als **Datenstrom** bereitgestellt werden
- **Unbegrenzter temporärer Speicher** notwendig ...
- ... wenn Ströme **nicht quasi-synchronisiert** sind
 - Valid-Time-Information kann helfen,
Temporärspeicher zu begrenzen


Anfrage 3 (Gruppierung und Aggregation)

- Total connection time for each caller

```
SELECT      O1.caller, sum(O2.time – O1.time)
FROM        Outgoing O1, Outgoing O2
WHERE       (O1.call_ID = O2.call_ID
            AND O1.event = START
            AND O2.event = END)
GROUP BY    O1.caller
```


- Ergebnis kann nicht als Strom (ohne Überschreibung) dargestellt werden
 - Ausgabeaktualisierung? ValidTime-Information nötig!
 - Aktueller Wert auf Anforderung?
 - Speicherverbrauch?

Data Stream Management System



Beispiel: Sensordatenauswertung

- Problem
Finde Ähnlichkeiten zwischen Messungen zweier Temperatursensoren
- Lösung
Bestimme **Pearson-Korrelationskoeffizient** oder **Cosinus-Distanz** zwischen zwei Messungen, in einem Zeitfenster



Fensterkonzept

Kein Einfluss von “alten” Daten auf Ergebnis

➔ Verschiebbare Fenster

- Endliche Teilsequenzen eines unendlichen Stroms
- Anfragebeantwortung auf neueste Daten fokussiert
- Wichtig für **ausdrucksstarke Anfragen** und deren **effiziente Verarbeitung**

• 2 Alternativen

- **Zählerbasierte** Fenster (siehe auch SQL:2011)
 - FIFO-Schlange der Größe w
- **Zeitbasierte** Fenster
 - t Zeitpunktfenster $[t, t]$ oder Intervallfenster $[0, t]$
 - $[t - w, t]$ Anfang und Ende der Gültigkeit (Intervallfenster)

Analytische Funktionen in SQL 2011

```
SQL> select * from currency order by 1;
```

DAY	EURCHF
01-JUN-2012 00:00:00	1.240
02-JUN-2012 00:00:00	1.223
03-JUN-2012 00:00:00	1.228
04-JUN-2012 00:00:00	1.217
05-JUN-2012 00:00:00	1.255
06-JUN-2012 00:00:00	1.289
07-JUN-2012 00:00:00	1.291
08-JUN-2012 00:00:00	1.247
09-JUN-2012 00:00:00	1.217
10-JUN-2012 00:00:00	1.265

```
SQL> select day, EURCHF, lag(EURCHF,1) over  
(order by day) as prev_eurchf from currency;
```

DAY	EURCHF	PREV_EURCHF
01-JUN-2012 00:00:00	1.240	
02-JUN-2012 00:00:00	1.223	1.240
03-JUN-2012 00:00:00	1.228	1.223
04-JUN-2012 00:00:00	1.217	1.228
05-JUN-2012 00:00:00	1.255	1.217
06-JUN-2012 00:00:00	1.289	1.255
07-JUN-2012 00:00:00	1.291	1.289
08-JUN-2012 00:00:00	1.247	1.291
09-JUN-2012 00:00:00	1.217	1.247
10-JUN-2012 00:00:00	1.265	1.217

SQL 2011: Historische Daten

Datenströme


- Datenelemente treffen in Realzeit im DSMS ein
 - Vergabe von Transaktionszeitwerten durch DSMS bei „Eintreffen“ eines Datenobjekts
- Probleme auf Datenströmen
 - Sampling
 - Kontinuierliche Anfragebeantwortung
 - Filterung
 - Zählen bestimmter Elemente
 - Schätzen von Momenten
 - Finden von häufig vorkommenden Elementen
 - Ggf. muss Gültigkeitsinformation an Ergebnisse angeheftet werden (meist implizit bis zum Eintreffen neuer Info)
 - Ggf. Kombination mit Zugriff auf statische Daten
 - Fenster, das immer größer wird

Abgeschlossenheit

- Kontinuierliche Anfragen produzieren Ströme
 - Evtl. Gültigkeits- und/oder Wahrscheinlichkeitsinformation beifügen
 - Wahrscheinlichkeitswerte können zeitabhängig sein!
 - Zur Anwendung geleitet (push)
 - Anwendung muss abnahmebereit sein (ggf. Timeouts)
 - Von Anwendung abgeholt (pull)
 - Temporärer Speicher nötig (ggf. mit Dropout bei Gültigkeitsende)
- Eingabe für weitere kontinuierliche Anfragen
 - Kaskadierung

Non-Standard-Datenbanken

Von temporalen Datenbanken zu Stromdatenbanken



STREAM: Stanford Stream Data Manager

- DSMS für Ströme und statische Daten
- Zeitstempel implizit vergeben (Systemzeit)
- Relationale Modellierung ergänzt um Stromkonzept
- Zentralisiertes Servermodell
- CQL: Deklarative Sprache für registrierte kontinuierliche Anfragen über Strömen und statischen Relationen

Konkrete Sprache – CQL

- Relationale Anfragesprache: SQL
- Fensterspezifikationssprache von SQL:2011
 - Tupelbasierte Fenster
 - Zeitbasierte Fenster
 - Partitionierende Fenster
- Einfaches Stichproben-Konstrukt “X% Sample”

CQL Beispielanfrage 1

- Zwei Ströme, sehr einfaches Schema für Beispielszwecke:
Orders (orderID, customer, cost)
Fulfillments (orderID, clerk)
- Informationsbedarf natürlichsprachlich ausgedrückt:
Total cost of orders fulfilled over the last day by clerk
“Sue” for customer “Joe”
- Anfrage in CQL:
Select Sum(O.cost)
From Orders O[∞], Fulfillments F[Range 1 Day]
Where O.orderID = F.orderID And F.clerk = “Sue”
And O.customer = “Joe”

CQL Beispielanfrage 2

Using a 10% sample of the Fulfillments stream, take the 5 most recent fulfillments for each clerk and return the maximum cost

Select F.clerk, Max(O.cost)

From Orders O[∞],

Fulfillments F[**Partition By clerk Rows 5**] **10% Sample**

Where O.orderID = F.orderID


Group By F.clerk

Relationen und Ströme

- Annahme
 - Globale, diskrete, geordnete Menge von Zeitpunkten
- Relation
 - Bildet *Zeitpunkte* T auf *Tupelmengen* R ab
- Strom
 - Menge von *(Tupel, Zeitstempel)*-Elementen
 - Definition mit `create stream s as select ...`
 - ... wobei wir `s: select ...` zur Abkürzung verwenden
- Anfragen werden beim DSMS registriert
("kontinuierliche" Anfragen)

Konversion

Fensterspezifikation



Spezielle Operatoren:
Istream, Dstream, Rstream

Jede relationale
Anfragesprache

Konversion – Definitionen

- **Strom-zu-Relation-Operator** $S[\dots]$
 - $S[W]$ ist eine Relation — zum Zeitpunkt T sind alle Tupel im Fenster W , angewendet auf den Strom S bis zum Zeitpunkt T , enthalten
 - Wenn $W = \infty$, sind all Tupel aus S bis zu T enthalten
 - W definiert sowohl **Zeitintervall** oder **Anzahl Tupel** (NOW=Rows 1) als auch **Verschiebung** (Slide)
 - *Standard-Fenster: $[\infty]$*
 - *Standard-Slide: eine Einheit*
- **Relation-zu-Strom-Operatoren**
 - $Istream(R)$ enthält alle (r, T) wobei $r \in R$ zum Zeitpunkt T aber $r \notin R$ zum Zeitpunkt $T-1$
 - $Dstream(R)$ enthält alle (r, T) wobei $r \in R$ zum Zeitpunkt $T-1$ aber $r \notin R$ zum Zeitpunkt T
 - $Rstream(R)$ enthält alle (r, T) wobei $r \in R$ zum Zeitpunkt T

Präzisierung – Multimengensemantik

- Multimenge: Elemente sind Tupel (x, k) , wobei $k > 0$ einen Zähler darstellt,
- $Istream(R) := \{ (x, m-n) \mid$
 $(x, m) \in R$ zum Zeitpunkt T ,
 $(x, n) \in R$ zum Zeitpunkt $T-1$,
 $m-n > 0 \}$
 $\cup$
 $\{ (x, m) \mid$
 $(x, m) \in R$ zum Zeitpunkt T ,
 $(x, n) \notin R$ zum Zeitpunkt $T-1 \}$

Abstrakte Semantik – Beispiel 1

```
Select F.clerk, Max(O.cost)
From O [ $\infty$ ], F [Rows 1000]
Where O.orderID = F.orderID
Group By F.clerk
```

Maximum-cost order fulfilled by each clerk in last 1000 fulfillments

Abstrakte Semantik – Beispiel 1

Select F.clerk, Max(O.cost)
From O [∞], F [Rows 1000]
Where O.orderID = F.orderID
Group By F.clerk

- Zum Zeitpunkt T : Ganzer Strom O und die letzten 1000 Tupel von F als Relation
- Evaluiere Anfrage, aktualisiere Ergebnisrelation zum Zeitpunkt T

Abstrakte Semantik – Beispiel 1

```
Select Istream(F.clerk, Max(O.cost))  
From O [ $\infty$ ], F [Rows 1000]  
Where O.orderID = F.orderID  
Group By F.clerk
```



Istream wird
standardmäßig
angenommen

- Zum Zeitpunkt T : Ganzer Strom O und die letzten 1000 Tupel von F als Relation
- Evaluiere Anfrage, aktualisiere Ergebnisrelation zum Zeitpunkt T
- **Streamed result:** Neues Element $(\text{<clerk,max>}, T)$ wenn <clerk,max> sich bezogen auf $T-1$ ändert

Abstrakte Semantik – Beispiel 2

Relation `CurPrice(stock, price)`

`Select stock, Avg(price)`

`From Istream(CurPrice) [Range 1 Day]`

`Group By stock`

Average price over last day for each stock

Istream, Rstream, Fenster

- Emit 5-second moving average at every timestep

Select Istream(Avg(A)) From S [Range 5 seconds]

Funktioniert das?

Nein: Hier wird nur ein Ergebnis erzeugt, wenn der Mittelwert sich ändert und nicht zu jedem Zeitschritt

- To emit a result at every timestep

Select **Rstream**(Avg(A)) From S [Range 5 seconds]

Standard-Fenster: $[\infty]$

Standard-Slide: eine Einheit


- To emit a result every 5 seconds

Select Rstream(Avg(A))

From S[Range 5 seconds **Slide 5 seconds**]

Arvind Arasu, Shivnath Babu, and Jennifer Widom. 2006. The CQL continuous query language: semantic foundations and query execution. The VLDB Journal 15, 2, 121-142, **2006**

Benchmark: "Linear Road"



Eingabestrom: Car Locations ([CarLocStr](#))

car_id	speed	exp_way	lane	x_pos
1000	55	5	3 (Right)	12762
1035	30	1	0 (Ramp)	4539
...	...	...	...	...

Linear Road-Benchmark

- Sammlung von kontinuierlichen Anfragen auf realen Verkehrsmanagement-Situationen
- Beispiele:
 - Stream car segments based on x-positions (**leicht**)
 - Identify probable accidents (**mittel**)
 - Compute toll whenever car enters segment (**schwierig**)
- Messlatte: Skalierung auf so viele Expressways wie möglich, ohne in der Verarbeitung zurückzufallen

Linear Road: A Stream Data Management Benchmark, A. Arasu et al.,
Proceedings of the 30th VLDB Conference, Toronto, Canada, **2004**

<http://www.cs.brandeis.edu/~linearroad/>
<http://infolab.stanford.edu/stream/cql-benchmark.html>
<http://www.it.uu.se/research/group/udbl/lr.html>

Einfaches Beispiel

Monitor speed and segments of cars 1-100

Select car_id, speed, x_pos/5280 as segment
From CarLocStr
Where car_id >= 1 and car_id <= 100

+/-	Timestamp	car_id	speed	segment
+	6/6/03 12:34:05	22	23	0
+	6/6/03 12:34:05	10	23	1
+	6/6/03 12:34:05	16	23	11
+	6/6/03 12:34:05	2	30	12
+	6/6/03 12:34:05	25	25	15
+	6/6/03 12:34:05	23	26	18
+	6/6/03 12:34:05	18	20	24
+	6/6/03 12:34:05	5	30	29
+	6/6/03 12:34:05	12	26	40
+	6/6/03 12:34:05	1	27	41
+	6/6/03 12:34:05	4	23	47
+	6/6/03 12:34:05	29	30	53
+	6/6/03 12:34:05	28	30	55
+	6/6/03 12:34:05	7	32	65
+	6/6/03 12:34:05	6	28	99
+	6/6/03 12:34:05	8	30	96
+	6/6/03 12:34:05	9	30	93
+	6/6/03 12:34:05	14	27	90
+	6/6/03 12:34:05	27	27	82
+	6/6/03 12:34:05	26	28	78
+	6/6/03 12:34:05	20	23	77
+	6/6/03 12:34:05	3	23	76
+	6/6/03 12:34:05	21	23	75
+	6/6/03 12:34:05	13	27	71
+	6/6/03 12:34:05	19	32	68

Schwieriges Beispiel

Whenever a car enters a segment, issue it the current toll for that segment

+ / -	Timestamp	E.car_id	E.seg	T.toll
+	6/6/03 12:34:35	6	98	8
+	6/6/03 12:34:35	8	95	4
+	6/6/03 12:34:35	9	92	10
+	6/6/03 12:34:35	14	89	7
+	6/6/03 12:34:35	27	81	9
+	6/6/03 12:34:35	26	77	4
+	6/6/03 12:34:35	21	74	9
+	6/6/03 12:34:35	13	70	2
+	6/6/03 12:34:35	19	67	9
+	6/6/03 12:34:35	11	65	5
+	6/6/03 12:34:35	17	60	4
+	6/6/03 12:34:35	24	35	2
+	6/6/03 12:34:36	53	95	5
+	6/6/03 12:34:36	55	91	8
+	6/6/03 12:34:36	45	90	6
+	6/6/03 12:34:36	35	85	10
+	6/6/03 12:34:36	40	79	8
+	6/6/03 12:34:36	780	79	9
+	6/6/03 12:34:36	784	74	10
+	6/6/03 12:34:36	37	73	3
+	6/6/03 12:34:36	46	71	6
+	6/6/03 12:34:36	739	71	7
+	6/6/03 12:34:36	757	67	10
+	6/6/03 12:34:36	776	65	6
+	6/6/03 12:34:36	50	64	7

Maut-Beispiel in CQL

```
Select Rstream(E.car_id, E.seg, T.toll)
From CarSegEntryStr [NOW] as E, SegToll as T
Where E.loc = T.loc
```

CarSegEntryStr: Select lstream(*) From CurCarSeg

CurCarSeg:

```
Select car_id, x_pos/5280 as seg,
       Location(expr_way, dir, x_pos/5280) as loc
From CarLocStr [Partition By car_id Rows 1]
```

1 mile = 5280 ft.

Maut-Beispiel in CQL (2)

SegToll:


```
Select S.loc, BaseToll * (V.volume - 150)2  
From SegAvgSpeed as S, SegVolume as V  
Where S.loc = V.loc and S.avg_speed < 40.0
```

SegAvgSpeed:

```
Select loc, Avg(speed) as avg_speed  
From CarLocStr [Range 5 minutes]  
Group By Location(expr_way, dir, x_pos/5280) as loc
```


SegVolume:

```
Select loc, Count(*) as volume  
From CurCarSeg  
Group By loc
```



Non-Standard-Datenbanken

Von temporalen Datenbanken zu Stromdatenbanken



Praktische Stromverarbeitung: PipelineDB

- Open-Source, initial basierend auf PostgreSQL 9.5
- Kontinuierliches SQL auf Datenströmen (kontinuierliche Sichten)
 - `CREATE STREAM` stream (x int, y int, z int);
INSERT INTO stream (x, y, z) VALUES (0, 1, 2);
 - Fensterkonzept
`CREATE CONTINUOUS VIEW` v `WITH` (max_age = '1 hour') `AS`
SELECT COUNT(*) FROM stream
 - Anwendungsspezifische Aggregation
 - Hoher Durchsatz, inkrementell materialisierte Sichten
 - Realzeitanalysen, Überwachung
 - Top-k, Perzentile, Distinct,

Weitere Stromdatenverarbeitungsumgebungen

- Apache
 - Flink (flink.apache.org)
 - Kafka (kafka.apache.org)
 - Spark (spark.apache.org)
 - Storm (storm.apache.org)
- Elastic Stack (www.elastic.co)
- Odysseus (odysseus.informatik.uni-oldenburg.de)
- Viele weitere ...

Implementierung eines DSMS – Designeinflüsse

- **Variable Datenraten** mit **hohen Spitzen** mit ...
- ... **kaum vorhersagbarer Verteilung**
- Hohe **Anzahl** registrierter kontinuierlicher Anfragen
- **Designziele** hiermit umzugehen:
 - Multi-Anfrage-Optimierung von Ausführungsplänen
 - Mehrfachverwendung von internen Teilströmen
 - Reoptimierung von Plänen bei Laständerung (Selbstbeobachtung des Systemverhaltens)
 - Lastabhängige Approximation von korrekten Ausgaben (graceful approximation)

Fenster-orientierte Verarbeitung


- Fenster sind Möglichkeiten, den Nutzer selbst kleine Einheiten zu definieren zu lassen
- Nicht immer kann man immer größer werdende Fenster (vgl. [SQL:2011](#)) wegoptimieren
- Auch bei “kleinem” Fenster kann bei einem “Eingabestoß” (burst) eine große Relation entstehen
 - Problematische Verzögerungen
- Auch bei blockierenden Operatoren (z.B. Sort) kann der Speicherbedarf für den jeweiligen Zustand bei großen Relationen sehr groß werden
 - Verarbeitung wird ggf. auch zu langsam

QoS-Vereinbarungen

- QoS-Vereinbarung kann beinhalten, dass Eingaben ggf. nicht verarbeitet werden ("**Skip**"), um nicht zurückzufallen
- Statt Tupel wegzulassen, **Approximationstechniken** betrachten
- Aber: Statt Approximation erst einmal **inkrementelle Verarbeitung** richtig organisieren

Kontinuierliche Anfragen

- Daten werden nur einmal betrachtet und
- Speicher für Zustand (stark) begrenzt: $O(\text{poly}(\log(|\text{Strm}|)))$ (oder $O((\log n)^k)$ für ein konstantes k)
- Rechenzeit pro Tupel möglichst klein (auch um Zustand im Hauptspeicher zu modifizieren)



Beispiel: Elektrizitätsverbrauchsanalyse





Fig. 1. A set of power consumption time series.

Fensterbasierte Anfragen

Informationsbedarf:

Welche Regionen haben hohen Verbrauch in der Woche vom 16.-22. Juni?




Region 1: **Interessant**
Höchster Tagesverbrauch
am 20. Juni

Region 2: **Interessant**
Höchster Durchschnittsverbrauch
im Anfragefenster

Region 3: **Nicht interessant**
Geringerer Verbrauch als Region 2
an jedem Tag

Fig. 1. A set of power consumption time series.

Intervall-Skyline-Anfragen




Für den Informationsbedarf ist eine Zeitreihe s "interessant", falls im Anfragefenster keine andere Zeitreihe s' liegt, so dass

- (1) s' besser ist als s zu mindestens einem Zeitpunkt und
- (2) s' nicht schlechter ist als s zu jedem Zeitpunkt


Naiver Ansatz

Zeitreihe: $(t_0, v_0), (t_1, v_1), \dots, (t_n, v_n)$



Zeitreihe = Punkt im
n-dimensionalen Raum

$(v_0, v_1, \dots, v_n)$



Skyline-Berechnung

Skyline-Punkte = interessante Zeitreihen

Probleme

- (1) Einfache Skyline-Anfragebeantwortungstechniken nicht inkrementell
- (2) Insbesondere für hohe Dimensionen (große Fenster) daher nicht effektiv
- (3) Für überlappende Zeitfenster im Stromverarbeitungskontext daher nicht geeignet

Intervall-Skyline-Anfrage

- Eine Zeitreihe s dominiert eine Zeitreihe q im Intervall $[i:j]$, geschrieben $s \succ_{[i:j]} q$, falls $\forall k \in [i : j] s[k] \geq q[k]$ und $\exists l \in [i : j] : s[l] > q[l]$
- Sei S eine Menge von Zeitreihen und $[i:j]$ ein Intervall, dann ist die Intervall-Skyline bzgl. S und $[i:j]$ die Menge der nicht dominierten Zeitreihen aus S in $[i:j]$, geschrieben

$$Sky[i : j] = \{s \in S \mid \nexists s' \in S, s' \succ_{[i:j]} s\}$$

Energieverbrauchsdiagramm




Fig. 1. A set of power consumption time series.

Skyline = {region1, region2}

Unterscheidung

- Basisintervall (Fenster)
- Anfrageintervall

Intervall-Skyline – Effektive Berechnung

Notation	Meaning
s, q	time series
$[i:j] (i \leq j)$	an interval
$Sky[i:j]$	the skyline in interval $[i:j]$
t_c	the most recent timestamp
w	the size of the base interval
n	the number of time series
$W = [t_c - w + 1 : t_c]$	the base interval of time series
$s.max$	the maximum value of s in the base interval W
$s.min[i:j]$	the minimum value of s in interval $[i,j]$ in W

Gegeben eine Menge von Zeitreihen S , so dass jede Zeitreihe im Basisintervall $W = [t_c - w + 1 : t_c]$ definiert ist.

Gesucht wird eine **Datenstruktur D** , so dass **jede Intervall-Skyline-Anfrage** in $[i:j] \subseteq W$ **effektiv mit D berechnet** werden kann


On-the-fly-Methode (OTF)

Online-Intervall-Skyline-Anfragebeantwortung

Beispieldaten:

A SET OF TIME SERIES DATA.

Time series ID	Timestamps					
	1	2	3	4	5	...
s_1	4	3	2	5	5	...
s_2	5	5	1	5	5	...
s_3	2	2	5	3	4	...
s_4	1	1	3	4	2	...
s_5	3	4	4	1	3	...



Intervall-Skyline: OTF-Verfahren

Proposition 1 (max-min)

Für zwei Zeitreihen s, q und Intervall $[i:j] \subseteq W$ gilt:

Falls $s.\min[i:j] > q.\max$ dann $s \succ_{[i:j]} q$

Basisidee:

- Speichere $s.\max$ und $s.\min[i:j]$ für jede Zeitreihe zur Berechnung einer Intervall-Skyline
- Reduziere dadurch ggf. unnötige Prüfungen auf "Dominanz" (aufwendig)

Intervall-Skyline: OTF-Verfahren

Algorithm 1 The on-the-fly query algorithm.

Input: a set S of time series, an interval $[i : j]$;

Output: the skyline in $[i : j]$;

Description:

- 1: L = a sorted list of the time series in S in the descending order of their $s.max$.
 - 2: $Sky = \emptyset$;
 - 3: $maxmin = -\infty$;
 - 4: let s be the first time series in L ;
 - 5: **while** L is not empty and $maxmin \leq s.max$ **do**
 - 6: **if** no time series in Sky dominates s in $[i : j]$ **then**
 - 7: remove the time series from Sky dominated by s in $[i : j]$;
 - 8: $Sky = Sky \cup \{s\}$
 - 9: $maxmin = \max_{q \in Sky} \{q.min[i : j]\}$;
 - 10: **end if**
 - 11: s = the next time series in L ;
 - 12: **end while**
 - 13: **return** Sky ;
-

List the “capability” of not being dominated in descending order


Record the maximum “ability” of dominating other time series

if $maxmin > s.max$ then
the remaining time series must be dominated by some Skyline in Sky because:
(1). L is in descending order of $s.max$
(2). Prop. 1

Beispiel

```

while  $L$  is not empty and  $maxmin \leq s.max$  do
  if no time series in  $Sky$  dominates  $s$  in  $[i : j]$  then
    remove the time series from  $Sky$  dominated by  $s$  in
     $[i : j]$ ;
     $Sky = Sky \cup \{s\}$ 
     $maxmin = \max_{q \in Sky} \{q.min[i : j]\}$ ;
  end if
   $s =$  the next time series in  $L$ ;
end while
    
```



$w=3$ $W=[1:3]$

Berechne Skyline in $[2:3]$

THE SORTED LIST L IN ALGORITHM 1.

Time series	s_2	s_3	s_5	s_1	s_4
max	5	5	4	4	3
$min[2 : 3]$	1	2	4	2	1

$Sky=\{\}$, $maxmin = -\infty$

check s_2 , none can dominate s_2 , add s_2 , $maxmin=1$

$Sky=\{s_2\}$

check s_3 , none dominates s_3 , add s_3 , $maxmin=2$

$Sky=\{s_2, s_3\}$

check s_5 , none dominates s_5 , add s_5 , $maxmin=4$

$Sky=\{s_2, s_3, s_5\}$

check s_1 , s_1 is dominated by s_5 , discard, $maxmin=4$

$Sky=\{s_2, s_3, s_5\}$

check s_4 , $maxmin=4 > s_4.max$, discard

Ergebnis:

$Sky = \{s_2, s_3, s_5\}$

Flaschenhals für Online-Verarbeitung?

- Zu berechnende Daten im Verfahren für n Zeitreihen

THE SORTED LIST L IN ALGORITHM 1.

Time series	s_2	s_3	s_5	s_1	s_4
max	5	5	4	4	3
$min[2 : 3]$	1	2	4	2	1

- $s.min[i:j]$
- $s.max$ für alle Zeitreihen

A SET OF TIME SERIES DATA.

Time series ID	Timestamps					
	1	2	3	4	5	...
s_1	4	3	2	5	5	...
s_2	5	5	1	5	5	...
s_3	2	2	5	3	4	...
s_4	1	1	3	4	2	...
s_5	3	4	4	1	3	...

- Das Fenster bewegt sich (sliding window)
 - Prüfe $s.min[i:j]$ (Teuer? Zeit: $O(nw)$ Platz: $O(nw)$)
 - Prüfe $s.max$ (Teuer? Zeit: $O(nw)$ Platz: $O(nw)$)

Inkrementelle Berechnung

- $maxmin = \max_{q \in Sky} \{q.min[i : j]\};$
- $min[i:j]$ für Zeitreihen in Sky

Durchsuche $[i:j]$ in der Zeitpunkt-Dimension
(binärer Suchbaum)


Gebe min-Wert zurück
(min Heap)

Vorschlag: **Treap** (siehe auch: **Randomized Search Tree**)
(Verknüpfung von Heap in einer Dimension und binärem Suchbaum in der anderen Dimension)

Treap



- Daten sind Punkte (x,y)
→ Für Zeitreihen: (Zeitpunkt, Datenwert)
- Alle x Werte sind verschieden, ganzzahlig und liegen im Bereich $[0, k)$
- Jedem Knoten des Suchbaums ist genau ein Element (x,y) und ein Intervall aus $[0, k)$ zugeordnet
- Der y Wert eines Elements im Knoten w ist $\leq$ zum y Wert aller Elemente im Unterbaum von w (y Werte definieren einen Min-Baum)
- Das Wurzelintervall ist $[0,k)$
- Wenn das Intervall für Knoten w mit $[a,b)$ gegeben ist:
 - Linkes Kind hat Intervall $[a, \text{floor}((a+b)/2))$
 - Rechtes Kind hat Intervall $[\text{floor}((a+b)/2), b)$

Beispiel für einen Treap




Einfügen

- Starte mit leerem Treap
- $k = 16$
- Wurzelintervall ist $[0,16)$
- Füge ein: $(5,8)$
- Füge ein: $(6,9)$
- $(5,8)$ bleibt Wurzel, weil $8 < 9$.
- $(6,9)$ in linken Unterbaum einfügen, weil 6 im linken Kindintervall liegt




Einfügen

- Füge ein: $(7,1)$
- $(7,1)$ geht in die Wurzel, weil $1 < 8$.
- $(5,8)$ in linken Unterbaum eingefügt, weil 5 ins linke Kindintervall passt
- $(5,8)$ ersetzt $(6,9)$, weil $8 < 9$.
- $(6,9)$ in rechten Unterbaum eingesetzt, weil 6 ins rechte Kindintervall gehört




Einfügen




Füge ein: $(11, 5)$.

Eigenschaften



- Höhe: $O(\log k)$.
- Einfügezeit: $O(\log k)$.

Suche: Bestimme Min-Wert im Bereich $[i:j]$




Suche($[1:4]$)

Suche($[3:6]$)


Suchzeit: $O(\log k)$.

Löschen



- Ähnlich zu delete-min beim Min-Heap

DeleteMin: Binärer Heap (Wdhlg. von AuD)




deleteMin(pq):

- **Form-Invariante:** $H[1] := H[n]; n := n - 1$
- **Heap-Invariante:** starte mit Element e in $H[1]$.

Vertausche e mit Kind mit min Schlüssel bis
 $H[k] \leq \min(\{H[2k], H[2k+1]\})$ für Position k von e
oder e in Blatt

Löschen



Lösche
Knoten, ziehe
von hinten
nach, siebe
ein

- Ähnlich zu delete-min beim Min-Heap
- Löschzeit: $O(\log k)$.

Inkrementelle Verwaltung von Treaps für Zeitreihen

- Verwende **Zeit** als Binärbaumdimension (**X**)
- Verwende **Datenwert** als als Heap-Dimension (**Y**)

Basisintervallgröße **w** ist fix, daher wird **W** in festen Wertebereich von **X** abgebildet: $\{0, 1, \dots, w-1\}$

Die Höhe des Treaps ist fix und balanciert also $O(\log w)$

Einfügen: $O(\log w)$

Löschen: $O(\log w)$

Suche: $O(\log w)$

Inkrementelle Verwaltung von Treaps für Zeitreihen

- Beispiel $k = w$: Bilde Zeitpunkte auf $[0, w)$ ab:

- $w_t := t_c \bmod w$

- $W = [t_c - w + 1 : t_c]$ wird abgebildet auf
 $w_t + 1, w_t + 2, \dots, w - 1, 0, 1, \dots, w_t$

- Wenn die Zeit fortschreitet: $t_c := t_c + 1$
 $W = [t_c - w + 1 : t_c]$

Sei $t_c = 3$

$w = 3$

$W = [1:3]$

Dann $t_c = 4$

$W = [2:4]$

- Wenn Abbildung $t \rightarrow \text{value}$ der Skyline für den neuen Zeitpunkt den gleichen Wert liefert, wie für den alten:
→ Treap ändert sich nicht
- Wenn gilt: das neue ersetzt das ausgelaufene Element,
→ Treap muss aktualisiert werden (Normalfall)

----- $O(\log w)$

Beispiel

- $W=[1:3]$ und $w=3$
 - s_1 abgebildet auf $(1, 4), (2, 3)$ und $(3, 2)$
- $W' = [2 : 4]$
 - s_1 abgebildet auf $(1, 5), (2, 3)$ und $(3, 2)$
 - Y-Wert für $X = 1$ wechselt von 4 auf 5
 - Punkt $(1, 4)$ rausnehmen und $(1, 5)$ einfügen

A SET OF TIME SERIES DATA.

Time series ID	Timestamps					
	1	2	3	1	5	...
s_1	4	3	2	5	5	...
s_2	5	5	1	5	5	...
s_3	2	2	5	3	4	...
s_4	1	1	3	4	2	...
s_5	3	4	4	1	3	...

Bestimmung von $\min[i:j]$

Gegeben ein Treap, dann $\min[i:j]$ effektiv bestimmbar

Abbildung von $[i:j]$ in X-Bereich:

$$w_i = i \bmod w; w_j = j \bmod w;$$

Fall 1: $w_i \leq w_j$

Bestimme den min-Wert im Intervall $[w_i, w_j]$

Fall 2: $w_i > w_j$

Bestimme den min-Wert im Intervall $[0, w_j]$

und $[w_i, w-1]$, nehme den kleinsten

$$O(\log w)$$

Bestimmung von max bei Fensterverschiebung

- 1: $L =$ a sorted list of the time series in S in the descending order of their $s.max$.
- Max-Berechnung über (v, t) -Paare für jede Zeitreihe
 - Fenster verschiebt sich "wenig"
 - Strategie: Verwende Hilfsspeicher (auch Skizze genannt)
 - Ein Paar (v, t) wird gehalten, falls kein anderes Paar (v', t') existiert, so dass $v' \geq v$ und $t' > t$
 - Auf diese Weise werden nur im Mittel nur $(\log w)$ Paare gehalten

Finde maximalen Wert: $O(1)$

Aktualisiere Zeitstempel $O(\log w)$

Intervall-Skyline: OTF-Verfahren

Algorithm 1 The on-the-fly query algorithm.

Input: a set S of time series, an interval $[i : j]$;

Output: the skyline in $[i : j]$;

Description:

- 1: L = a sorted list of the time series in S in the descending order of their $s.max$.
 - 2: $Sky = \emptyset$;
 - 3: $maxmin = -\infty$;
 - 4: let s be the first time series in L ;
 - 5: **while** L is not empty and $maxmin \leq s.max$ **do**
 - 6: **if** no time series in Sky dominates s in $[i : j]$ **then**
 - 7: remove the time series from Sky dominated by s in $[i : j]$;
 - 8: $Sky = Sky \cup \{s\}$
 - 9: $maxmin = \max_{q \in Sky} q.min[i : j]$
 - 10: **end if**
 - 11: s = the next time series in L ;
 - 12: **end while**
 - 13: **return** Sky ;
-

Bestimmung von max bei Fensterverschiebung

A SET OF TIME SERIES DATA.

Time series ID	Timestamps					
	1	2	3	4	5	...
s_1	4	3	2	5	5	...
s_2	5	5	1	5	5	...
s_3	2	2	5	3	4	...
s_4	1	1	3	4	2	...
s_5	3	4	4	1	3	...

Beispiel: max für s_1

$W = [1 : 3]$, Skizze für s_1 enthält $\{(4,1),(3,2),(2,3)\}$

$W = [2 : 4]$,

(5,4) aktualisiere Skizze

$5 > 2, 4 > 3 \rightarrow \text{remove } (2,3)$

$5 > 3, 4 > 2 \rightarrow \text{remove } (3,2)$

$5 > 4, 4 > 1 \rightarrow \text{remove } (4,1)$

Skizze für s_1 : $\{(5,4)\}$

Neusortierung nach max bei Fensterverschiebung

- Maximalwert der Zeitreihen kann sich bei Fensterverschiebung ändern
- Es muss die Liste L neu sortiert werden
- Da üblicherweise Varianz im Zeitintervall klein, werden wenig Inversionen benötigt, um L sortiert zu halten

Algorithm 1 The on-the-fly query algorithm.

Input: a set S of time series, an interval $[i : j]$;

Output: the skyline in $[i : j]$;

Description:

- 1: L = a sorted list of the time series in S in the descending order of their $s.max$.
 - 2: $Sky = \emptyset$;
 - 3: $maxmin = -\infty$;
 - 4: let s be the first time series in L ;
 - 5: **while** L is not empty and $maxmin \leq s.max$ **do**
 - 6: **if** no time series in Sky dominates s in $[i : j]$ **then**
 - 7: remove the time series from Sky dominated by s in $[i : j]$;
 - 8: $Sky = Sky \cup \{s\}$
 - 9: $maxmin = \max_{q \in Sky} \{q.min[i : j]\}$;
 - 10: **end if**
 - 11: $s =$ the next time series in L ;
 - 12: **end while**
 - 13: **return** Sky ;
-

Analyse von OTF

- Für jede Zeitreihe (Platz)
Verwende $O(w)$ Platz für Treap
Verwende $O(\log w)$ Platz für Skizze für max Werte
---- Platzbedarf für n Zeitreihen $O(nw)$
- Für jede Zeitreihe (Zeit)
Verwende $O(\log w)$ Schritte, um Treap zu aktualisieren
Verwende $O(\log w)$ Schritte, um Skizze zu aktualisieren
---- Amortisierter Zeitbedarf für n Zeitreihen $O(n \log w)$

Experimente: Synthetische Datensätze

Skyline-Mittelwert μ normalverteilt


Parameter	Values
n	20k, 40k, 60k , 80k, 100k
σ	0.1, 0.3, 0.5 , 0.7, 0.9
w	100, 200, 300 , 400, 500
m	50, 100, 150 , 200, 250

Anzahl Skylines


Varianz

Breite Basisintervall


Breite Anfragefenster



(a) $\sigma = 0.1$.



(b) $\sigma = 0.5$.




(c) $\sigma = 0.9$.


Experimente

NA: Naïve Algorithm
OTF: On-the-fly Method
VM: View-Materialization Method


- Synthetische Datensätze
 - Anzahl der Skylines



(a) Effect of the standard deviation σ .




(b) Effect of the number of time series n .




(c) Effect of the interval size m .


- Anfragezeit



(a) Effect of the standard deviation σ .




(b) Effect of the number of time series n .




(c) Effect of the interval size m .

Experimente


- Synthetische Datensätze
 - Aktualisierungseffizienz



(a) Effect of the standard deviation σ .




(b) Effect of the number of time series n .




(c) Effect of the base interval size w .


- Platzbedarf



(a) Effect of the standard deviation σ .




(b) Effect of the number of time series n .



(c) Effect of the base interval size w .

Experiments

- Stock Data Sets
 - Query Time



Übersicht

