




Μαζικός Παραλληλισμός με Map - Reduce

- Μοντέλο
- Θέματα υλοποίησης
- Παραδείγματα διαχείρισης δεδομένων

Ευχαριστίες


- Οι διαφάνειες στηρίζονται σε μεγάλο βαθμό στο υλικό που είναι διαθέσιμο από το εργαστήριο Infolab του Stanford για τα μαθήματα CS345A και CS347.

<http://infolab.stanford.edu>


Τι είναι το MapReduce

- Πρόκειται για ένα προγραμματιστικό μοντέλο,
- που είναι κατάλληλο για επεξεργασία πολύ μεγάλων όγκων δεδομένων σε κατανεμημένους πόρους.
- Βασίζεται σε ιδέες γνωστές από δεκαετίες!
- Αρχικά αναπτύχθηκε από την Google αλλά οι περισσότεροι το χρησιμοποιούν μέσω της υλοποίησης ανοιχτού κώδικα Hadoop.


Δημιουργία Ευρετηρίου (index) κειμένου - I




Δημιουργία Ευρετηρίου (index) κειμένου - II



Γενικό Μοντέλο επεξεργασίας: Map



Γενικό Μοντέλο επεξεργασίας: Reduce



Συνοπτική Περιγραφή

- $\text{map} (\text{κλειδί}, \text{τιμή}) \rightarrow \text{λίστα από ζεύγη} (\text{κλειδί}', \text{τιμή}')$
- $\text{reduce} (\text{κλειδί}', \text{λίστα από τιμές}') \rightarrow \text{τελική_τιμή (list)}$

Ή αλλιώς:

- $\text{Map: } (k1, v1) \rightarrow [(k2, v2)]$
- $\text{Reduce: } (k2, [v2]) \rightarrow [v3]$ //σε εκδόσεις Hadoop μπορεί να αλλάξει το κλειδί $k2$ σε $k3$.

-Το κλειδί δεν έχει εδώ την αυστηρή έννοια των ΒΔ, δηλ. μπορούν να υπάρχουν περισσότερες ενδιάμεσες τιμές με το ίδιο κλειδί.

Παράδειγμα: καταμέτρηση εμφανίσεων λέξεων

```
map(String doc, String value);  
  // doc: όνομα εγγράφου  
  // value: περιεχόμενο εγγράφου  
  for each word w in value:  
    EmitIntermediate(w, “1”);
```

Παράδειγμα:

```
map(doc, “cat dog cat bat dog”) emits  
  [cat 1], [dog 1], [cat 1], [bat 1], [dog 1]
```


Παράδειγμα: καταμέτρηση εμφανίσεων λέξεων

```
reduce(String key, Iterator values);  
  // key: λέξη  
  // values: λίστα με καταμετρήσεις  
  int result = 0;  
  for each v in values:  
    result += ParseInt(v)  
  Emit(AsString(result));
```

Παράδειγμα:

```
reduce("dog", "1 1 1 1") emits "4"
```

Σύνοψη παράλληλης εκτέλεσης



Μοντέλο επεξεργασίας - Map

- Η είσοδος στη συνάρτηση map (π.χ., γραμμές από αρχείο, εγγραφές από ΒΔ, κλπ.) έχουν τη μορφή (κλειδί, τιμή).
- Η συνάρτηση map μετατρέπει κάθε ένα τέτοιο ζευγάρι σε ένα άλλο ζευγάρι (κλειδί', τιμή').
 - Επεξεργάζεται κάθε στοιχείο της εισόδου ξεχωριστά (γι αυτό και παραλληλίζεται εύκολα).
 - Αντιστοιχεί στο ενδιάμεσο αποτέλεσμα (δηλ. την τιμή') ένα κλειδί.
- Ο βαθμός παραλληλισμού καθορίζεται από το σύστημα.

Μοντέλο επεξεργασίας - Reduce

- Η επεξεργασία της συνάρτησης reduce γίνεται αφού ολοκληρωθεί η επεξεργασία της map.
- Για κάθε ξεχωριστό κλειδί, δημιουργείται μία λίστα που περιέχει όλες τις αντίστοιχες τιμές.
- Η συνάρτηση reduce υπολογίζει μία τελική τιμή για το κλειδί επεξεργάζοντας τη λίστα με τις τιμές που παρήγαγε η map (το κλειδί δεν αλλάζει).
- Οι τιμές για κάθε κλειδί μπορούν να υπολογίζονται παράλληλα.


Συντονισμός – κόμβος master

- Ο κόμβος master
 - Ελέγχει αν μια εργασία (task) δεν έχει εκτελεστεί (idle), εκτελείται (in-progress) ή έχει ολοκληρωθεί (completed).
 - Οι εργασίες χρονοδρομολογούνται μόλις ελευθερώνονται κόμβοι.
 - Όταν ολοκληρώνεται μία map εργασία, ο master ενημερώνεται για τη θέση και το μέγεθος των ενδιάμεσων αποτελεσμάτων, που είναι σε τόσα αρχεία, όσα και οι κόμβοι για τη reduce.
 - Κατόπιν ενημερώνονται οι κόμβοι για τη reducer.
- Επίσης ο master ελέγχει περιοδικά (με pings) τους κόμβους για τον εντοπισμό σφαλμάτων.


Θέματα υλοποίησης

- Συναρτήσεις συνδυασμού
- Σύστημα Αρχείων
- Διαμερισμός εισόδου και κλειδιών
- Αποτυχίες
- Εργασίες Backup
- Ταξινόμηση αποτελεσμάτων

Συναρτήσεις συνδυασμού (combine)



Παρόμοιο με την εκτέλεση ενός τοπικού *reduce* στα ενδιάμεσα αποτελέσματα.



Κατανεμημένο Σύστημα Αρχείων





Figure 1: Execution overview

Διαμερισμός εισόδου και κλειδιών

- Πόσοι θα είναι κόμβοι worker;
 - Καλύτερα να υπάρχουν πολλά κομμάτια εισόδου ανά κόμβο, για καλύτερη εξισορρόπηση φόρτου και για καλύτερη αντιμετώπιση αποτυχιών.
- Σε πόσα κομμάτια θα διαμεριστεί η είσοδος;
 - Πιο πολλά από τον αριθμό των κόμβων,
 - Που είναι ήδη μεγάλος.
 - Στα τυπικά παραδείγματα της google ο διαμερισμός είναι σε κομμάτια των 64MB.
- Η ανάθεση γίνεται έτσι ώστε να ανατίθενται κομμάτια της εισόδου στους πιο κοντινούς κόμβους.
 - Όταν αυτό είναι εφικτό

Αποτυχίες

- Ο κόμβος Master εντοπίζει αποτυχίες και ξανα αναθέτει την εργασία του κόμβου που απέτυχε σε άλλο κόμβο worker.
- Αν οι αποτυχίες οφείλονται σε λάθη στα δεδομένα εισόδου, τότε το αντίστοιχο αρχικό κομμάτι δεδομένων μπορεί να αφαιρεθεί.



Backup Εργασίες

- Υπάρχει περίπτωση ένα μηχάνημα να έχει μείνει πίσω στην εκτέλεση των εργασιών (straggler) λόγω π.χ., κάποιου τεχνικού προβλήματος, όπως χαλασμένος δίσκος.
- Εξαιτίας αυτού του μηχανήματος, όλη η επεξεργασία καθυστερεί.
 - Όταν πολλές διεργασίες εκτελούνται παράλληλα, η πιο αργή καθορίζει και τον χρόνο ολοκλήρωσης.
- Λύση: όταν πλησιάζει η συνολική εργασία προς το τέλος, τότε ο συντονιστής χρονοδρομολογεί πολλαπλές φορές τις map/reduce υποεργασίες που απομένουν.
 - Με το σκεπτικό ότι τουλάχιστον μία θα ολοκληρωθεί στον προβλεπόμενο χρόνο.
 - Υπάρχουν επιπλέον μηχανισμοί για την διαγραφή περιττών (διπλών) αποτελεσμάτων όταν όλες οι υποεργασίες τελειώνουν κανονικά.

Ταξινόμηση αποτελεσμάτων

- Γίνεται σε κάθε κόμβο βάσει κλειδιού.





Figure 1: Execution overview

Παράδειγμα: ταξινόμηση εγγραφών



Map: extract k, output [k, record]

Reduce: Τίποτα!

Παραδείγματα - A

- **Κατανεμημένο Grep:**
- map: παράγει μία γραμμή αν η συγκεκριμένη γραμμή ταυτίζεται με το πρότυπο.
- reduce: απλή αντιγραφή των ενδιάμεσων αποτελεσμάτων στην έξοδο.

Παραδείγματα - B

- **Καταμέτρηση της συχνότητας προσπέλασης μιας διεύθυνσης URL:**
- Map: επεξεργασία των αρχείων log και παραγωγή ενδιάμεσων αποτελεσμάτων της μορφής <URL, 1> για κάθε προσπέλαση.
- Reduce: πρόσθεση όλων των τιμών για κάποιο συγκεκριμένο URL και παραγωγή ζευγών <URL, total count> .

Παραδείγματα - Γ

- **Αντίστροφος Γράφος Web-Link:**
- Map: παραγωγή ζευγών $\langle \text{target}, \text{source} \rangle$ για κάθε σύνδεσμο target προς μια σελίδα από την σελίδα source που εκείνη τη στιγμή επεξεργάζεται.
- Reduce: απλή αντιγραφή στην έξοδο των αποτελεσμάτων που έχουν τη μορφή ζευγών $\langle \text{target}, \text{list}(\text{source}) \rangle$.

Παραδείγματα ερωτημάτων

- Έστω η σχέση Employees(id, dno, salary).
- Θέλουμε να υπολογίσουμε το ερώτημα:

```
Select dno, SUM(salary)
from employees
where salary>1000
group by dno
```
- Map: για κάθε πλειάδα με salary>1000 δημιουργείται ένα ζεύγος (dno, salary)
- Reduce: για κάθε τιμή του dno, η είσοδος είναι όλες οι αντίστοιχες τιμές salary. Η συνάρτηση απλώς τις προσθέτει.

Παραδείγματα σχεσιακών τελεστών

- Τελεστές όπως η επιλογή σ_C ή η προβολή π_A απαιτούν μόνο κατάλληλη συνάρτηση map.
- Έστω η σύνδεση $R(X, Y) \bowtie S(Y, Z)$.
 - Map:
 - Είσοδος: (όνομα σχέσης R ή S , μία πλειάδα t)
 - Έξοδος: λίστα (τιμή του Y ,
λίστα από (όνομα σχέσης, υπόλοιπο πλειάδας X ή Z)).
 - Reduce: για κάθε τιμή του Y , δημιουργεί όλα τα ζευγάρια XZ .

Πλεονεκτήματα

- Το μοντέλο Map-Reduce κρύβει τις τεχνικές λεπτομέρειες της παραλληλοποίησης και παρέχει built-in μηχανισμούς ανάκαμψης από σφάλματα.
- Πολλά προβλήματα μπορούν να εκφραστούν με βάση το μοντέλο Map-Reduce.
- Οι εφαρμογές κλιμακώνονται σε χιλιάδες μηχανήματα.
 - Αλλά παρόμοια κλιμάκωση επιτυγχάνεται και με παράλληλη επεξεργασία ερωτημάτων σε αρχιτεκτονικές shared nothing.

Μειονεκτήματα

- Το μοντέλο επεξεργασίας μοναδικής εισόδου και δύο σταδίων δεν είναι ευέλικτο ώστε να προσαρμόζεται σε όλα τα επιθυμητά σενάρια.
- Απαιτείται η συγγραφή κώδικα ακόμη και για τους πιο συνηθισμένους τελεστές, όπως επιλογής και προβολής.
 - Δήλωση εργασιών σε πολύ χαμηλότερο επίπεδο σε σχέση με την SQL.
- Ο κώδικας μέσα στις συναρτήσεις map και reduce δεν είναι φανερός → δυσκολία στην βελτιστοποίηση.

Υλικό για μελέτη

- MapReduce: Simplified Data Processing on Large Clusters, *Jeffrey Dean and Sanjay Ghemawat*,
<http://labs.google.com/papers/mapreduce-osdi04.pdf>
- Hadoop: υλοποίηση ανοιχτού κώδικα
- Pig Latin: A Not-So-Foreign Language for Data Processing, *Christopher Olston, Benjamin Reedy, Utkarsh Srivastava, Ravi Kumar, Andrew Tomkins*, <http://wiki.apache.org/pig/>