OPEN ACCESS
Indo-JC SUBMISSION
ISSN XXXX-XXXX IND. JOURNAL ON COMPUTINNG VOL. XX, NO. XX, MARCH 2016
SOCJ.TELKOMUNIVERSITY.AC.ID/INDOJC PP. XX-XX. DOI:XXX

Implementasi Algoritma Penjadwalan untuk pengelolaan Big Data dengan Hadoop

Sidik Prabowo [#1], Maman Abdurohman[*2]

School of Computing,Telkom University
Jalan Telekomunikasi no 1, Bandung, Jawa Barat. Indonesia 40257

pakwowo@telkomuniversity.ac.id
abdurohman@ telkomuniversity.ac.id

Abstract

This paper proposes a hadoop scheduler scheme on completing the appropriate job type for Hadoop performance improvement. The suitability of the scheduler type and the type of job done can increase throughput and decrease the average job completion time. The main problem with job execution is the mismatch between the scheduler and the type of job being done. In this paper we have tested several Hadoop scheduler algorithms namely FIFO, Fair, SARS and COSHH scheduler with some kind of job which handled in hadoop environment. The types of jobs that are tested are word count, random text writer and grep. The test is done two scenarios, namely homogeneous job (one type) and heterogeneous (some kind of job) done together. The results show that SARS algorithm suitable for use on job completion which is homogeneous. Meanwhile, COSHH algorithm is suitable for heterogeneous combined job.

Keywords : Hadoop, scheduler, SARS,FAIR, COSHH, dan job.

Abstrak

Paper ini mengusulkan skema scheduler hadoop pada penyelesaikan tipe job yang sesuai untuk peningkatan kinerja Hadoop. Kesesuaian jenis scheduler dan tipe job yang dikerjakan dapat meningkatkan throughput dan menurunkan waktu rata-rata penyelesaian job. Masalah utama pada eksekusi job adalah ketidaksesuaian antara scheduler dengan tipe job yang dikerjakan. Pada paper ini telah dilakukan pengujian terhadap beberapa algoritma scheduler Hadoop yaitu FIFO, Fair, SARS dan COSHH scheduler dengan beberapa jenis job yang ditangani dalam lingkungan hadoop. Jenis-jenis job yang diujikan adalah word count, random text writer dan grep. Pengujian dilakukan dua skenario, yaitu job homogen (satu jenis) dan heterogen (beberapa jenis job) dikerjakan bersama. Hasil pengujian menunjukan bahwa algoritma SARS cocok digunakan pada penyelesaian job yang sifatnya homogen. Sementara itu algoritma COSHH cocok digunakan pada penyelesaian job gabungan yang heterogen.

Kata kunci: Hadoop, scheduler, SARS, COSHH, dan job.

Received on xxx, accepted on xxx, published on xxx

I. INTRODUCTION

HADOOP merupakan salah satu sistem file terdistribusi yang diperuntukan untuk mengerjakan job-job untuk data yang masuk kategori besar (*Big Data*). Arsitektur Hadoop Distributed File System (HDFS) yang ditunjukan pada gambar 1. terdiri dari dua bagian yaitu *Namenode* dan *Datanode*. *Namenode* merupakan node utama yang berkomunikasi dengan client untuk menyelesaikan job.

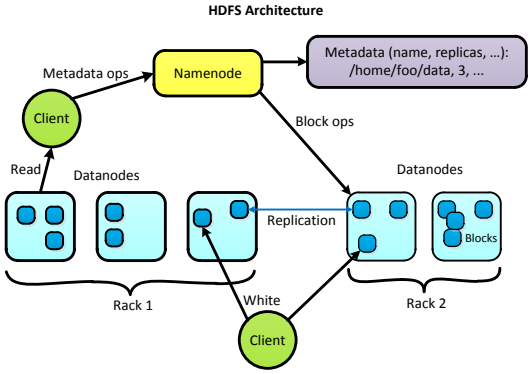

Gambar 1. Arsitektur HDFS [1]

Pada satu sistem terdapat sejumlah datanodes yang didalamnya data disimpan secara redundan. Dalam sistem Hadoop terdapat dua lapisan yaitu lapisan *MapReduce* dan lapisan HDFS. Gambar 2. menunjukan lapisan pada Hadoop. Pada masing-masing lapisan terapat peran node master (*masternode*) dan slave (*datanode*). Pada lapisan *MapReduce* terdapat dua proses penting yaitu *Map* dan *Reduce*. Kedua proses ini merupakan keunggulan sistem Hadoop dibandingkan dengan sistem terdistribusi yang lain.

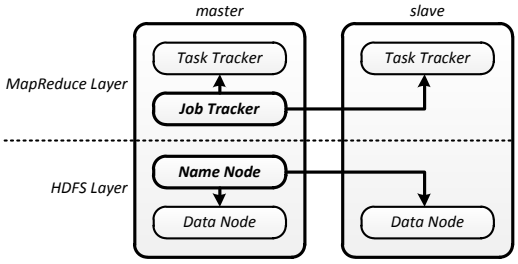

Gambar 2. Lapisan pada Hadoop [1]

Setiap job yang masuk ke dalam master akan dilakukan proses *mapi* dan *reduce*. Pada proses ini diperlukan job scheduler sebagai sistem manajemen penjadwalan eksekusi job. Terdapat beberapa algoritma yang dibangun untuk memastikan bahwa proses ini berjalan cepat dan akurat. Melihat karakteristik Big Data saat ini, dimana baik ukuran maupun variasi jenis dan tipe data yang sangat besar, hal ini akan menyebabkan terdapatnya sekumpulan job yang harus diselesaikan oleh master node dalam waktu yang hampir bersamaan. Job dalam kategorisasinya dapat dikelompokkan menjadi homogen (job yang sama) atau dilakukan secara bersamaan antar job yang berbeda (heterogen). Kedua karakteristik job ini memerlukan algoritma yang berbeda sehingga diperoleh hasil proses yang efektif dilihat dari sisi *throughput* dan waktu rata-rata pengerjaan job. Semakin besar *throughput* dan semakin kecil rata-rata pengerjaan job, menunjukan sistem semakin berjalan dengan baik.

Pada paper ini dilakukan pengujian algoritma *scheduler* yang tersedia untuk dijalankan diatas Hadoop yaitu: FIFO, Fair, SARS dan COSHH. Kedua scheduler pertama yaitu FIFO dan Fair adalah scheduler asli yang dibawa pada Hadoop, sementara itu SARS dan COSHH merupakan algoritma pengembangan dari

algoritma scheduler sebelumnya. Pengujian dilakukan pada dua tipe job yaitu job homogen (satu jenis job) dan job heterogen (beberapa jenis job dijalankan secara bersamaan). Hasil pengujian ini merupakan rekomendasi penggunaan scheduler yang sesuai untuk tipe job yang dijalankan pada Hadoop.

II. TINJAUAN PUSTAKA

Scheduller pada Hadoop bertujuan untuk mengelola pencarian maupun pemrosesan data supaya dapat dieksekusi lebih cepat. Secara default Hadoop menggunakan First In First Out (FIFO) dan Fair untuk penjadwalan eksekusi Job.

A. FIFO (*First In First Out*)

Mekanisme dari metode penjawalan FIFO adalah dengan mengeksekusi jobs yang masuk kedalam antrian lebih dahulu, diikuti job selanjutnya sesuai dengan urutan kedatangan. Algoritma FIFO tidak menjalankan penanganan skala prioritas serta perhitungan baik dari kategorisasi *long jobs* atau *short jobs* maupun parameter yang lain, dimana hal ini mengakibatkan penggunaan algoritma FIFO kurang efektif untuk beberapa type job tertentu[2].FIFO akan tetap mempertahankan job yang sedang bekerja pertama kali saat jobs yang lain akan masuk[3]. FIFO akan memberikan kesempatan job untuk menggunakan resource yang ada sesuai dengan waktu kedatangan dan apabila resource kosong, nantinya akan dilanjutkan oleh job selanjutnya [2]. Penggunaan MapReduce pada algoritma FIFO juga mengikuti pertama kali map dimulai[3]. Berikut ilustrasi dari FIFO berdasarkan fungsi reduce pada hadoop:

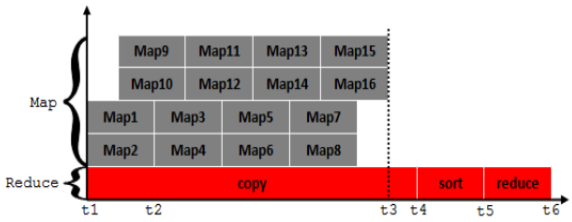

Gambar 3. Ilustrasi FIFO untuk reduce Hadoop[2]

B. Fair

Fair scheduler bekerja dengan cara mendistribusikan resource secara sama rata (*Fair*), untuk setiap job yang masuk kedalam antrian. Ketika hanya tedapat satu Job yang sedang berjalan, job tersebut akan menggunakan keseluruhan sumber daya yang tersedia. Ketika terdapat job baru masuk untuk dieksekusi, sumber daya digunakan oleh job sebelumnya akan dibebaskan alokasinya dan ditugaskan untuk eksekusi job yang baru, sehingga setiap setiap job pada akhirnya mendapatkan jumlah sumber daya yang kira-kira sama. Tidak seperti FIFO, yang membentuk antrian Job, pada metode ini memungkinkan untuk waktu eksekusi job yang pendek selesai dieksekusi dalam waktu singkat, tanpa mengorbankan job yang lebih panjang.

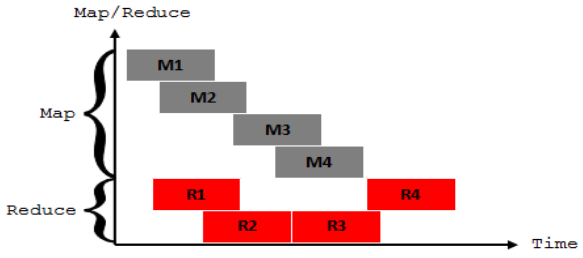

Gambar 4. Ilustrasi Fair Scheduller untuk reduce Hadoop[2]

Fair juga mampu melakukan pembagian sumber daya yang adil ,serta dapat bekerja dengan memberikan prioritas job yang selanjutnya dapat digunakan sebagai bobot untuk menentukan bagian dari total sumber daya yang harus diperoleh masing-masing job.

C.SARS (*Self-Adaptive Scheduling Algorithm for Seduce Start Time*)

Algoritma penjadwalan dapat SARS mengurangi *completion time* dan waktu yang dibutuhkan untuk proses *reduce* pada slot resources [3]. Penyimpanan slot ini tidak terjadi apada algoritma FIFO. Pengurangan *completion time* ini akandapat memaksimalkan *response time* [3]. Dengan semakin kecilnya *response time* yagng diperoleh maka akan berpengaruh dengan pada parameter *job throughput* yang akan maksimal [4]

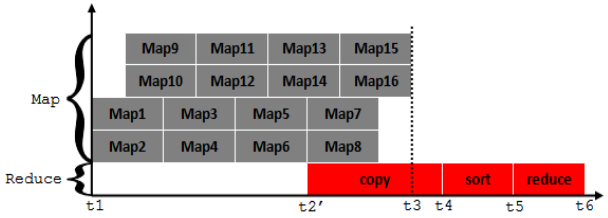

Gambar 5. Ilustrasi Scheduller SARS

Penggunaan *MapReduce* pada algoritma SARS akan dimulai cukup jauh atau setengah dari dimulainya proses map, hal ini dikarenakan algoritma SARS akan mendelay waktu *reduce* namusn sebelum map selesai yang nantinya dapat mengurangi response time [5]. Atas delay yang dilakukan pada reduce task, akan mengakibatkan jobs dalam slot resources tidak bekerja secara normal [5]. Dikarenakan menyesuaikan pengurangan waktu penjadwalan, metode ini akan mengurangi waktu yang terbuang untuk replikasi data dan mengoptimalkan pemanfaatan slot resources yang tersedia secara lebih efektif dibandingkan dengan FIFO.

COSHH adalah sebuah algoritma scheduling dalam Hadoop yang meminimalkan *mean*/*average* completion time dari job yang masuk dalam antrian[6]. Scheduler bawaan dari hadoop sendiri terlihat mengabaikan aspek heterogenitas job yang mungkin dieksekusi[6], dimana salah satu aspek yang penting dari scheduling adalah heterogenitas. Maka dari itu COSHH dibuat untuk memaksimalkan heterogenitas pada level cluster. Seperti yang dijabarkan sebelumnya COSHH dapat mengurangi *Average Completion Time* dibanding dengan Scheduler – Scheduler yang lain. Adapun arsitektur dari COSHH sendiri adalah sebagai berikut:

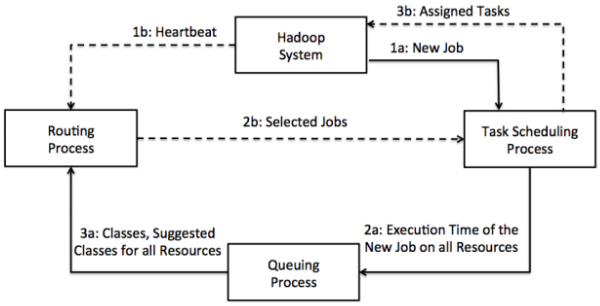

Gambar 6. Arsitektur COSHH[6]

Terdapat empat komponen utama penyusun COSHH yaitu; *Task Scheduling Process, The Queuing Process*, dan *Routing Process*. Hadoop Scheduler pada umumnya menerima dua message dari sistem Hadoop yaitu *message signal* dari user dan *heartbeat message* dari *resource* yang bebas. Ketika menerima suatu job baru maka scheduler akan memasukan job tersebut ke *queuing process* untuk menyimpan job yang datang menuju queue yang tepat[6]. Ketika menerima *heartbeat message,* scheduler akan memasukannya ke *routing process*

untuk menempatkan job ke resource yang bebas. Pada gambar di atas alur job ditandai dengan garis sedangkan alur heartbeat ditandai dengan garis putus – putus.

III. PERANCANGAN SISTEM

Pada penelitian ini fokus pada performansi metode scheduler untuk system cluster server Hadoop. Penelitian dilakukan lingkungan terbatas dengan menggunakan arsitektur MultiNode Hadoop dengan topologi sebagai berikut :

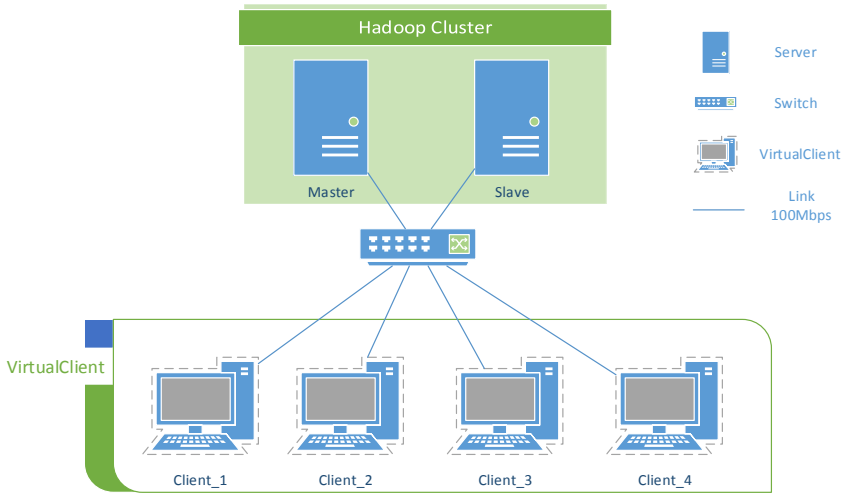

Gambar 8 . Topologi Jaringan

Dalam lingkungan uji coba, terdiri atas dua buah server, dimana salah satunya berfungsi sebagai Master node dan yang lainnya berfungsi sebagai Slave Node. Konfigurasi hadoop yang digunakan adalah multi-node, dimana Slave hanya akan berfungsi sebagai slave server saja, sedangkan untuk Master node dapat berfungsi sebagai Master server dan juga dapat bertindak sebagai slave server. Fungsi client adalah mengirimkan job yang selanjutnya akan dieksekusi disisi serverJenis job yang dikerjakan seperti pada tabel 1 berikut.

Tabel 1. Karakteristik Job

Jenis Job	Karakteristik Job
WordCount	Menghitung jumlah kata yang unik dalam sebuah data text berukuran besar. Output dari job ini adalah daftar kata beserta jumlah kemunculan kata tersebut dalam sebuah file.
Grep	Mencari kata yang ditentukan oleh user, sehingga data hasil dari grep hanya kata yang dicari user saja.
RandomTextWriter	Akan membuat suatu file text yang berukuran tertentu yang sudah didefinisikan oleh user dan untuk kemudian disimpan pada Hadoop. Job ini digunakan saat kegiatan generate data secara random dalam ukuran besar untuk keperluan penelitian selanjutnya.

Skenario yang dijalankan terdiri atas 3 skenario job utama, yang kemudian di kombinasikan berdasarkan karakteristik job yang berbeda. Hal ini ditujukan untuk melihat pengaruh scheduler terhadap type job yang homogen maupun heterogen. Tabel 2 menunjukkan kombinasi job yang digunakan dalam penelitian ini.

Tabel 2. Skenario Job

Skenario	Jenis Job	Job
1	Homogen	Wordcount
2		Grep
3		RandomTextWriter
4	Heterogen	WordCount-Grep-RandomTextWriter

Dari dataset yang disediakan, setiap skenario akan di jalankan dengan variasi jumlah job yaitu : 10,15,20,25 dan 30 job untuk setiap client nya.Adapun untuk melihat performansi scheduler

IV. HASIL PENGUJIAN

Dari percobaan yang telah dilaksanakan, perbandingan performa 4 algoritma penjadwalan yang diimplementasikan diatas hadoop, akan dibandingkan dengan 3 parameter sebagai berikut :

- *Task Failure Rate*
  Mengukur jumlah job yang gagal serta akan diulang kembali eksekusinya atau yang benar-benar gagal , kegagalan eksekusi job ini merupakan salah satu akibat dari kegagalan Hadoop dalam menyediakan resource yang diperlukan untuk eksekusi job. Satuan yang digunakan adalah *job*

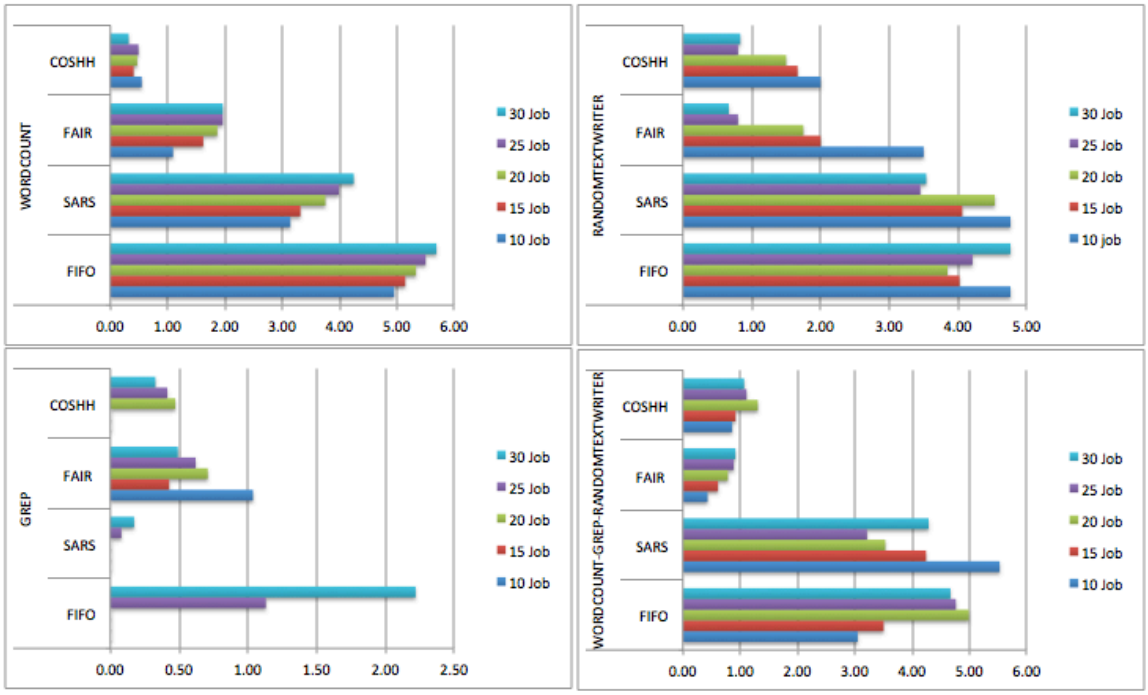

Gambar 9. Task Fail Rate

Secara keseluruhan scenario job yang dieksekusi, baik homogen maupun heterogen, terlihat bahwa Algoritma COSHH memilki rata-rata nilai *Task Failure Rate* yang paling kecil, kecuali untuk jenis job

grep dimana algoritma SARS, dimana perbedaanya berkisar antara 0-0.5 job. Hal ini dipengaruhi oleh karakteristik COSHH, dimana dalam eksekusinya mengatur jumlah *pool* atau *queue* sebelum mengeksekusi job. Hal inilah yang menyebabkan prosentasi kemungkinan terjadinya Failure pada job yang akan dieksekusi menjadi berkurang.

- *Average Completion Time*
  Parameter mengukur rata – rata dari waktu yang dibutuhkan dari suatu job. Nilai yang diperoleh merupakan total keseluruhan waktu yang dibutuhkan untuk menyelesaikan keseluruhan job dibagi dengan jumlah job yang dikerjakan [4]. Satuan yang digunakan adalah detik / *second*.

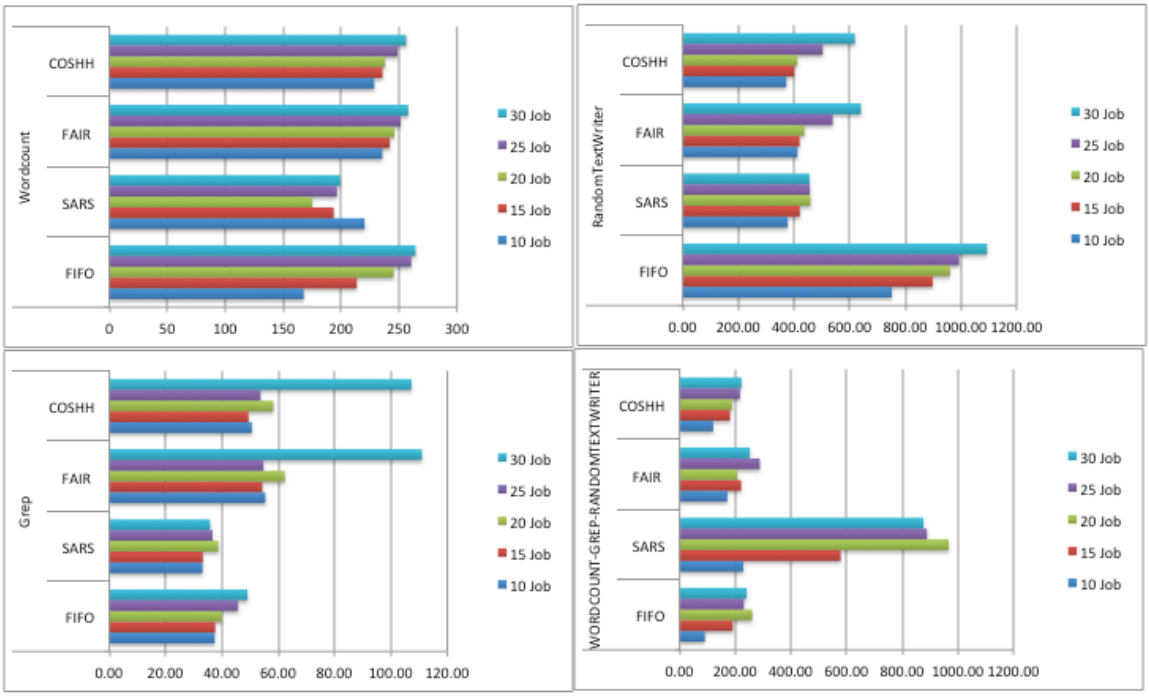

Gambar 10. Average Completion Time

Algoritma SARS memiliki nilai yang paling dijalankan pada skenario satu sampai skenario lima , atau untuk scenario job homogeny. Namun hal berlawanan pada skenario dimana job yang dieksekusi adalah job yang bertipe homogeny. Hal ini dipengaruhi karakteristik SARS yang mengatur jumlah *maps* serta *reduce* pada *tasktracer,* hal ini memerlukan komputasi yang lebih komplek ketika dikerjakan pada scenario dimana karakteristik job yang dieksekusi bermacam-macam atau *heterogen*.

- *Job Throughput*
  Parameter ini mengukur jumlah job yang telah berhasil dieksekusi dalam suatu satuan waktu. Satuan yang dipakai adalah job per menit. Seperti ditunjukkan pada gambar 11, terlihat bahwa pada parameter ini diperoleh hasil bahwa SARS memiliki job Throughput yang paling tinggi untuk seluruh scenario yang sifat jobnya homogen. Sedangkan untuk job yang sifatnya Heterogen, COSHH memiliki throughput yang paling tinggi diantara ke empat algotritma yang diuji cobakan.

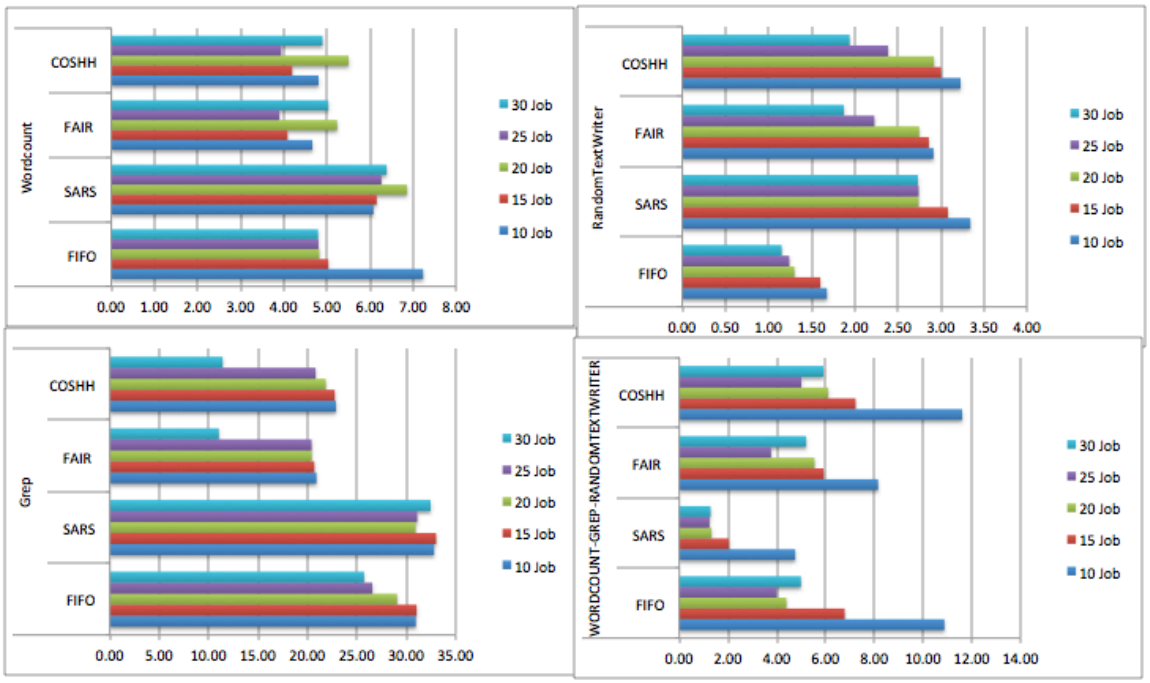

Gambar 11. Job Throughput

V. Conclusion

Hasil pengujian menunjukan bahwa algoritma SARS cocok digunakan pada penyelesaian job yang sifatnya homogen/sejenis. Hal ini ditunjukan dengan tingginya *throughput* dan *average completion time* pada saat menyelesaikan job sejenis baik *word count*, *random text writer* maupun *grep*. Sementara itu algoritma COSHH cocok digunakan pada penyelesaian job gabungan yang *heterogen*. Hal ini terlihat dari tingginya *throughput* dan kecilnya *average completion time* pada saat menyelesaikan job heterogen gabungan *word count*, *random text writer* dan *grep*.

REFERENCES

[1] D. Borthakur, "HDFS Architecture Guide," 2008.

[2] A. Rasooli and D. G. Down, "Guidelines for Selecting Hadoop Schedulers Based on System Heterogeneity," *J. Grid Comput.*, vol. 12, no. 3, pp. 499–519, Sep. 2014.

[3] S. R. Pakize, "A Comprehensive View of Hadoop MapReduce Scheduling Algorithms," *Int. J. Comput. Networks Commun. Secur.*, vol. 2, no. 9, pp. 308–317, 2014.

[4] M. Zaharia, D. Borthakur, J. Sen Sarma, K. Elmeleegy, and S. Shenker, "Job Scheduling for Multi-User MapReduce Clusters," 2009.

[5] Z. Tang, L. Jiang, J. Zhou, K. Li, and K. Li, "A self-adaptive scheduling algorithm for reduce start time," *Futur. Gener. Comput. Syst.*, vol. 43–44, pp. 51–60, 2015.

[6] A. Rasooli and D. G. Down, "COSHH: A classification and optimization based scheduler for heterogeneous Hadoop systems," *Futur. Gener. Comput. Syst.*, vol. 36, no. 36, pp. 1–15, Jul. 2014.