

SKRIPSI

WEB CRAWLING TERDISTRIBUSI PADA LINGKUNGAN HADOOP



Gabriella

NPM: 2014730013

PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNOLOGI INFORMASI DAN SAINS
UNIVERSITAS KATOLIK PARAHYANGAN
2018

UNDERGRADUATE THESIS

**DISTRIBUTED WEB CRAWLING ON HADOOP
ENVIRONMENT**



Gabriella

NPM: 2014730013

**DEPARTMENT OF INFORMATICS
FACULTY OF INFORMATION TECHNOLOGY AND SCIENCES
PARAHYANGAN CATHOLIC UNIVERSITY
2018**

LEMBAR PENGESAHAN



WEB CRAWLING TERDISTRIBUSI PADA LINGKUNGAN HADOOP

Gabriella

NPM: 2014730013

Bandung, 31 Mei 2018

Menyetujui,

Pembimbing

A handwritten signature in black ink, appearing to read "Gede Karya".

Gede Karya, M.T., CISA, IPM

Ketua Tim Penguji

A handwritten signature in black ink, appearing to read "Vania Natali".

Vania Natali, M.T.

Anggota Tim Penguji

A handwritten signature in black ink, appearing to read "Pascal Alfadian".

Pascal Alfadian, M.Comp.

Mengetahui,

Ketua Program Studi

A handwritten signature in black ink, appearing to read "Mariskha Tri Adithia".

Mariskha Tri Adithia, P.D.Eng



PERNYATAAN

Dengan ini saya yang bertandatangan di bawah ini menyatakan bahwa skripsi dengan judul:

WEB CRAWLING TERDISTRIBUSI PADA LINGKUNGAN HADOOP

adalah benar-benar karya saya sendiri, dan saya tidak melakukan penjiplakan atau pengutipan dengan cara-cara yang tidak sesuai dengan etika keilmuan yang berlaku dalam masyarakat keilmuan.

Atas pernyataan ini, saya siap menanggung segala risiko dan sanksi yang dijatuhkan kepada saya, apabila di kemudian hari ditemukan adanya pelanggaran terhadap etika keilmuan dalam karya saya, atau jika ada tuntutan formal atau non-formal dari pihak lain berkaitan dengan keaslian karya saya ini.

Dinyatakan di Bandung,
Tanggal 31 Mei 2018



Gabriella
NPM: 2014730013

ABSTRAK

Web crawler merupakan program yang melakukan *web scanning* dan *data indexing* dengan metode tertentu. Salah satu metode *crawling* yakni *distributed web crawling* yang memanfaatkan banyak agen *crawler* dengan tujuan mempercepat proses *crawling*. Data hasil *crawling* dapat berukuran besar, atau yang sering disebut sebagai *big data*, sehingga diperlukan media penyimpanan yang dapat mengolah *big data*. Untuk mengatasi masalah ini, dapat digunakan Hadoop ecosystem, seperti: HDFS dan HBase. Oleh karena itu, pada penelitian ini dikembangkan aplikasi *distributed web crawler* pada lingkungan Hadoop *Cluster* (HBase). Penelitian juga mencakup eksperimen untuk menjawab pertanyaan: (1) bagaimana pengaruh banyaknya *crawler* terhadap kecepatan *crawling*; dan (2) bagaimana kecepatan pemrosesan data menggunakan Hadoop.

Untuk menyelesaikan permasalahan ini, dilakukan analisis dan perancangan arsitektur dan algoritma *distributed crawling*. Setelah itu, dikembangkan aplikasi *web crawler* yang terdiri atas situs induk, *server crawler*, dan agen *crawler* terdistribusi. Berikutnya, disiapkan Hadoop *Cluster* (HDFS dan HBase) untuk pengujian dan pengumpulan URL *seed* untuk data uji. Langkah terakhir yang dilakukan yakni melaksanakan pengujian dan eksperimen performa *distributed crawler*.

Pengujian dilakukan untuk memastikan perangkat lunak telah berfungsi sebagaimana mestinya. Pengujian ini dilakukan berdasarkan *usecase* dan skenario yang diperoleh dari analisis kebutuhan perangkat lunak. Berdasarkan pengujian fungsional tersebut, didapat perangkat lunak sudah berjalan sebagaimana mestinya. Eksperimen dilakukan untuk melihat performa *crawler*; dilakukan dengan menjalankan aplikasi *web crawler* pada empat komputer yang tergabung dalam *cluster* Hadoop; satu *master* dan tiga *slave*, dimana masing-masing komputer menjalankan lima agen *crawler*. Ada dua eksperimen yang dilakukan, yakni eksperimen *crawling* dan eksperimen *searching*. Eksperimen *crawling* dilakukan untuk melihat bagaimana pengaruh banyaknya *crawler* dan *node* komputer pada *cluster* Hadoop yang digunakan terhadap kecepatan *crawling*. Eksperimen *searching* dilakukan untuk melihat bagaimana pengaruh banyaknya *node* komputer pada *cluster* Hadoop yang digunakan terhadap kecepatan pencarian.

Pada eksperimen *crawling*, didapatkan rata-rata kecepatan *crawling* bertambah sebesar 1.16 kali untuk setiap penambahan satu *node* dan lima agen. Pada eksperimen *searching*, didapatkan rata-rata peningkatan kecepatan pencarian adalah sebesar 1.19 kali untuk setiap penambahan satu *node*. Berdasarkan kedua hasil eksperimen tersebut, dapat disimpulkan bahwa semakin banyak agen dan komputer dalam *cluster* Hadoop yang digunakan, maka semakin cepat pula proses *crawling*. Selain itu, semakin banyak komputer dalam *cluster* Hadoop yang digunakan, semakin cepat pula waktu pencarian.

Kata-kata kunci: *web crawler*, *distributed*, Hadoop

ABSTRACT

Web crawler is a program that performs web scanning and data indexing with certain methods. One of its method is distributed web crawling that utilizes many crawler agents with the aim of speeding up the crawling process. Data from the crawling result can be large, which is often referred to as big data. Therefore, a storage media which can process a big data is required. To solve this problem, Hadoop ecosystem, such as HDFS and HBase, can be used. On this study, a web crawler application was developed on Hadoop Cluster environment (HBase). The study also includes experiments to answer: how the number of crawlers affects crawling speed; and the speed of data processing on Hadoop environment.

To solve these problems, analysis and design of distributed crawler architecture and algorithm are performed. After that, a web crawler application that consists of main site, crawler server, and distributed crawler agent was developed. Next, Hadoop Cluster (HDFS and HBase) for testing was prepared and the URL seed were collected as a test data. The last step is to conduct testing and performance experiment on the distributed crawler.

Testing is done to ensure the software is working properly. This test is based on the usecase and scenarios obtained from the software requirement analysis. Based on the functional testing, the software is found to be working properly. The experiment was conducted to see the performance of the crawler; done by running the web crawler application on four computers which were part of the Hadoop cluster; one master and three slaves, where each computer run five crawler agents. There are two experiments conducted, namely crawling experiment and searching experiment. Crawling experiment were conducted to see how the number of crawlers and computer nodes on the Hadoop cluster used affects crawling speed. The searching experiment was conducted to see how the number of computer nodes on the Hadoop cluster used affects searching speed.

Based on the crawling experiment result, the average crawling speed increased by 1.16 times for each addition of one node and five agents. Based on the searching experiment result, the average searching speed increased 1.19 times for each addition of one node. Based on these two experiments results, it can be concluded that the more agents and computers in the Hadoop cluster are used, the faster the crawling process can be done. In addition, the more computers in the Hadoop cluster are used, the faster the searching process can be done.

Keywords: web crawler, distributed, hadoop

Dipersembahkan untuk orang tua dan adik penulis

KATA PENGANTAR

Puji syukur penulis haturkan pada Tuhan yang Maha Esa atas segala berkat dan rahmat-Nya, sehingga skripsi berjudul "*Web Crawling Terdistribusi Pada Lingkungan Hadoop*" dapat penulis selesaikan dengan baik. Skripsi ini dibuat untuk melengkapi persyaratan kelulusan tingkat sarjana (S-1) di Fakultas Teknologi Informasi dan Sains Jurusan Teknik Informatika Universitas Katolik Parahyangan. Selama pembuatan skripsi ini, penulis mendapatkan bantuan dan dukungan dari berbagai pihak. Maka dari itu, pada kesempatan ini penulis hendak mengucapkan terima kasih kepada:

1. Bapak Gede Karya, M.T., CISA, IPM selaku dosen pembimbing yang telah menyediakan waktu untuk membimbing penulis selama penyusunan skripsi.
2. Ibu Vania Natali, M.T. dan Bapak Pascal Alfadian, M.Comp. selaku dosen penguji yang telah memberi kritik dan saran untuk skripsi ini.
3. Orang tua dan adik penulis yang selalu memberi doa dan dukungan selama penyusunan skripsi.
4. Sahabat dan rekan-rekan penulis yang telah banyak membantu dan memberi dukungan selama penyusunan skripsi.

Akhir kata, penulis menyadari bahwa skripsi ini belum sempurna. Namun, penulis berharap skripsi ini dapat bermanfaat bagi para pembaca yang ingin menambah wawasan ataupun melakukan penelitian yang serupa.

Bandung, Mei 2018

Penulis

DAFTAR ISI

KATA PENGANTAR	xv
DAFTAR ISI	xvii
DAFTAR GAMBAR	xix
DAFTAR TABEL	xxiii
1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	1
1.3 Tujuan	2
1.4 Batasan Masalah	2
1.5 Metodologi	2
1.6 Sistematika Pembahasan	3
2 LANDASAN TEORI	5
2.1 <i>Web Crawler</i>	5
2.1.1 Arsitektur <i>Web Crawler</i>	5
2.1.2 Algoritma <i>Web Crawler</i>	7
2.1.3 <i>File Robots.txt</i>	7
2.1.4 <i>Distributed Web Crawling</i>	8
2.2 <i>Big Data</i>	9
2.3 Hadoop	9
2.3.1 HDFS	10
2.3.2 MapReduce	11
2.3.3 HBase	13
2.4 Java 2 Enterprise Edition (J2EE)	16
2.4.1 JavaServer Pages (JSP)	17
2.4.2 Servlet	19
2.5 <i>Library Jsoup</i>	20
3 EKSPLORASI DAN ANALISIS	21
3.1 Eksplorasi Hadoop	21
3.1.1 Eksplorasi HDFS	21
3.1.2 Eksplorasi HBase	24
3.2 Analisis Masalah dan Usulan Solusi	28
3.2.1 Analisis Masalah	28
3.2.2 Usulan Solusi	28
3.3 Analisis Kebutuhan Perangkat Lunak	34
3.3.1 Deskripsi Analisis Perangkat Lunak	34
3.3.2 Diagram <i>Use Case</i> dan Skenario Situs Induk	35
3.3.3 Kebutuhan <i>Input</i> Perangkat Lunak	38

3.3.4	Kebutuhan <i>Output</i> Perangkat Lunak	38
3.3.5	Kebutuhan Atribut Pada Tabel di <i>Database</i>	38
3.3.6	Diagram Kelas Sederhana	39
4	PERANCANGAN	43
4.1	Perancangan <i>Database</i> Pada HBase	43
4.2	Desain <i>User Interface</i>	45
4.3	Diagram Kelas Rinci	51
4.3.1	Diagram Kelas <i>Crawler</i>	51
4.3.2	Diagram Kelas Situs Induk	55
4.3.3	UrlChecker	56
5	IMPLEMENTASI, PENGUJIAN, DAN EKSPERIMEN	61
5.1	Implementasi	61
5.1.1	Lingkungan Implementasi Perangkat Keras	61
5.1.2	Lingkungan Implementasi Perangkat Lunak	61
5.1.3	Implementasi <i>Database</i>	61
5.1.4	Implementasi Situs Induk	64
5.1.5	Implementasi <i>Web Crawler</i>	71
5.2	Pengujian	77
5.3	Eksperimen	79
5.3.1	Konfigurasi Lingkungan Eksperimen	79
5.3.2	Eksperimen <i>Crawling</i>	81
5.3.3	Eksperimen Pencarian <i>Term</i>	82
6	KESIMPULAN DAN SARAN	85
6.1	Kesimpulan	85
6.2	Saran	85
DAFTAR REFERENSI		87
A	KODE PROGRAM	89
A.1	Kode Program <i>Web Crawler</i>	89
A.1.1	<i>Package engine</i>	89
A.1.2	<i>Package database</i>	94
A.2	Kode Program Situs Induk	97
A.2.1	<i>Package engine</i>	97
A.2.2	<i>Package database</i>	100
A.2.3	<i>Package servlet</i>	104
B	HASIL EKSPERIMEN	109
B.1	Hasil Eksperimen Pencarian <i>Term</i>	109
B.2	Hasil Perhitungan Banyak URL	117
B.3	Penyimpanan Pada Hadoop	118
B.4	Foto dan <i>Screenshoot</i> Eksperimen <i>Crawling</i>	123

DAFTAR GAMBAR

2.1	Arsitektur <i>Web Crawler</i>	6
2.2	Isi <i>File robots.txt</i>	8
2.3	<i>High-level Hadoop Architecture</i>	10
2.4	Arsitektur HDFS	11
2.5	Mekanisme Kerja MapReduce	12
2.6	Mekanisme <i>Shuffle and Sort</i>	13
2.7	Komponen RegionServer	14
2.8	Arsitektur HBase	15
2.9	Skema Tabel HBase	15
2.10	Pemrosesan JSP	18
2.11	JSP <i>Life Cycle</i>	19
2.12	Arsitektur Servlet	19
3.1	Menghapus <i>Metadata</i> di NameNode	21
3.2	Memulai HDFS dan YARN	21
3.3	Potongan Informasi NameNode di <i>Command Prompt</i>	21
3.4	Potongan Informasi DataNode di <i>Command Prompt</i>	22
3.5	Potongan Informasi ResourceManager di <i>Command Prompt</i>	22
3.6	Potongan Informasi NodeManager di <i>Command Prompt</i>	22
3.7	<i>Overview dfshealth</i>	22
3.8	<i>Summary dfshealth</i>	23
3.9	Informasi DataNode	23
3.10	Memasukkan <i>File</i> ke HDFS dan <i>Me-list File</i>	23
3.11	Operasi <i>Wordcount</i> Menggunakan MapReduce di <i>Command Prompt</i>	24
3.12	Menghentikan HDFS dan YARN	24
3.13	Menjalankan HBase	24
3.14	Memulai HBase <i>Shell</i>	25
3.15	Melihat Status <i>Cluster</i> , Versi, dan <i>Current User</i> HBase dengan <i>Shell</i>	25
3.16	Membuat Tabel Menggunakan HBase <i>Shell</i>	25
3.17	Informasi Tabel HBase	25
3.18	Informasi RegionServer	26
3.19	Memasukkan Data ke Tabel Menggunakan HBase <i>Shell</i> (1)	26
3.20	Memasukkan Data ke Tabel Menggunakan HBase <i>Shell</i> (2)	26
3.21	Melihat Data Tabel "table1" Menggunakan <i>Command scan</i> di HBase <i>Shell</i>	26
3.22	Menghentikan HBase	27
3.23	Meng- <i>import</i> HBase <i>Library</i> Pada Program Java	27
3.24	Membuat Koneksi ke HBase Menggunakan HBase API	27
3.25	Membuat Tabel Menggunakan HBase API	28
3.26	Memasukkan Data ke Tabel Menggunakan HBase API	28
3.27	Melakukan <i>scan</i> Tabel Menggunakan HBase API	28
3.28	<i>Flowchart</i> Proses <i>Distributed Crawling</i>	32
3.29	Arsitektur <i>Distributed Web Crawler</i>	34

3.30	<i>Use Case Situs Induk</i>	35
3.31	Diagram Kelas Sederhana (Situs Induk)	40
3.32	Diagram Kelas Sederhana (<i>Web Crawler</i>)	42
4.1	Tampilan <i>Homepage</i>	45
4.2	Tampilan <i>Pop-up Registrasi</i>	46
4.3	Tampilan <i>Pop-up Log in</i>	46
4.4	Tampilan Halaman <i>Admin Menu</i>	47
4.5	Tampilan <i>Pop-up Add URL</i>	47
4.6	Tampilan Halaman <i>Frontier</i>	48
4.7	Tampilan Halaman <i>Web Repository</i>	49
4.8	Tampilan Halaman <i>Search Result</i> Untuk Admin	50
4.9	Tampilan Halaman <i>Search Result</i> Untuk User	50
4.10	Tampilan Halaman <i>Content</i>	51
4.11	Diagram Kelas <i>Crawler (Package engine)</i>	52
4.12	Diagram Kelas <i>Crawler (Package database)</i>	54
4.13	Diagram Kelas Situs Induk (<i>Package engine</i>)	56
4.14	Diagram Kelas Situs Induk (<i>Package database</i>)	57
4.15	Diagram Kelas Situs Induk (<i>Package servlet</i>)	59
5.1	Membuat Tabel <i>Frontier</i> Menggunakan HBase API	62
5.2	Membuat Tabel <i>Web Repository</i> dan <i>Secondary Indexer</i> -nya Menggunakan HBase API	62
5.3	Membuat Tabel Admin Menggunakan HBase API	63
5.4	Memasukkan Data ke Tabel <i>Frontier</i> Menggunakan HBase API	63
5.5	Memasukkan Data ke Tabel <i>Web Repository</i> Menggunakan HBase API	63
5.6	Memasukkan Data ke Tabel Admin Menggunakan HBase API	64
5.7	Tampilan <i>Homepage</i>	64
5.8	Tampilan <i>Pop-up Register</i>	65
5.9	Tampilan <i>Pop-up Log in</i>	65
5.10	Tampilan Admin <i>Menu</i>	66
5.11	Tampilan <i>Pop-up Add URL File</i>	66
5.12	Tampilan Halaman <i>Frontier</i>	67
5.13	Tampilan Halaman <i>Frontier</i> (Kosong)	67
5.14	Tampilan Halaman <i>Repository</i>	68
5.15	Tampilan Halaman <i>Repository</i> (Kosong)	68
5.16	Tampilan Halaman Hasil Pencarian (Admin)	69
5.17	Tampilan Halaman Hasil Pencarian (User)	69
5.18	Tampilan Halaman Hasil Pencarian Kosong (Admin)	69
5.19	Tampilan Halaman Hasil Pencarian Kosong (User)	70
5.20	Tampilan Halaman Konten (Admin)	70
5.21	Tampilan Halaman Konten (User)	71
5.22	Pengecekan Konten Pada Proses Pencarian <i>Term</i>	71
5.23	Memeriksa, Mengambil, dan Menandai URL dari <i>Frontier</i>	72
5.24	Memasukkan URL ke <i>Frontier</i>	73
5.25	Memasukkan URL ke <i>Web Repository</i>	73
5.26	Proses Ekstraksi URL	74
5.27	Menandai URL Untuk Proses <i>Re-crawling</i>	75
5.28	Meng-update Data Hasil <i>Crawling</i> Pada Tabel <i>Web Repository</i> dan <i>Secondary Indexer</i> -nya	75
5.29	Inisialisasi <i>Socket</i> Milik Server	76
5.30	Inisialisasi <i>Socket</i> Milik Agen	76

5.31 Inisialisasi <i>Reader</i> dan <i>Writer</i>	76
5.32 Konfigurasi Jaringan Internet	80
5.33 Konfigurasi Perangkat Lunak	81
5.34 Banyaknya URL Hasil <i>Crawling</i> dengan Penggunaan 1, 2, 3, dan 4 <i>Node</i>	81
5.35 Perbandingan Banyak <i>Node</i> Terhadap Kecepatan Pencarian <i>Term</i>	82
B.1 Pencarian dengan 1 <i>Node</i> Saat URL bBerjumlah 1105 Buah	109
B.2 Pencarian dengan 2 <i>Node</i> Saat URL bBerjumlah 1105 Buah	110
B.3 Pencarian dengan 3 <i>Node</i> Saat URL bBerjumlah 1105 Buah	110
B.4 Pencarian dengan 4 <i>Node</i> Saat URL bBerjumlah 1105 Buah	111
B.5 Pencarian dengan 1 <i>Node</i> Saat URL Berjumlah 1332 Buah	111
B.6 Pencarian dengan 2 <i>Node</i> Saat URL Berjumlah 1332 Buah	112
B.7 Pencarian dengan 3 <i>Node</i> Saat URL Berjumlah 1332 Buah	112
B.8 Pencarian dengan 4 <i>Node</i> Saat URL Berjumlah 1332 Buah	113
B.9 Pencarian dengan 1 <i>Node</i> Saat URL Berjumlah 1568 Buah	113
B.10 Pencarian dengan 2 <i>Node</i> Saat URL Berjumlah 1568 Buah	114
B.11 Pencarian dengan 3 <i>Node</i> Saat URL Berjumlah 1568 Buah	114
B.12 Pencarian dengan 4 <i>Node</i> Saat URL Berjumlah 1568 Buah	115
B.13 Pencarian dengan 1 <i>Node</i> Saat URL Berjumlah 1721 Buah	115
B.14 Pencarian dengan 2 <i>Node</i> Saat URL Berjumlah 1721 Buah	116
B.15 Pencarian dengan 3 <i>Node</i> Saat URL Berjumlah 1721 Buah	116
B.16 Pencarian dengan 4 <i>Node</i> Saat URL Berjumlah 1721 Buah	117
B.17 Perhitungan Banyak URL Untuk Eksperimen dengan 1 <i>Node</i>	117
B.18 Perhitungan Banyak URL Untuk Eksperimen dengan 2 <i>Node</i>	117
B.19 Perhitungan Banyak URL Untuk Eksperimen dengan 3 <i>Node</i>	117
B.20 Perhitungan Banyak URL Untuk Eksperimen dengan 4 <i>Node</i>	118
B.21 Melihat Data Penyimpanan Tabel Admin Melalui Hadoop UI di <i>Port 50070</i>	118
B.22 Melihat Data Penyimpanan Tabel <i>Frontier</i> Melalui Hadoop UI di <i>Port 50070</i>	118
B.23 Melihat Data Penyimpanan Tabel <i>Web Repository</i> Melalui Hadoop UI di <i>Port 50070</i>	119
B.24 Melihat Data Penyimpanan Tabel <i>Secondary Indexer</i> untuk <i>web repository</i> Melalui Hadoop UI di <i>Port 50070</i>	119
B.25 <i>File</i> Data <i>columnfamily depth</i> di Tabel <i>Frontier</i>	120
B.26 <i>File</i> Data <i>columnfamily crawling</i> di Tabel <i>Frontier</i>	120
B.27 <i>File</i> Data <i>columnfamily page</i> di Tabel <i>Web Repository</i>	121
B.28 <i>File</i> Data <i>columnfamily agent</i> di Tabel <i>Web Repository</i>	121
B.29 <i>File</i> Data <i>columnfamily depth</i> di Tabel <i>Web Repository</i>	122
B.30 <i>File</i> Data <i>columnfamily idxvalue</i> di Tabel <i>Secondary Indexer</i> Milik <i>Web Repository</i>	122
B.31 Foto Eksperimen <i>Crawling</i> (1)	123
B.32 Foto Eksperimen <i>Crawling</i> (2)	123
B.33 <i>Screenshot</i> Proses Eksperimen <i>Crawling 1 Node</i> (Komputer <i>master</i>)	124
B.34 <i>Screenshot</i> Proses Eksperimen <i>Crawling 2 Node</i> (Komputer <i>master</i>)	124
B.35 <i>Screenshot</i> Proses Eksperimen <i>Crawling 3 Node</i> (Komputer <i>master</i>)	125
B.36 <i>Screenshot</i> Proses Eksperimen <i>Crawling 4 Node</i> (Komputer <i>master</i>)	125

DAFTAR TABEL

3.1	Perbandingan Penelusuran URL dengan Metode BFS dan DFS	29
3.2	Skenario <i>Log in</i>	36
3.3	Skenario Register	36
3.4	Skenario Memasukkan URL	36
3.5	Skenario Melihat <i>Frontier</i>	37
3.6	Skenario Melihat <i>Web Repository</i>	37
3.7	Skenario <i>Search Term</i>	38
3.8	Atribut Pada Tabel <i>Frontier</i>	39
3.9	Atribut Pada Tabel <i>Web Repository</i>	39
3.10	Atribut Pada Tabel Admin	39
4.1	Tabel <i>Frontier</i> (<i>RowKey</i> dan <i>ColumnFamily crawling</i>)	43
4.2	Tabel <i>Frontier</i> (<i>ColumnFamily depth</i>)	44
4.3	Tabel <i>Web Repository</i> (<i>RowKey</i> , <i>ColumnFamily page</i> , dan <i>ColumnFamily agent</i>) .	44
4.4	Tabel <i>Web Repository</i> (<i>ColumnFamily depth</i>)	44
4.5	Tabel <i>Repository Indexer</i>	44
4.6	Tabel Admin	45
5.1	Hasil Pengujian Situs Induk	78
5.2	<i>Hostname</i> dan IP <i>Address</i> Komputer Pengujian	79
5.3	Peningkatan Banyaknya Hasil <i>Crawling</i>	82
5.4	Peningkatan Kecepatan Pencarian Untuk 1105 URL	83
5.5	Peningkatan Kecepatan Pencarian Untuk 1332 URL	83
5.6	Peningkatan Kecepatan Pencarian Untuk 1568 URL	84
5.7	Peningkatan Kecepatan Pencarian Untuk 1721 URL	84

BAB 1

PENDAHULUAN

Pada bab ini dilakukan pembahasan mengenai latar belakang, rumusan masalah, tujuan, batasan masalah, metodologi, dan sistematika pembahasan.

1.1 Latar Belakang

Pada jaman sekarang, orang-orang diberi kemudahan dalam mencari informasi dengan adanya *web*. *Web* atau *World Wide Web* merupakan suatu "ruang" informasi yang berisi *resource* dalam berbagai bentuk, misalnya dokumen dan gambar. Tiap *web resource* berada pada suatu tempat yang disebut halaman *web*, dan memiliki alamat atau *Uniform Resource Locator* (URL) sebagai penanda lokasi halaman *web* tersebut. Agar suatu halaman dapat di-retrieve ketika melakukan pencarian, *search engine* yang digunakan harus terlebih dahulu mengumpulkan informasi mengenai halaman tersebut. Pengumpulan informasi ini dilakukan dengan menggunakan *web crawler*.

Web crawler merupakan program yang melakukan *web scanning* dan *data indexing* dengan metode tertentu. Ada berbagai metode *crawling*, antara lain: *batch and incremental crawling*; *deep crawling*; *distributed crawling*; *focused crawling*; dll. Data yang dihasilkan dari proses *crawling* berupa URL atau halaman-halaman *web*. Pada skripsi ini, dibuat *web crawler* dengan metode *distributed crawling*. *Distributed web crawling* memanfaatkan banyak *crawler* untuk melakukan proses *crawling* dengan tujuan untuk mempercepat proses *crawling*.

Data hasil *crawling* dapat berukuran besar ataupun berjumlah banyak. Jenis data seperti ini sering disebut sebagai *big data*. Oleh karena itu, diperlukan suatu media penyimpanan yang dapat memproses atau mengolah *big data*. Hadoop merupakan salah satu *framework* yang digunakan untuk penyimpanan terdistribusi dan pemrosesan *big data*. Inti dari Hadoop terdiri atas bagian penyimpanan yang disebut *Hadoop Distributed File System* (HDFS) dan bagian pemrosesan yang menggunakan model pemrograman MapReduce.

Aplikasi *distributed web crawler* yang dikembangkan memanfaatkan teknologi HBase, yakni *database* Hadoop yang berjalan diatas HDFS. Oleh karena *web crawler* yang dibuat menggunakan metode *distributed web crawling* dan memanfaatkan Hadoop sebagai media penyimpanan data, maka dilakukan pula eksperimen untuk menjawab pertanyaan: (1) bagaimana pengaruh banyaknya *crawler* terhadap kecepatan *crawling*; dan (2) bagaimana kecepatan pemrosesan data menggunakan Hadoop.

1.2 Rumusan Masalah

Salah satu masalah dalam *web crawling* adalah proses yang memerlukan waktu yang cukup lama. Untuk itu, pada skripsi ini ingin diselesaikan masalah peningkatan kecepatan *crawling* dengan agen terdistribusi. Oleh karena itu, permasalahan dapat dirumuskan sebagai berikut:

1. Bagaimana mekanisme pembagian tugas dan koordinasi antar agen sehingga bisa meningkatkan kecepatan *crawling*?

2. Bagaimana mekanisme penyimpanan informasi oleh masing-masing agen pada lingkungan *file system* terdistribusi Hadoop?

1.3 Tujuan

Tujuan dari skripsi ini adalah sebagai berikut:

1. Memahami mekanisme pembagian tugas dan koordinasi antar agen sehingga bisa meningkatkan kecepatan *crawling*.
2. Memahami mekanisme penyimpanan data oleh masing-masing agen pada lingkungan *file system* terdistribusi Hadoop.
3. Membangun perangkat lunak *web crawler* dengan metode *distributed web crawling* yang memanfaatkan Hadoop sebagai media penyimpanan URL.
4. Melakukan eksperimen untuk melihat pengaruh banyaknya agen dan *node* komputer pada *cluster* Hadoop terhadap kecepatan *crawling* dan pencarian.

1.4 Batasan Masalah

Karena fokus penelitian pada skripsi ini adalah mengenai kecepatan *crawling* dan mekanisme penyimpanan hasil *crawling* pada lingkungan Hadoop, maka batasan-batasan berikut diterapkan pada aplikasi yang dikembangkan:

1. Proses *crawling* tidak memproses *crawler policy*. *Crawler policy* memiliki aturan *politeness* yang memungkinkan suatu *web* tidak bisa di-*crawl* oleh *web crawler*. Jika aturan ini diproses maka keakuratan hasil penelitian kecepatan *crawling* dan pemrosesan data dapat berkurang karena bisa saja ada URL yang seharusnya dapat diproses, tetapi karena *policy* tersebut akhirnya URL tidak jadi diproses.
2. Penelusuran URL hanya berdasarkan HTML. Penelusuran *active link* seperti *javascript* tidak akan dilakukan karena memerlukan teknik penelusuran yang berbeda dan tidak terkait fokus penelitian dari skripsi ini.
3. Hasil yang disimpan berupa teks yang terdapat pada halaman *web*. Penyimpanan *tag* diperlukan jika yang dibuat adalah *search engine*, yang berada diluar fokus penelitian pada skripsi ini.

1.5 Metodologi

Berikut ini adalah langkah-langkah yang dilakukan dalam membuat perangkat lunak:

1. Studi pustaka tentang konsep *web crawler*.
2. Studi pustaka dan eksplorasi tentang sistem terdistribusi berbasis Hadoop.
3. Studi teknik *distributed crawling*.
4. Studi teknik penyimpanan pada Hadoop.
5. Menganalisis pemilihan penyimpanan pada Hadoop.
6. Mengembangkan perangkat lunak *web crawler* yang terdiri atas situs induk, *server crawler* dan agen *crawler*.
7. Melaksanakan pengujian dan eksperimen performa pada perangkat lunak.

1.6 Sistematika Pembahasan

Sistematika pembahasan dalam skripsi ini adalah sebagai berikut:

1. Bab 1 Pendahuluan

Bab ini membahas tentang latar belakang, rumusan masalah, tujuan, batasan masalah, metodologi, dan sistematika pembahasan.

2. Bab 2 Landasan Teori

Bab ini membahas tentang teori-teori yang menunjang pengembangan perangkat lunak, antara lain teori *web crawler*, *big data*, Hadoop, Java 2 *Enterprise Edition*, dan *library jsoup*.

3. Bab 3 Eksplorasi dan Analisis

Bab ini membahas tentang eksplorasi Hadoop, analisis masalah dan usulan solusi, serta analisis kebutuhan perangkat lunak.

4. Bab 4 Perancangan

Bab ini membahas tentang perancangan *User Interface* dan *database*, serta diagram kelas rinci.

5. Bab 5 Implementasi, Pengujian, dan Eksperimen

Bab ini membahas implementasi, pengujian, dan eksperimen.

6. Bab 6 Kesimpulan dan Saran

Bab ini membahas tentang kesimpulan yang didapatkan dan saran yang dapat diberikan berdasarkan hasil analisis, perancangan, implementasi, pengujian, dan eksperimen yang telah dilakukan.