



Vorlesung

Cloud- und Web- Technologien

(CS3140)

Operatoren der Relationalen Algebra in MapReduce

Professor Dr. rer. nat. habil. Sven Groppe

<https://www.ifis.uni-luebeck.de/index.php?id=groppe>

Chronologische Übersicht über die Themen

Nr Thema

1 Einleitung

2 Einführung in das Semantic Web, RDF und SPARQL



Datenmodell

3 Die Semantic Web-Ontologiesprachen RDFS und OWL

4 Multiplattform-Entwicklung mit Kotlin



Multiplattform

5 Fortgeschrittene Themen mit Kotlin

6 Einstieg in Cloud Computing, Hadoop



Backend

7 Operatoren der relationalen Algebra in Hadoop

8 Datenverarbeitung mit Pig

9 Einführung in Spark und Flink

10 Stromverarbeitung mit Flink

11 Knotenzentrische Algorithmen mit Flink

12 HTML und CSS



Web

13 Browserprogrammierung mit JS/JQuery und
Serverprogrammierung mit PHP Hypertext Preprocessor

14 Zusammenfassung und Ausblick

Relationale Algebra

- Grundlage von SQL
- Jede Anfragesprache sollte mindestens die Mächtigkeit der Relationalen Algebra haben
=> Relationale Vollständigkeit
- Aber: Relationale Algebra nicht Turing-vollständig
 - Keine Möglichkeit zur Berechnung der transitiven Hülle
 - Fehlen von Rekursion
 - ...Durch diese Einschränkung besser optimierbar!

Kriterien für Anfragesprachen 1/3

- Ad-Hoc-Formulierung
 - Einfache Formulierung der Anfrage
 - Ohne ein ganzes Programm formulieren zu müssen
- Deskriptivität/Deklarativität
 - Deklarativ: „Was?“ und nicht „Wie?“
- Optimierbarkeit
 - Anfrage kann auf wenige Basisoperationen abgebildet werden, für die es Optimierungsregeln gibt

Kriterien für Anfragesprachen 2/3

- Mengenorientiert
 - Operationen auf Mengen von Daten
- Abgeschlossenheit
 - Ergebnis ist wieder eine Relation und kann als Eingabe für nächste Anfrage dienen
(\rightarrow Verschachtelbare Ausdrücke)
- Adäquatheit
 - Unterstützung aller Konstrukte des darunterliegenden Datenmodells
- Orthogonalität
 - Sprachkonstrukte sind in ähnlichen Situationen auch ähnlich anwendbar

Kriterien für Anfragesprachen 3/3

- Effizienz
 - Effiziente Ausführbarkeit jeder Operation
 - Relationales Modell: $\leq O(n^2)$, n Anzahl Tupel der Eingangsrelation
- Sicherheit
 - Syntaktisch korrekte Anfragen liefern endliche Ergebnisse und terminieren (keine Endlosschleife und keine unendlichen Ergebnisse)
- Vollständigkeit
 - Sprache muss mindestens so mächtig wie eine Standardsprache sein (z.B. relationale Algebra)

Relationale Algebra - Operatoren

Minimale Menge von Operatoren
(es existieren auch andere minimale Mengen)

Operator	Symbol
Projektion	π
Selektion	σ
Kreuzprodukt	\times
Vereinigung	\cup
Differenz	$-$
Umbenennung	ρ

Weitere Operatoren

Operator	Symbol
Durchschnitt	\cap
Division/Quotient	\div
Join	\bowtie

Erweiterte Relationale Algebra
(Außer Semi-Join (\ltimes/\ltimes) und
MIN/MAX nicht durch Operatoren
der minimalen Menge darstellbar)

Operator	Symbol
Semi Join	\ltimes, \ltimes
Äußere Joins	$\ltimes, \ltimes, \ltimes$
Duplikateliminierung	δ
Aggregation	<i>SUM, AVG, MIN, MAX, COUNT, ...</i>
Gruppierung	γ
Sortierung	τ
Erweiterte Projektion	π
Äußere Vereinigung	\cup

Mengen versus Multimengen

- Menge
 - Jedes Element ist höchstens einmal enthalten
 - Reihenfolge spielt keine Rolle
 - SQL mit Duplikateliminierung (DISTINCT)
- Multimenge
 - Jedes Element kann mehrfach vorkommen
 - Reihenfolge spielt keine Rolle
 - SQL ohne Duplikateliminierung (ohne DISTINCT)
 - Meist effizienter, da aufwändige Duplikateliminierung entfällt (falls gewünscht Duplikateliminierung evtl. nur einmal abschließend)
- Operatoren der Relationalen Algebra
 - Traditionell Mengensemantik
 - Zusätzlich Vorstellung der Multimengensemantik

Selektion σ_C 1/2

- $\sigma_C(R) := \{t \mid t \in R \wedge C(t)\}$ mit
 - R Relation
 - C Selektionsbedingung:
 - $l\Theta r$ mit l und r Konstanten oder Attribute aus R ,
 $\Theta \in \{=, \neq, <, \leq, >, \geq\}$ bei geordneten Wertebereichen,
sonst $\Theta \in \{=, \neq\}$
 - $C_1 \wedge C_2, C_1 \vee C_2, \neg C_1$ mit C_1, C_2 Selektionsbedingungen
 - *true, false*

Selektion σ_C 2/2

<p>Eingangsrelation R</p>	<p>$R_E := \sigma_{Preis \geq 500 \wedge Lieferzeit \leq 3} (Teil)$</p>																								
<p><i>Teil</i></p> <table border="1" data-bbox="111 584 593 838"> <thead> <tr> <th>PID</th> <th>Bez.</th> <th>Lieferzeit</th> <th>Preis</th> </tr> </thead> <tbody> <tr> <td>22</td> <td>PC1</td> <td>5</td> <td>1000</td> </tr> <tr> <td>23</td> <td>PC2</td> <td>3</td> <td>520</td> </tr> <tr> <td>24</td> <td>PC3</td> <td>1</td> <td>100</td> </tr> </tbody> </table>	PID	Bez.	Lieferzeit	Preis	22	PC1	5	1000	23	PC2	3	520	24	PC3	1	100	<p>R_E</p> <table border="1" data-bbox="629 584 1112 742"> <thead> <tr> <th>PID</th> <th>Bez.</th> <th>Lieferzeit</th> <th>Preis</th> </tr> </thead> <tbody> <tr> <td>23</td> <td>PC2</td> <td>3</td> <td>520</td> </tr> </tbody> </table> <p>Mengensemantik: Duplikate können nicht entstehen, da Eingangsrelation keine Duplikate enthalten kann</p> <p>Multimengensemantik: Evtl. vorhandene Duplikate bleiben bestehen</p>	PID	Bez.	Lieferzeit	Preis	23	PC2	3	520
PID	Bez.	Lieferzeit	Preis																						
22	PC1	5	1000																						
23	PC2	3	520																						
24	PC3	1	100																						
PID	Bez.	Lieferzeit	Preis																						
23	PC2	3	520																						

- MapReduce
 - Map
 - $\forall t \in R$ mit $C(t) = true$: Emit (t, t) as key/value-pair

Duplikateliminierung δ

- Wandelt Multimenge in Menge um
 - SQL: Mengensemantik bei DISTINCT meist durch genau eine finale Duplikateliminierung realisiert
- $\delta(R) := \{ t \mid t \in R \}$ mit
 - R Relation
- MapReduce
 - Map
 - $\forall t \in R$: Emit (t, t) as key/value-pair
 - gut mit anderen Operatoren (wie Projektion π oder Selektion σ) mit nur einer Map-Phase kombinierbar
 - Reduce
 - for each fetched $(t, [t, \dots, t])$: Emit (t, t) as key/value-pair

Projektion π 1/2

- $\pi_{A_1, \dots, A_k}(R) := \{(t[A_1], \dots, t[A_k]) \mid t \in R\}$ mit
 - R Relation
 - A_1, \dots, A_k Attribute aus R

Eingangsrelation R

<u>BestID</u>	Datum	PID → Teil	KID → Kunde
1	2.1.18	10	14
2	3.1.18	12	15
3	4.1.18	10	14

$$R_E := \pi_{PID, KID}(Bestellung)$$

Mengensemantik

PID → Teil	KID → Kunde
10	14
12	15

Multimengensemantik

PID → Teil	KID → Kunde
10	14
12	15
10	14

Projektion π 2/2

- $\pi_{A_1, \dots, A_k}(R) := \{(t[A_1], \dots, t[A_k]) \mid t \in R\}$ mit
 - R Relation
 - A_1, \dots, A_k Attribute aus R
- MapReduce
 - Map
 - $\forall t \in R : \text{Emit}((t[A_1], \dots, t[A_k]), (t[A_1], \dots, t[A_k]))$ as key/value-pair
 - Reduce
 - Bei Mengensemantik Reduce-Schritt der Duplikateliminierung
 - Bei Multimengensemantik entfällt Reduce-Schritt

Vereinigung \cup 1/2

- $R \cup S = \{t \mid t \in R \vee t \in S\}$

Mengensemantik

	R	S	$R \cup S$
Tupel in	✓		✓
		✓	✓
	✓	✓	✓

Bsp.: R S $R \cup S$

A	B	A	B	A	B
1	2	3	4	1	2
3	4	5	6	3	4
				5	6

Multimengensemantik

	R	S	$R \cup S$
Tupel in	n-mal	m-mal	(n+m)-mal

Bsp.: $R \cup S$

A	B
1	2
3	4
3	4
5	6

Vereinigung \cup 2/2

- $R \cup S = \{t \mid t \in R \vee t \in S\}$
- Hadoop MapReduce unterstützt in der Map-Phase das Lesen von mehreren Eingaben gleichzeitig
- MapReduce
 - Map
 - $\forall t \in R$: Emit (t, t) as key/value-pair
 - $\forall t \in S$: Emit (t, t) as key/value-pair
 - Reduce
 - Bei Mengensemantik Reduce-Schritt der Duplikateliminierung
 - Bei Multimengensemantik entfällt Reduce-Schritt

Durchschnitt \cap 1/2

- $R \cap S = \{t \mid t \in R \wedge t \in S\}$

Mengensemantik

	R	S	$R \cap S$
Tupel in	✓		
		✓	
	✓	✓	✓

Bsp.:

R	S	$R \cap S$
A B	A B	A B
1 2	3 4	3 4
3 4	5 6	

Multimengensemantik

	R	S	$R \cap S$
Tupel in	n-mal	m-mal	min(n, m)-mal

Bsp.:

R	S	$R \cap S$
A B	A B	A B
1 2	1 2	1 2
1 2	1 2	1 2
3 4	1 2	3 4
	3 4	
	5 6	

Durchschnitt \cap 2/2

- $R \cap S = \{t \mid t \in R \wedge t \in S\}$
- Hadoop MapReduce unterstützt in der Map-Phase das Lesen von mehreren Eingaben gleichzeitig
- MapReduce
 - Map
 - $\forall t \in R$: Emit (t , "R") as key/value-pair
 - $\forall t \in S$: Emit (t , "S") as key/value-pair
 - Reduce
 - Mengensemantik:
 - for each fetched (t , $[a_1, \dots, a_n]$) mit $\exists i, j \in \{1, \dots, n\}$:
 $a_i = \text{"R"} \wedge a_j = \text{"S"} : \text{Emit } (t, t)$ as key/value-pair
 - Multimengensemantik:
 - for each fetched (t , A) mit $A := [a_1, \dots, a_n]$:
 $r := |\{a \mid a \in A \wedge a = \text{"R"}\}| \wedge s := |\{a \mid a \in A \wedge a = \text{"S"}\}|$:
 $\min(r, s)$ -times Emit (t , t) as key/value-pair

Differenz — 1/2

- $R - S = \{t \mid t \in R \wedge t \notin S\}$

Mengensemantik

	R	S	$R - S$
Tupel in	✓		✓
		✓	
	✓	✓	

Bsp.:

R	S	$R - S$																
<table border="1"><tr><th>A</th><th>B</th></tr><tr><td>1</td><td>2</td></tr><tr><td>3</td><td>4</td></tr></table>	A	B	1	2	3	4	<table border="1"><tr><th>A</th><th>B</th></tr><tr><td>3</td><td>4</td></tr><tr><td>5</td><td>6</td></tr></table>	A	B	3	4	5	6	<table border="1"><tr><th>A</th><th>B</th></tr><tr><td>1</td><td>2</td></tr></table>	A	B	1	2
A	B																	
1	2																	
3	4																	
A	B																	
3	4																	
5	6																	
A	B																	
1	2																	
		$S - R$																
		<table border="1"><tr><th>A</th><th>B</th></tr><tr><td>5</td><td>6</td></tr></table>	A	B	5	6												
A	B																	
5	6																	

Multimengensemantik

	R	S	$R - S$
Tupel in	n-mal	m-mal	max(0, n-m)-mal

"Jedes Tupel t in S eliminiert ein t in R "

Bsp.:

R	S	$R - S$																										
<table border="1"><tr><th>A</th><th>B</th></tr><tr><td>1</td><td>2</td></tr><tr><td>1</td><td>2</td></tr><tr><td>3</td><td>4</td></tr><tr><td>7</td><td>8</td></tr></table>	A	B	1	2	1	2	3	4	7	8	<table border="1"><tr><th>A</th><th>B</th></tr><tr><td>1</td><td>2</td></tr><tr><td>1</td><td>2</td></tr><tr><td>1</td><td>2</td></tr><tr><td>3</td><td>4</td></tr><tr><td>5</td><td>6</td></tr></table>	A	B	1	2	1	2	1	2	3	4	5	6	<table border="1"><tr><th>A</th><th>B</th></tr><tr><td>7</td><td>8</td></tr></table>	A	B	7	8
A	B																											
1	2																											
1	2																											
3	4																											
7	8																											
A	B																											
1	2																											
1	2																											
1	2																											
3	4																											
5	6																											
A	B																											
7	8																											
		$S - R$																										
		<table border="1"><tr><th>A</th><th>B</th></tr><tr><td>1</td><td>2</td></tr><tr><td>5</td><td>6</td></tr></table>	A	B	1	2	5	6																				
A	B																											
1	2																											
5	6																											

Differenz — 2/2

- $R - S = \{t \mid t \in R \wedge t \notin S\}$
- Hadoop MapReduce unterstützt in der Map-Phase das Lesen von mehreren Eingaben gleichzeitig
- MapReduce
 - Map
 - $\forall t \in R : \text{Emit}(t, "R")$ as key/value-pair
 - $\forall t \in S : \text{Emit}(t, "S")$ as key/value-pair
 - Reduce
 - Mengensemantik:
 - for each fetched $(t, [a_1, \dots, a_n])$ mit $\exists i \in \{1, \dots, n\} : a_i = "R"$ \wedge $\nexists j \in \{1, \dots, n\} : a_j = "S"$: Emit (t, t) as key/value-pair
 - Multimengensemantik ("Jedes Tupel t in S eliminiert ein t in R):
 - for each fetched (t, A) mit $A := [a_1, \dots, a_n]$:
 $r := |\{a \mid a \in A \wedge a = "R"\}|$ \wedge $s := |\{a \mid a \in A \wedge a = "S"\}|$:
 $\max(r - s, 0)$ -times Emit (t, t) as key/value-pair

Kartesisches Produkt \times

$h(r) \setminus h(s)$	0	1	...	$n - 1$
0		1		
1	n	$n + 1$...	$2 \times n - 1$
...		...		
$n - 1$		$(n - 1) \times n + 1$		

Verteilungsschema für
 $r \in R$ mit $h(r) = 1$ (Zeile 1)
 bzw. für $s \in S$ mit $h(s) = 1$
 (Spalte 1)

- MapReduce

- Map

- $\forall t \in R : \forall i \in \{0, \dots, n - 1\}$: Emit $(h(t) \times n + i, (t, "R"))$
- $\forall t \in S : \forall i \in \{0, \dots, n - 1\}$: Emit $(h(t) + i \times n, (t, "S"))$

- Reduce

- Multi-/Mengensemantik:
 - for each fetched $(t, [a_1, \dots, a_n])$
 mit $\exists i, j \in \{1, \dots, n\} : a_i = (r, "R") \wedge a_j = (s, "S")$:
 Emit $(r \circ s, r \circ s)$ as key/value-pair

Equi-Join \bowtie 1/2

- $R \bowtie_C S = \sigma_C(R \times S)$ mit C ist Joinbedingung von der Form:
 - $r = s$ mit r Attribut aus R und s Attribut aus S
 - $C_1 \wedge C_2$ mit C_1 und C_2 Joinbedingungen

Mengensemantik

Bsp.: R S $R \bowtie_{R.B=S.B} S$

A	B
1	2
0	2
3	4
7	8

B	C
2	3
2	4
5	6
4	5

A	R.B	S.B	C
1	2	2	3
0	2	2	3
1	2	2	4
0	2	2	4
3	4	4	5

Multimengensemantik

Bsp.: R S $R \bowtie_{R.B=S.B} S$

A	B
1	2
0	2
7	8
3	4

B	C
2	3
4	5
4	5
4	5
5	6

A	R.B	S.B	C
1	2	2	3
0	2	2	3
3	4	4	5
3	4	4	5
3	4	4	5

Equi-Join \bowtie 2/2

- $R \bowtie_C S = \sigma_C(R \times S)$ mit C ist Joinbedingung von der Form:
 - $r = s$ mit r Attribut aus R und s Attribut aus S
 - $C_1 \wedge C_2$ mit C_1 und C_2 Joinbedingungen
- MapReduce
 - Map ($C := r_1 = s_1 \wedge \dots \wedge r_n = s_n$)
 - $\forall t \in R$: Emit $((t[r_1], \dots, t[r_n]), ("R", t[1], \dots, t[|t|]))$ as key/value-pair
 - $\forall t \in S$: Emit $((t[s_1], \dots, t[s_n]), ("S", t[1], \dots, t[|t|]))$ as key/value-pair
 - Reduce
 - for each fetched $(j, A) : \forall ("R", r[1], \dots, r[n]) \in A :$
 $\forall ("S", s[1], \dots, s[m]) \in A : t := (r[1], \dots, r[n], s[1], \dots, s[m]) :$
Emit (t, t) as key/value-pair

Semi-Join \bowtie 1/2

- $R \bowtie_C S = \pi_{\text{Attribute aus } R}(R \bowtie_C S)$ mit C ist Joinbedingung von der Form:
 - $r = s$ mit r Attribut aus R und s Attribut aus S
 - $C_1 \wedge C_2$ mit C_1 und C_2 Joinbedingungen

Mengensemantik

Bsp.: R S $R \bowtie_{R.B=S.B} S$

A	B
1	2
0	2
3	4
7	8

B	C
2	3
2	4
5	6
4	5

A	B
1	2
0	2
3	4

Multimenssemantik

Bsp.: R S $R \bowtie_{R.B=S.B} S$

A	B
1	2
0	2
7	8
3	4

B	C
2	3
4	5
4	5
4	5
5	6

A	B
1	2
0	2
3	4
3	4
3	4

Semi-Join \bowtie 2/2

- $R \bowtie_C S = \pi_{\text{Attribute aus } R}(R \bowtie_C S)$ mit C ist Joinbedingung von der Form:
 - $r = s$ mit r Attribut aus R und s Attribut aus S
 - $C_1 \wedge C_2$ mit C_1 und C_2 Joinbedingungen
- MapReduce
 - Map ($C := r_1 = s_1 \wedge \dots \wedge r_n = s_n$)
 - $\forall t \in R$: Emit $((t[r_1], \dots, t[r_n]), ("R", t[1], \dots, t[|t|]))$ as key/value-pair
 - $\forall t \in S$: Emit $((t[s_1], \dots, t[s_n]), ("S", t[1], \dots, t[|t|]))$ as key/value-pair
 - Reduce
 - for each fetched $(j, A) : \forall ("R", r[1], \dots, r[n]) \in A :$
 $\forall ("S", s[1], \dots, s[m]) \in A : t := (r[1], \dots, r[n]):$
Emit (t, t) as key/value-pair
 - Bei Mengensemantik nur $1 \times$ Versenden von (t, t)

Äußere Joins \bowtie , \ltimes , \rtimes - 1/2

- „Ergebnis des Joins plus die Tupel aus einer Eingangsrelation ohne Joinpartner“
- $R \ltimes S = (R - (R \bowtie S)) \cup (R \bowtie S)$
- $R \rtimes S = (R \bowtie S) \cup (S - (S \bowtie R))$
- $R \bowtie S = (R - (R \bowtie S)) \cup (R \bowtie S) \cup (S - (S \bowtie R))$

Mengensemantik

Bsp.: R S $R \bowtie S$

A	B	B	C	A	B	C
1	2	2	3	1	2	3
0	2	2	4	0	2	3
3	4	4	5	1	2	4
7	8	5	6	0	2	4
				3	4	5
					5	6
				7	8	

Multimengensemantik

Bsp.: R S $R \bowtie S$

A	B	B	C	A	B	C
1	2	2	3	1	2	3
0	2	4	5	0	2	3
3	4	4	5	3	4	5
7	8	4	5	3	4	5
		5	6		5	6
				7	8	

Äußere Joins \bowtie , \ltimes , \rtimes - 2/2

- MapReduce

- Map ($C := r_1 = s_1 \wedge \dots \wedge r_n = s_n$)

- $\forall t \in R$: Emit $((t[r_1], \dots, t[r_n]), ("R", t[1], \dots, t[|t|]))$ as key/value-pair
- $\forall t \in S$: Emit $((t[s_1], \dots, t[s_n]), ("S", t[1], \dots, t[|t|]))$ as key/value-pair

- Reduce

- for each fetched $(j, A) : \forall ("R", r[1], \dots, r[n]) \in A :$
 $\forall ("S", s[1], \dots, s[m]) \in A : t := (r[1], \dots, r[n], s[1], \dots, s[m]) :$
 Emit (t, t) as key/value-pair
- Voller (\bowtie) und Linker (\ltimes) äußerer Join: for each fetched $(j, A) :$
 $\nexists ("S", s[1], \dots, s[m]) \in A \wedge \forall ("R", r[1], \dots, r[n]) \in A :$
 $t := (r[1], \dots, r[n]) : \text{Emit } (t, t)$ as key/value-pair
- Voller (\bowtie) und Rechter (\rtimes) äußerer Join: for each fetched $(j, A) :$
 $\nexists ("R", r[1], \dots, r[n]) \in A \wedge \forall ("S", s[1], \dots, s[m]) \in A :$
 $t := (s[1], \dots, s[m]) : \text{Emit } (t, t)$ as key/value-pair

Gruppierung γ 1/3

- Partitionierung der Tupel einer Relation (in „Gruppen“) gemäß ihrer Werte in einem oder mehreren Attributen
 - Hauptzweck: Aggregation auf den jeweiligen Gruppen
- $\gamma_{(F_1, \dots, F_n)}(R)$, wobei F_i von folgender Form ist:
 - ein Attribut von R
 - ein Ausdruck $X \rightarrow Y$, wobei Y ein neuer Attributname ist, und X von folgender Form:
 - ein Attribut von R
 - eine Aggregationsfunktion ($SUM, COUNT, AVG, MIN, MAX, \dots$)
 - eine (verschachtelbare) Berechnungsvorschrift (arithmetische Formel, String-Operation, Klammern, ...)
 - Ist kein F_i angegeben, so ist ganz R die (einzige) Gruppe

Gruppierung γ 2/3

- $\gamma(A_1, \dots, A_k, F_1, \dots, F_n)(R)$, wobei A_i Attribute aus R sind und F_i Zuweisungen von Ausdrücken der Form $X \rightarrow Y$ sind

Bestellung

<u>BestID</u>	Datum	PID → Teil	KID → Kunde
1	2.1.18	10	14
2	3.1.18	12	15
3	4.1.18	10	14

$\gamma_{KID, COUNT(PID) \rightarrow NR, MAX(Datum) \rightarrow MaxDatum}(Bestellung)$

KID	Nr	MaxDatum
14	2	4.1.18
15	1	3.1.18

Gruppierung γ 3/3

- $\gamma(A_1, \dots, A_k, F_1, \dots, F_n)(R)$, wobei A_i Attribute aus R sind und F_i Zuweisungen von Ausdrücken der Form $X \rightarrow Y$ sind
- MapReduce
 - Map
 - $\forall t \in R$: Emit $((t[A_1], \dots, t[A_k]), t)$ as key/value-pair
 - Reduce
 - for each fetched $((t[A_1], \dots, t[A_k]), [t_1, \dots, t_m])$:
 $t' := (t[A_1], \dots, t[A_k], F_1(t_1, \dots, t_m), \dots, F_n(t_1, \dots, t_m))$:
Emit (t', t') as key/value-pair

Sortierung τ 1/2

- Ergebnis von $\tau_{A_1, \dots, A_k}(R)$ ist eine Liste von Tupeln aus R , die primär nach A_1 , sekundär nach A_2 usw. sortiert ist

Bestellung

<u>BestID</u>	Datum	PID → Teil	KID → Kunde
1	2.1.18	10	14
2	3.1.18	12	15
3	4.1.18	10	14

$\tau_{KID, Datum}$ (Bestellung)

<u>BestID</u>	Datum	PID → Teil	KID → Kunde
1	2.1.18	10	14
3	4.1.18	10	14
2	3.1.18	12	15

- Wichtig:

- Ergebnis der Sortierung ist keine (Multi-)Menge, sondern eine Liste
- Sortieroperation immer letzte Operation, da ansonsten wieder (Multi-) Mengen entstehen
- In DBMS wird häufig auch zwischendurch sortiert (oder auf vorsortierte Eingaben aus einem Index zugegriffen), um optimierte Algorithmen anzuwenden, die sortierte Eingaben erfordern

Sortierung τ 2/2

- Ergebnis von $\tau_{A_1, \dots, A_k}(R)$ ist eine Liste von Tupeln aus R , die primär nach A_1 , sekundär nach A_2 usw. sortiert ist
- MapReduce
 - Map
 - $\forall t \in R$: Emit $((t[A_1], \dots, t[A_k]), t)$ as key/value-pair
 - Reduce
 - MapReduce ordnet die Reducer nach der Ordnung der Schlüssel der Eingabe, d.h. Reducer i erhält nur Schlüssel-Wert-Paare, deren Schlüssel kleiner sind als die von Reducer $i + 1$

SPARQL-Anfrage in der Cloud



- Welche Map- und Reduce-Phasen sind notwendig zum Verarbeiten folgender SPARQL-Anfrage?

```
PREFIX ...  
SELECT ?person ?name  
WHERE {  
  ?article rdf:type bench:Article .  
  ?article dc:creator ?person .  
  ?person foaf:name ?name .  
}  
ORDER BY ?name
```

Annahme:

Durch geschickte Verwendung von Indexen können die Ergebnisse der Tripelmuster mit einem Indexzugriff erfolgen.

Zusammenfassung

- Relationale Algebra als Basis von vielen Anfragesprachen
- Operatoren der Relationalen Algebra als Map/Reduce-Jobs ausführbar
- Komplexe Anfragen erfordern Hintereinanderschaltung mehrerer Map/Reduce-Jobs