

マイクロソフトと 大規模データ処理

2012年4月19日

佐々木邦暢 (@ksasakims)

日本マイクロソフト株式会社

本日の内容

マイクロソフトとビッグデータ

弊社内での大規模データ処理事例

Apache HadoopのWindows対応と関連技術

Windows 向けの調整と機能追加を
Apache ヘフィードバック

WindowsでHadoopを活用する時代に向けて

変わりゆくマイクロソフトと Windows

本日の内容

マイクロソフトとビッグ データ

弊社内での大規模データ処理事例

Apache HadoopのWindows対応と関連技術

Windows 向けの調整と機能追加を
Apache ヘフィードバック

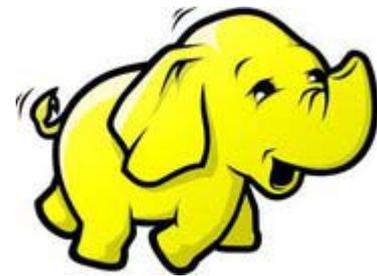
WindowsでHadoopを活用する時代に向けて

変わりゆくマイクロソフトと Windows

Big Data

ビッグデータ

Apache Hadoop



しかし
その前に

マイクロソフトは
どうなの？



ユニーク
ユーザー
4億6千万



月間 PV
42 億



Windows Live™
Hotmail.

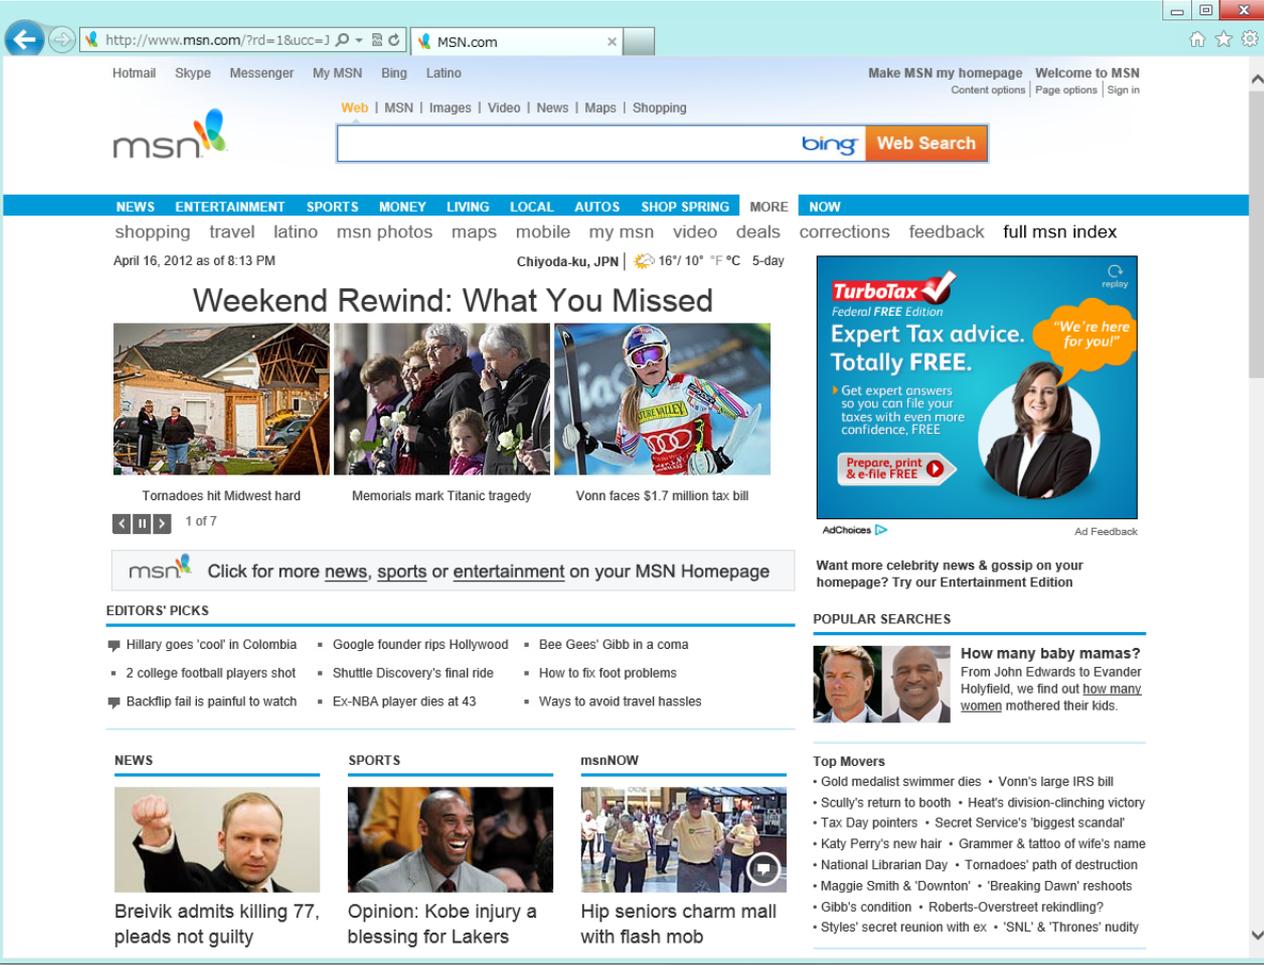
3億6千万
ユーザー

Windows Live™

Hotmail
受信トレイ (3)

- フォルダー
 - 迷惑メール
 - 下書き
 - 送信済み
 - ごみ箱
- Microsoft (4)
 - Twitter (12)
 - フォルダーの新規作成
- クイック分類
 - Office ファイル
 - フラグ付き (1)
 - 写真付き (1)
 - カテゴリの新規作成
- Messenger
 - Messenger にサインイン
- ホーム
 - アドレス帳
 - カレンダー

ネットショッピング用の
エイリアスを作れば
受信トレイがスッキリ!



http://www.msn.com/?rd=1&ucc=J MSN.com

Hotmail Skype Messenger My MSN Bing Latino

Make MSN my homepage Welcome to MSN

Web | MSN | Images | Video | News | Maps | Shopping

bing Web Search

NEWS ENTERTAINMENT SPORTS MONEY LIVING LOCAL AUTOS SHOP SPRING MORE NOW

shopping travel latino msn photos maps mobile my msn video deals corrections feedback full msn index

April 16, 2012 as of 8:13 PM Chiyoda-ku, JPN 16° 10' °F °C 5-day

Weekend Rewind: What You Missed



Tornadoes hit Midwest hard



Memorials mark Titanic tragedy



Vonn faces \$1.7 million tax bill

1 of 7

Click for more [news](#), [sports](#) or [entertainment](#) on your MSN Homepage

EDITORS' PICKS

- Hillary goes 'cool' in Colombia
- Google founder rips Hollywood
- Bee Gees' Gibb in a coma
- 2 college football players shot
- Shuttle Discovery's final ride
- How to fix foot problems
- Backflip fail is painful to watch
- Ex-NBA player dies at 43
- Ways to avoid travel hassles

NEWS



Breivik admits killing 77, pleads not guilty

SPORTS



Opinion: Kobe injury a blessing for Lakers

msnNOW



Hip seniors charm mall with flash mob

詳しくはこちら

広告を閉じる

© 2012 Microsoft 使用条件 プライバシー 広告について 広告 開発者向け情報 (英語) ヘルプセンター ご意見ご感想 日本語



TurboTax
Federal FREE Edition
Expert Tax advice.
Totally FREE.
Get expert answers so you can file your taxes with even more confidence. FREE
Prepare, print & e-file FREE

AdChoices Ad Feedback

Want more celebrity news & gossip on your homepage? Try our Entertainment Edition

POPULAR SEARCHES



How many baby mamas?
From John Edwards to Evander Holyfield, we find out how many women mothered their kids.

Top Movers


- Gold medalist swimmer dies
- Vonn's large IRS bill
- Scully's return to booth
- Heat's division-clinching victory
- Tax Day pointers
- Secret Service's 'biggest scandal'
- Katy Perry's new hair
- Grammer & tattoo of wife's name
- National Librarian Day
- Tornadoes' path of destruction
- Maggie Smith & 'Downton'
- 'Breaking Dawn' reshoots
- Gibb's condition
- Roberts-Overstreet rekindling?
- Styles' secret reunion with ex
- 'SNL' & 'Thrones' nudity



1日あたり
1億4千万
検索

1検索あたり
20KB 記録

SERVERNAME
CLIENTIP
USERAGENT
REFERRER
TARGET
etc...



なんだかんだで
1日 2PBぐらい
生成しています

そのデータを
格納/分析
するための

仕組みを
もっています

Cosmos

データのリポジトリ

- 様々なデータを蓄えます
- Web のインデックス
- Big のアクセスログ
- ツールバーのログ
- その他諸々のログ

並列計算のための基盤

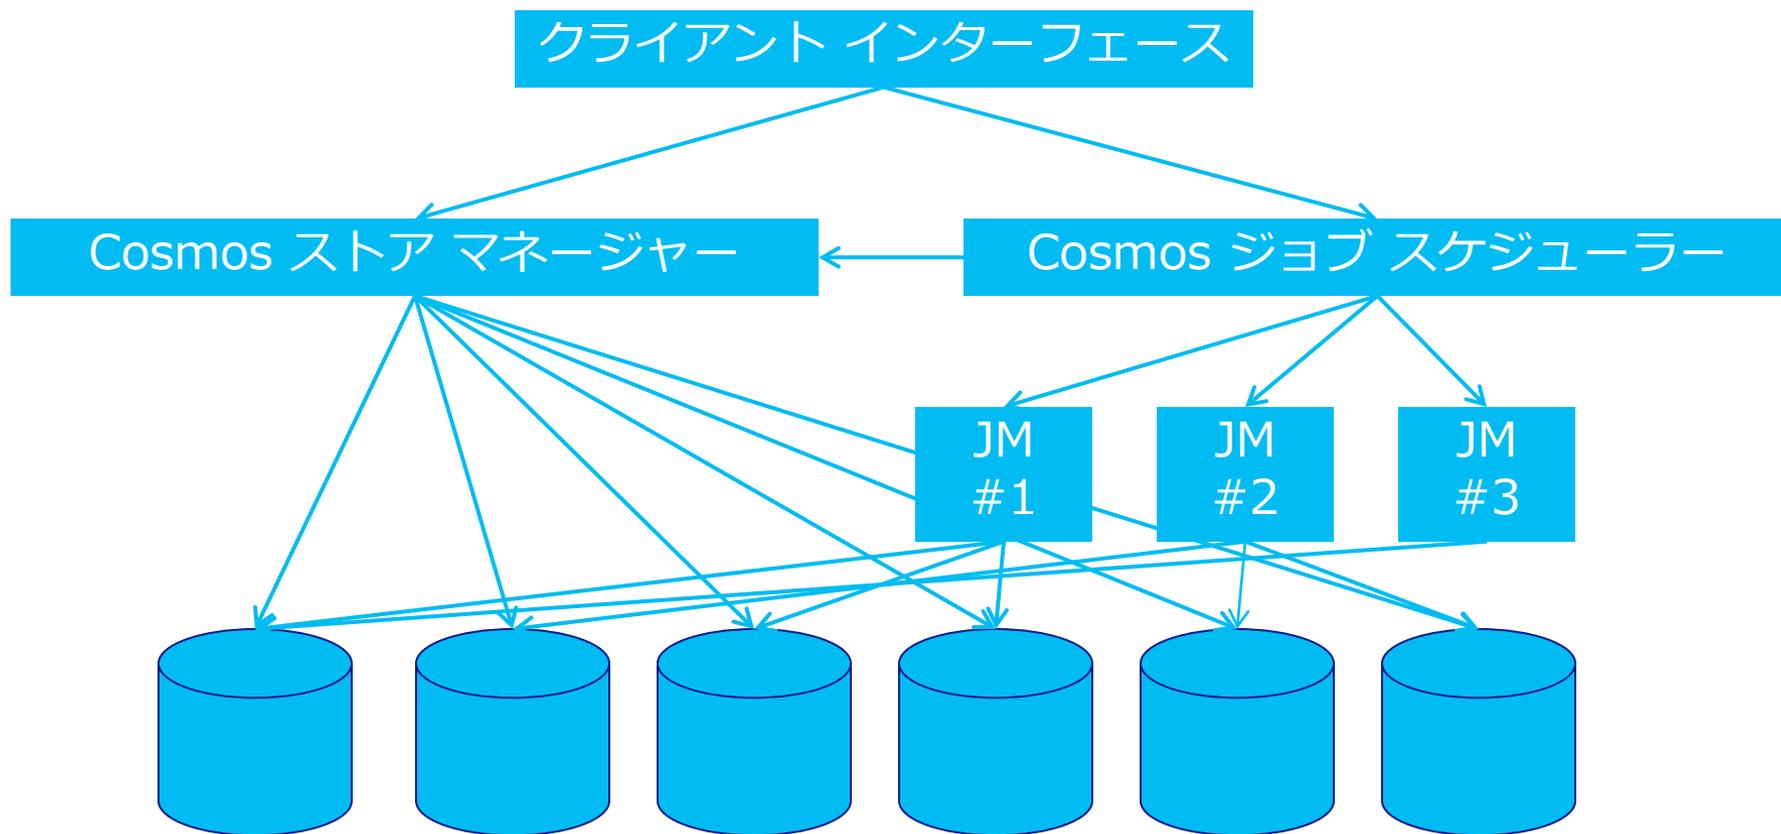
- 自身の分散ファイルシステムに蓄えられた種々のデータを分析するための実行環境

言ってみれば Cosmos とは

- Google の GFS, Hadoop の HDFS 的な分散ファイルシステム
- Big Data 向けの No SQL データストア
- 洗練された MapReduce 基盤
- Hadoop, Pig, Hive に相当する機能も持っています
- Microsoft 社内に多くのユーザーを持ち、大きなコミュニティが形成されています



Cosmos 概念図



Scope - Architecture

- SCOPE
(**S**tructured **C**omputations **O**ptimized for **P**arallel Execution)
- SQL ライクなクエリの中に C# コードを埋め込むことができる。



SCOPE – 例 1

```
a = VIEW "/shares/logdata/weblogs/weblogs.view" PARAMS
(startDate="2011-04-01", endDate="2011-04-30");
```

```
b = EXTRACT url
FROM "/my/urllist.txt"
USING DefaultTextExtractor;
```

```
SELECT query, GetFirstClickedUrl(clicks) AS clickedUrl
FROM a
WHERE HasClicks(clicks);
```

```
SELECT b.url, a.query
FROM a INNER JOIN b ON a.clickedUrl == b.url;
```

```
OUTPUT c
TO "/my/outputdata/queriesforurls.txt";
```

SCOPE – 例 2

```
a = VIEW "/shares/logdata/weblogs/weblogs.view" PARAMS  
(startDate="2011-04-01", endDate="2011-04-30");
```

```
b = EXTRACT url  
FROM "/my/urllist.txt"  
USING DefaultTextExtractor;
```

```
a = SELECT query, GetFirstClickedUrl(clicks) AS clickedUrl  
FROM a  
WHERE HasClicks(clicks);
```

```
c = SELECT b.url, a.query  
FROM a INNER JOIN b ON a.clickedUrl == b.url;
```

```
OUTPUT c  
TO "/my/outputdata/queriesforurls.txt";
```

SCOPE: Easy and Efficient Parallel Processing of Massive Data Sets

Ronnie Chaiken, Bob Jenkins, Per-Åke Larson, Bill Ramsey,
Darren Shakib, Simon Weaver, Jingren Zhou
Microsoft Corporation

{rchaiken, bobjen, palarson, brams, darrens, sweaver, jrzhou}@microsoft.com

ABSTRACT

Companies providing cloud-scale services have an increasing need to store and analyze massive data sets such as search logs and click streams. For cost and performance reasons, processing is typically done on large clusters of shared-nothing commodity machines. It is imperative to develop a programming model that hides the complexity of the underlying system but provides flexibility by allowing users to extend functionality to meet a variety of requirements.

In this paper, we present a new declarative and extensible scripting language, SCOPE (Structured Computations Optimized for Parallel Execution), targeted for this type of massive data analysis. The language is designed for ease of use with no explicit parallelism, while being amenable to efficient parallel execution on large clusters. SCOPE borrows several features from SQL. Data is modeled as sets of rows composed of typed columns. The select statement is retained with inner joins, outer joins, and aggregation allowed. Users can easily define their own functions and implement their own versions of operators: extractors (parsing and constructing rows from a file), processors (row-wise processing), reducers (group-wise processing), and combiners (combining rows from two inputs). SCOPE supports nesting of expressions but also allows a computation to be specified as a series of steps, in a manner often preferred by programmers. We also describe how scripts are compiled into efficient, parallel execution plans and executed on large clusters.

1. INTRODUCTION

Internet companies store and analyze massive data sets, such as search logs, web content collected by crawlers, and click streams collected from a variety of web services. Such analysis is becoming increasingly valuable for business in a variety of ways, for example, to improve service quality and support novel features, to detect changes in patterns over time, and to detect fraudulent activity.

Due to the size of these data sets, traditional parallel database solutions can be prohibitively expensive. To be able to perform this type of web-scale analysis in a cost-effective manner, several

companies have developed distributed data storage and processing systems on large clusters of shared-nothing commodity servers, including Google's File System [8], Bigtable [3], Map-Reduce [5], Hadoop [1], Yahoo!'s Pig system [2], Ask.com's Neptune [4], and Microsoft's Dryad [6]. A typical cluster consists of hundreds or thousands of commodity machines connected via a high-bandwidth network. It is challenging to design a programming model that enables users to easily write programs that can efficiently and effectively utilize all resources in such a cluster and achieve maximum degree of parallelism.

The *Map-Reduce* programming model provides a good abstraction of group-by-aggregation operations over a cluster of machines. The programmer provides a map function that performs grouping and a reduce function that performs aggregation. The underlying run-time system achieves parallelism by partitioning the data and processing different partitions concurrently using multiple machines.

However, this model has its own set of limitations. Users are forced to map their applications to the map-reduce model in order to achieve parallelism. For some applications this mapping is very unnatural. Users have to provide implementations for the map and reduce functions, even for simple operations like projection and selection. Such custom code is error-prone and hardly reusable. Moreover, for complex applications that require multiple stages of map-reduce, there are often many valid evaluation strategies and execution orders. Having users implement (potentially multiple) map and reduce functions is equivalent to asking users specify physical execution plans directly in database systems. The user plans may be suboptimal and lead to performance degradation by orders of magnitude.

In this paper, we present a new scripting language, SCOPE (Structured Computations Optimized for Parallel Execution), targeted for large-scale data analysis that is under development at Microsoft. Many users are familiar with relational data and SQL. SCOPE intentionally builds on this knowledge but with simplifications suited for the new execution environment. Users familiar with SQL require little or no training to use SCOPE. Like SQL, data is modeled as sets of rows composed of typed columns. Every rowset has a well-defined schema. The SCOPE runtime provides implementations of many standard physical operators, saving users from implementing similar functionality repetitively. SCOPE is being used daily for a variety of data analysis and data mining applications inside Microsoft.

SCOPE is a declarative language. It allows users to focus on the data transformations required to solve the problem at hand and hides the complexity of the underlying platform and implementation details. The SCOPE compiler and optimizer are responsible for generating an efficient execution plan and the runtime for executing the plan with minimal overhead.

Permission to copy without fee all or part of this material is granted provided that the copies are not made or distributed for direct commercial advantage, the VLDB copyright notice and the title of the publication and its date appear, and notice is given that copying is by permission of the Very Large Database Endowment. To copy otherwise, or to republish, to post on servers or to redistribute to lists, requires a fee and/or special permissions from the publisher, ACM.

VLDB '08, August 24-30, 2008, Auckland, New Zealand.
Copyright 2008 VLDB Endowment, ACM 000-0-00000-000-0/00/00.

本日の内容

マイクロソフトとビッグデータ

弊社内での大規模データ処理事例

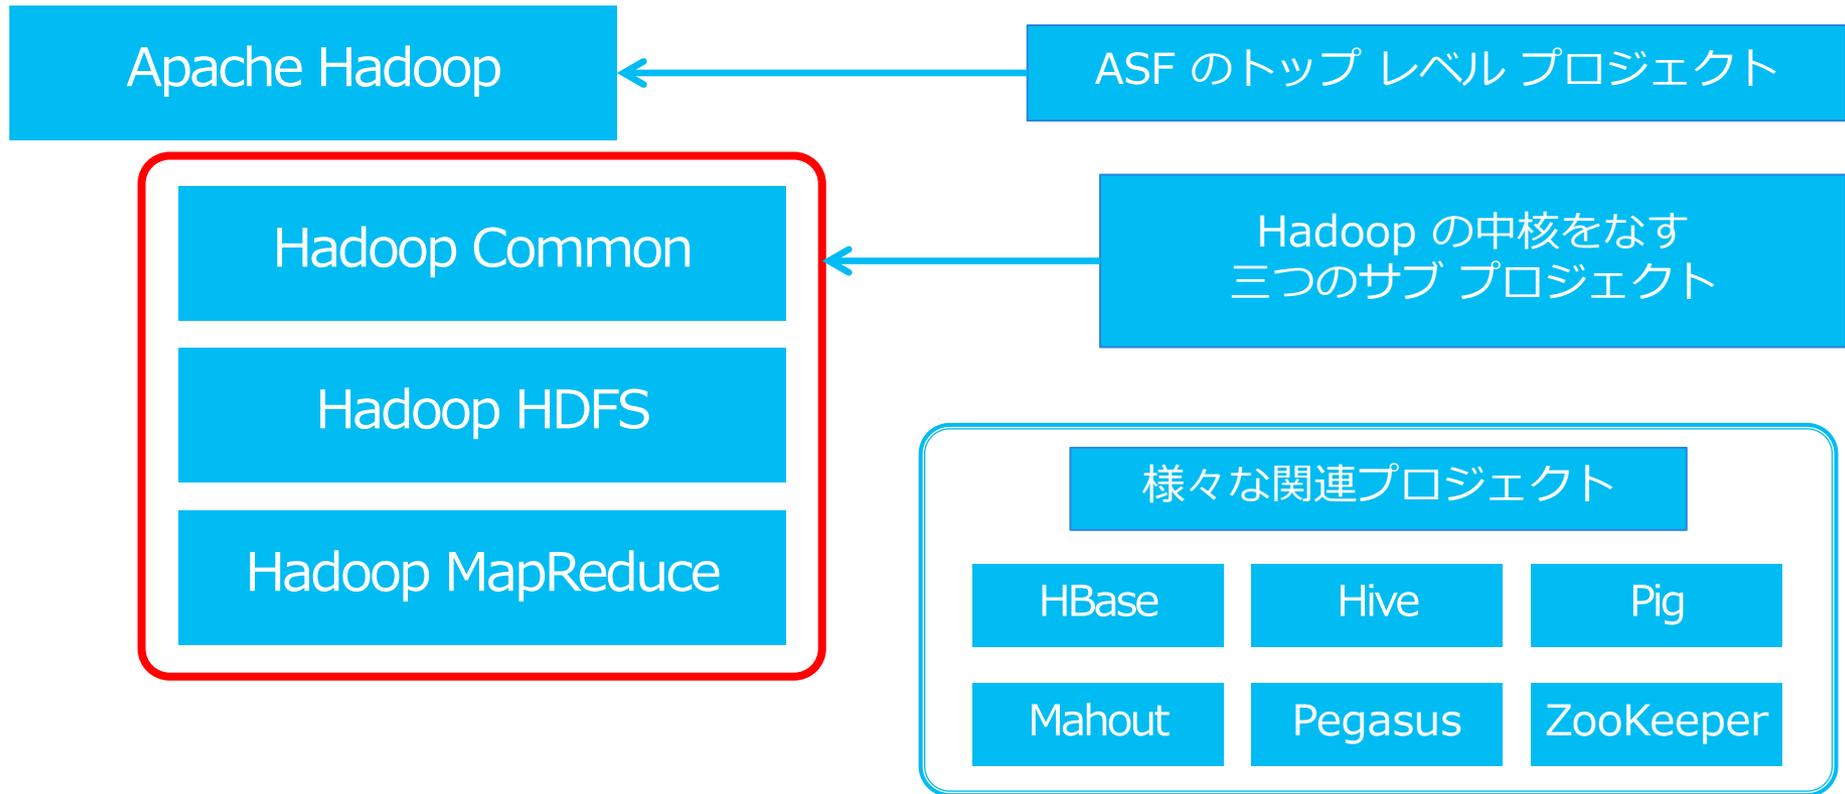
Apache HadoopのWindows対応と関連技術

Windows 向けの調整と機能追加を
Apache ヘフィードバック

WindowsでHadoopを活用する時代に向けて

変わりゆくマイクロソフトと Windows

Apache Hadoop とその周辺



MS-Hadoop (Isotope) は、Windows (Azure|Server) 上にHadoop環境を提供するために、

- コア部分と関連プロジェクトをパッケージ化
- Cygwin 等に頼らず Windows 上で直接実行できるように移植
- 既存の Windows テクノロジとの接続性を追加

Hadoop on Windows / Linux

Microsoft 版 Hadoop
(コードネーム: Isotope)

Cloudera 版 Hadoop (CDH)

```
管理者: Windows コマンド プロセッサ
C:\%Apps%\dist\%bin>hadoop
Usage: hadoop [--config confdir] COMMAND
where COMMAND is one of:
  namenode -format      format the DFS filesystem
  secondarynamenode    run the DFS secondary namenode
  namenode              run the DFS namenode
  datanode              run a DFS datanode
  dfsadmin             run a DFS admin client
  mradmin              run a Map-Reduce admin client
  fsck                 run a DFS filesystem checking utility
  fs                   run a generic filesystem user client
  balancer             run a cluster balancing utility
  jobtracker          run the MapReduce job Tracker node
  pipes               run a Pipes job
  tasktracker         run a MapReduce task Tracker node
  job                 manipulate MapReduce jobs
  queue               get information regarding JobQueues
  version             print the version
  jar <jar>           run a jar file

  distcp <srcurl> <desturl> copy file or directories recursively
  archive -archiveName NAME <src>* <dest> create a hadoop archive
  daemonlog          get/set the log level for each daemon
  or
  CLASSNAME         run the class named CLASSNAME
Most commands print help when invoked w/o parameters.

C:\%Apps%\dist\%bin>
```

```
アプリケーション 場所 システム
Terminal
ファイル(F) 編集(E) 表示(V) 端末(T) ヘルプ(H)
ks-ubuntu-01:~ [pts/0] $ hadoop
Usage: hadoop [--config confdir] COMMAND
where COMMAND is one of:
  namenode -format      format the DFS filesystem
  secondarynamenode    run the DFS secondary namenode
  namenode              run the DFS namenode
  datanode              run a DFS datanode
  dfsadmin             run a DFS admin client
  mradmin              run a Map-Reduce admin client
  fsck                 run a DFS filesystem checking utility
  fs                   run a generic filesystem user client
  balancer             run a cluster balancing utility
  jobtracker          run the MapReduce job Tracker node
  pipes               run a Pipes job
  tasktracker         run a MapReduce task Tracker node
  job                 manipulate MapReduce jobs
  queue               get information regarding JobQueues
  version             print the version
  jar <jar>           run a jar file
  distcp <srcurl> <desturl> copy file or directories recursively
  archive -archiveName NAME -p <parent path> <src>* <dest> create a hadoop archive
  oiv                 apply the offline fsimage viewer to an fsimage
  classpath          prints the class path needed to get the
  dfsgroups          get the groups which users belong to on the Name Node
  mrgroups           get the groups which users belong to on the Job Tracker
  Hadoop jar and the required libraries
  daemonlog          get/set the log level for each daemon
  or
  CLASSNAME         run the class named CLASSNAME
Most commands print help when invoked w/o parameters.
ks-ubuntu-01:~ [pts/0] $
```

Isotope に含まれるサブプロジェクト

HBase

- Google の “Bigtable” に相当する分散型列指向データストア
- HDFS の上位レイヤとなり、ランダムアクセスができない HDFS の欠点がある程度補うことができる。

Hive

- HDFS に対して SQL 的な言語 (Hive QL) でクエリを発行できる。
- MapReduce の複雑さを隠蔽し RDB ユーザーが直感的に Hadoop を活用できる。

Pig

- こちらも HDFS に対する上位レイヤで、大規模なデータセットの探索を容易にする仕組み
- “Pig Latin” というスクリプト言語で処理を記述すると、Pig がそれを MapReduce ジョブに変換して実行する。

Isotope に含まれるサブプロジェクト

Mahout

- Hadoop 上で大規模な機械学習を行うためのライブラリ
- 典型的には、ネットワーク経由で収集される大量のデータを基に、レコメンデーション エンジンの作成や評判分析に利用される。

Sqoop

- RDBMS と HDFS の間で、双方向のバルクデータ転送を行う仕組み
- SQL Server-Hadoop Connector も Sqoop を利用しています。

ZooKeeper

- 複数のコンピューターからなる分散システムで、ノードのメンバーシップの管理、分散ロック、構成情報の同期といった、「必ず必要になるが実装は骨が折れる」機能を提供するライブラリ
- Windows では、フェールオーバークラスターのメンバシップマネージャが行っている処理に近いもの

Isotope の提供形態

Windows Server と Windows Azure の両方で稼働します

Windows Server 版
(オンプレミス)

Windows Server にインストールして
Hadoop クラスタを構築する方式

Windows Azure 版
その1 - 「自前クラスタ」

Windows Azure の既存サブスクリプションに、
Hadoop クラスタをデプロイする方式

Windows Azure 版
その2 - “Elastic MapReduce”

クラスタの詳細を意識せず、
単純に MapReduceプログラムだけを
デプロイして利用する方式

本日は
Azure 版を
ご紹介

Hadoop on Azure EMR

通常のWindows Azure管理
ポータルとは別の専用サイト

CTP2 (プレビュー版第2弾)を提供中

Windows Azure Apache™ Hadoop™-based Services for Windows Azure SASAKI Kuninobu | [Sign Out](#)

Welcome back!

Request a new cluster

DNS name

DNS name
 Available
http://kscluster.cloudapp.net

Cluster size

| | | | |
|--|--|---|--|
| <input type="radio"/> Small 4 nodes 2 TB disk space Available | <input checked="" type="radio"/> Medium 8 nodes 4 TB disk space Available | <input type="radio"/> Large 16 nodes 8 TB disk space Available | <input type="radio"/> Extra large 32 nodes 16 TB disk space Available |
|--|--|---|--|

Cluster login

Username

Password

Confirm password

SQL Azure
 Use SQL Azure for Hive Metastore?

Request cluster

JavaScript コンソール

"#コマンド" で、FS Shellの
コマンドを呼び出せます。

"#lsr"は"hadoop fs -lsr"に相当します。

Interactive JavaScript

JavaScript

Hive

```
js> #lsr /
drwxr-xr-x - root supergroup 0 2012-03-27 01:55 /example
drwxr-xr-x - root supergroup 0 2012-03-27 01:55 /example/apps
-rw-r--r-- 3 root supergroup 4608 2012-03-27 01:55 /example/apps/cat.exe
-rw-r--r-- 3 root supergroup 5120 2012-03-27 01:55 /example/apps/wc.exe
drwxr-xr-x - root supergroup 0 2012-03-27 01:55 /example/data
drwxr-xr-x - root supergroup 0 2012-03-27 01:55 /example/data/cloudburst
-rw-r--r-- 3 root supergroup 4493593 2012-03-27 01:55 /example/data/cloudburst/100k.br
-rw-r--r-- 3 root supergroup 579773 2012-03-27 01:55 /example/data/cloudburst/s_suis.br
-rw-r--r-- 3 root supergroup 1395667 2012-03-27 01:55 /example/data/davinci.txt
-rw-r--r-- 3 root supergroup 674762 2012-03-27 01:55 /example/data/outlineofscience.txt
-rw-r--r-- 3 root supergroup 1573044 2012-03-27 01:55 /example/data/ulysses.txt
drwxr-xr-x - root supergroup 0 2012-03-27 01:54 /hdfs
drwxr-xr-x - root supergroup 0 2012-03-27 01:54 /hdfs/tmp
drwxr-xr-x - root supergroup 0 2012-03-27 01:54 /hdfs/tmp/mapred
drwx----- - root supergroup 0 2012-03-27 01:54 /hdfs/tmp/mapred/system
-rw----- 3 root supergroup 4 2012-03-27 01:54 /hdfs/tmp/mapred/system/jobtracker.info
drwxr-xr-x - root supergroup 0 2012-03-27 01:55 /hive
drwxr-xr-x - root supergroup 0 2012-03-27 01:55 /hive/warehouse
drwxr-xr-x - root supergroup 0 2012-03-27 01:55 /hive/warehouse/hivesampletable
-rw-r--r-- 3 root supergroup 5015508 2012-03-27 01:55 /hive/warehouse/hivesampletable/HiveSampleData.tx
drwxr-xr-x - root supergroup 0 2012-03-27 01:55 /tmp
drwxr-xr-x - root supergroup 0 2012-03-27 01:55 /tmp/hive-RD00155D421795$
drwxrwxrwx - root supergroup 0 2012-03-27 01:54 /uploads
drwxr-xr-x - root supergroup 0 2012-03-27 02:51 /user
drwxr-xr-x - root supergroup 0 2012-03-27 01:55 /user/SYSTEM
drwxr-xr-x - root supergroup 0 2012-03-27 01:55 /user/SYSTEM/graph
-rw-r--r-- 3 root supergroup 80 2012-03-27 01:55 /user/SYSTEM/graph/catepillar_star.edge
drwxr-xr-x - root supergroup 0 2012-03-27 01:55 /user/SYSTEM/query
-rw-r--r-- 3 root supergroup 12 2012-03-27 01:55 /user/SYSTEM/query/catepillar_star_rwr.query
drwxr-xr-x - root supergroup 0 2012-03-27 02:51 /user/root
drwxr-xr-x - root supergroup 0 2012-03-27 02:51 /user/root/.oink
```

```
js> fs.get("/example/data/davinci.txt")
```

```
js>
```

"#fs.get" でHDFS上のファイルを
ローカルコンピューターへ
ダウンロードできます。

www.hadoonazure.com から Fs (1.33 MB) を開くか、または保存しますか?

ファイルを開く(O)

保存(S)

キャンセル(C)

Help

Hive コンソール

The screenshot shows the Hive Interactive Console interface. At the top, there's a navigation bar with "Interactive Hive" and buttons for "JavaScript" and "Hive". Below this, there are dropdown menus for "tables" and "columns". The main area is split into two columns. The left column shows the results of a query: "show tables;" followed by "hivesampletable", and "select count(*) from hivesampletable;" followed by "59793". The right column shows the Hive history for the executed queries, including the file path, status (OK), and execution time (3.843 seconds). At the bottom, there is a text input field containing "select * from hivesampletable;" and two buttons: "Evaluate" and "Clear screen".

クエリの結果と、実行された Map-Reduceジョブに関する情報が、ここに表示されます。

ここにHQLを入力します。

Windows Azure Storage との接続

Windows Azure Apache™ Hadoop™-based Services for Windows Azure SASAKI Kuninobu | Sign Out

Configure Azure Blob Storage

Azure Credentials

Storage Account Name
usnorthcentral01

Passkey
qRX5+EaDALbmNYTg8Ht97FLxFGXQGCwStWBry2gbNylNnqXfRgoW00ZzaeQ x

Save settings

© 2012 Microsoft | Privacy Statement Help

Windows Azure BLOB ストレージへの接続設定

asv://ストレージアカウント名/
でアクセスできます。

Windows Azure Apache™ Hadoop™-based Services for Windows Azure SASAKI Kuninobu | Sign Out

Interactive JavaScript

JavaScript Hive

```
-IWXIWXIWX 1 9774592 2012-03-26 03:52 /jp/H24.3.22/test032208/perflog_AZURECN-1164_WIN-35NFPTS5D5P.zip
-IWXIWXIWX 1 9811013 2012-03-26 03:53 /jp/H24.3.22/test032208/perflog_AZURECN-1165_WIN-0G2GUDIM29E.zip
-IWXIWXIWX 1 9699977 2012-03-26 03:54 /jp/H24.3.22/test032208/perflog_AZURECN-1166_WIN-GNWN5442M5C.zip
-IWXIWXIWX 1 9784427 2012-03-26 03:55 /jp/H24.3.22/test032208/perflog_AZURECN-1167_WIN-A64R29UV152.zip
-IWXIWXIWX 1 9737857 2012-03-26 03:55 /jp/H24.3.22/test032208/perflog_AZURECN-1168_WIN-1196F7AF1IV.zip
-IWXIWXIWX 1 9793794 2012-03-26 03:56 /jp/H24.3.22/test032208/perflog_AZURECN-1169_WIN-963HLRR67P2.zip
-IWXIWXIWX 1 9712498 2012-03-26 03:57 /jp/H24.3.22/test032208/perflog_AZURECN-1170_WIN-JMOV4R38PF6.zip
-IWXIWXIWX 1 9786183 2012-03-26 03:58 /jp/H24.3.22/test032208/perflog_AZURECN-1171_WIN-H2LBLEK72NT.zip
-IWXIWXIWX 1 9672620 2012-03-26 03:59 /jp/H24.3.22/test032208/perflog_AZURECN-1172_WIN-LHD7SRBKC4M.zip
-IWXIWXIWX 1 9784189 2012-03-26 04:00 /jp/H24.3.22/test032208/perflog_AZURECN-1173_WIN-MTFNSNNOGN1.zip
-IWXIWXIWX 1 9712041 2012-03-26 04:01 /jp/H24.3.22/test032208/perflog_AZURECN-1174_WIN-1RC4KHEHUV78.zip
-IWXIWXIWX 1 9718327 2012-03-26 04:02 /jp/H24.3.22/test032208/perflog_AZURECN-1175_WIN-TBR9AV3M110.zip
-IWXIWXIWX 1 9749709 2012-03-26 04:03 /jp/H24.3.22/test032208/perflog_AZURECN-1176_WIN-F1HLRLD2BC.zip
-IWXIWXIWX 1 9668981 2012-03-26 04:04 /jp/H24.3.22/test032208/perflog_AZURECN-1177_WIN-N2BFFDHFH89.zip
-IWXIWXIWX 1 9775192 2012-03-26 04:04 /jp/H24.3.22/test032208/perflog_AZURECN-1178_WIN-3H2RG92K64C.zip
-IWXIWXIWX 1 9792725 2012-03-26 04:05 /jp/H24.3.22/test032208/perflog_AZURECN-1179_WIN-TQ43Q7MVCV.zip
-IWXIWXIWX 1 9823509 2012-03-26 04:06 /jp/H24.3.22/test032208/perflog_AZURECN-1180_WIN-A28TTEU17JA.zip
-IWXIWXIWX 1 9769265 2012-03-26 04:07 /jp/H24.3.22/test032208/perflog_AZURECN-1181_WIN-RK9DHOVGE08.zip
-IWXIWXIWX 1 9674106 2012-03-26 04:08 /jp/H24.3.22/test032208/perflog_AZURECN-1182_WIN-TB99M2UK0A.zip
-IWXIWXIWX 1 9795427 2012-03-26 04:09 /jp/H24.3.22/test032208/perflog_AZURECN-1183_WIN-JHP7CUDFN5A.zip
-IWXIWXIWX 1 9783717 2012-03-26 04:10 /jp/H24.3.22/test032208/perflog_AZURECN-1184_WIN-C25EPLOKQ2E.zip
-IWXIWXIWX 1 9686430 2012-03-26 04:11 /jp/H24.3.22/test032208/perflog_AZURECN-1185_WIN-ZMFV3Q9N3.zip
-IWXIWXIWX 1 9759009 2012-03-26 04:11 /jp/H24.3.22/test032208/perflog_AZURECN-1186_WIN-BN0P8234DFL.zip
-IWXIWXIWX 1 9723742 2012-03-26 04:12 /jp/H24.3.22/test032208/perflog_AZURECN-1187_WIN-ALICJCAJG41.zip
-IWXIWXIWX 1 9701274 2012-03-26 04:13 /jp/H24.3.22/test032208/perflog_AZURECN-1188_WIN-KLRCCER7DSM.zip
-IWXIWXIWX 1 9781387 2012-03-26 04:14 /jp/H24.3.22/test032208/perflog_AZURECN-1189_WIN-0F2VHISQ93.zip
-IWXIWXIWX 1 9809144 2012-03-26 04:15 /jp/H24.3.22/test032208/perflog_AZURECN-1190_WIN-S6AMQ3T8J09.zip
-IWXIWXIWX 1 9821072 2012-03-26 04:16 /jp/H24.3.22/test032208/perflog_AZURECN-1191_WIN-HMQ12M305PD.zip
-IWXIWXIWX 1 9715359 2012-03-26 04:17 /jp/H24.3.22/test032208/perflog_AZURECN-1192_WIN-LG2K7V38FPD.zip
-IWXIWXIWX 1 9771521 2012-03-26 04:18 /jp/H24.3.22/test032208/perflog_AZURECN-1193_WIN-LTA8072Q9P3.zip
-IWXIWXIWX 1 9824738 2012-03-26 04:19 /jp/H24.3.22/test032208/perflog_AZURECN-1194_WIN-A14HJN114K.zip
-IWXIWXIWX 1 9763141 2012-03-26 04:19 /jp/H24.3.22/test032208/perflog_AZURECN-1195_WIN-A4BNQNM29.zip
-IWXIWXIWX 1 9771590 2012-03-26 04:20 /jp/H24.3.22/test032208/perflog_AZURECN-1197_WIN-0EVA3RSU17.zip
-IWXIWXIWX 1 9658382 2012-03-26 04:21 /jp/H24.3.22/test032208/perflog_AZURECN-1198_WIN-1P8C8A05RA.zip
-IWXIWXIWX 1 9787840 2012-03-26 04:22 /jp/H24.3.22/test032208/perflog_AZURECN-1199_WIN-4NH8K308VAQ.zip
-IWXIWXIWX 1 9711443 2012-03-26 04:23 /jp/H24.3.22/test032208/perflog_AZURECN-1200_WIN-04Q04AINV77.zip
```

```
js> #!er asv://usnorthcentral01/
```

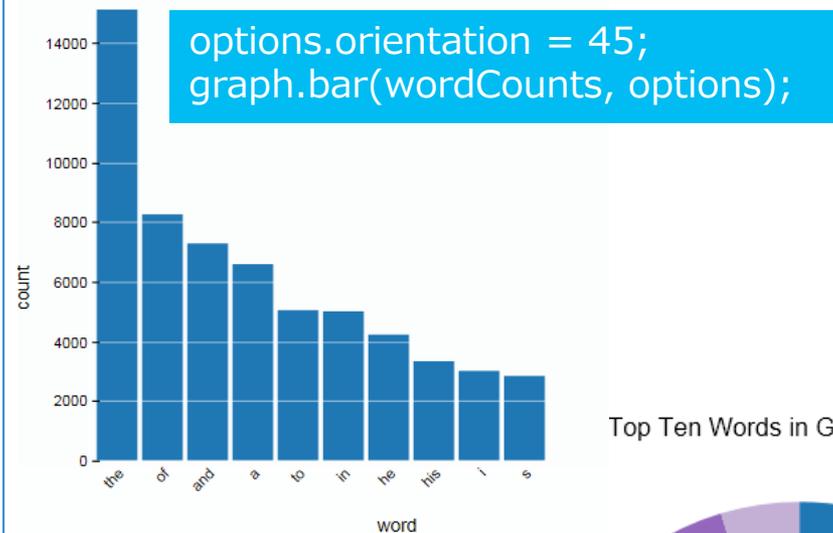
© 2012 Microsoft | Privacy Statement Help

他にも色々
Isotope の
追加機能

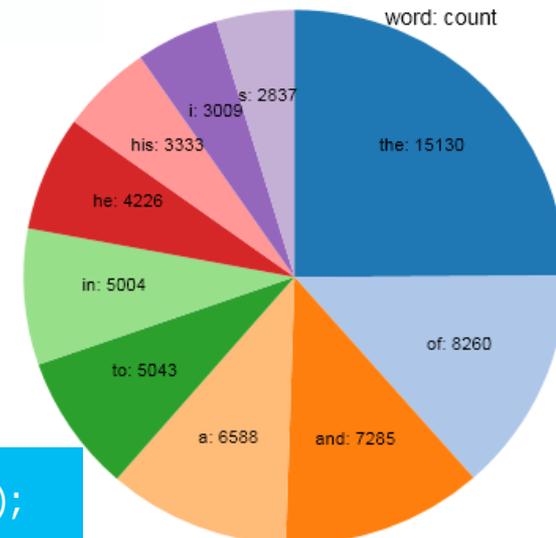
JavaScript MapReduce

```
// Map Reduce function in JavaScript
var map = function (key, value, context) {
  var words = value.split(/[^\a-zA-Z]/);
  for (var i = 0; i < words.length; i++) {
    if (words[i] !== "")
      context.write(words[i].toLowerCase(),
        1);}
  };
var reduce = function (key, values, context)
{
  var sum = 0;
  while (values.hasNext()) {
    sum += parseInt(values.next());
  }
  context.write(key, sum);
};
```

Top Ten Words in Gutenberg Text



Top Ten Words in Gutenberg Text



```
graph.pie(wordCounts, options);
```

分散ファイルシステム API

Isotope には、Hadoop の分散ファイルシステムを操作するためのライブラリが含まれます

ネイティブ DLL
(UNIX系の libhdfs に相当)

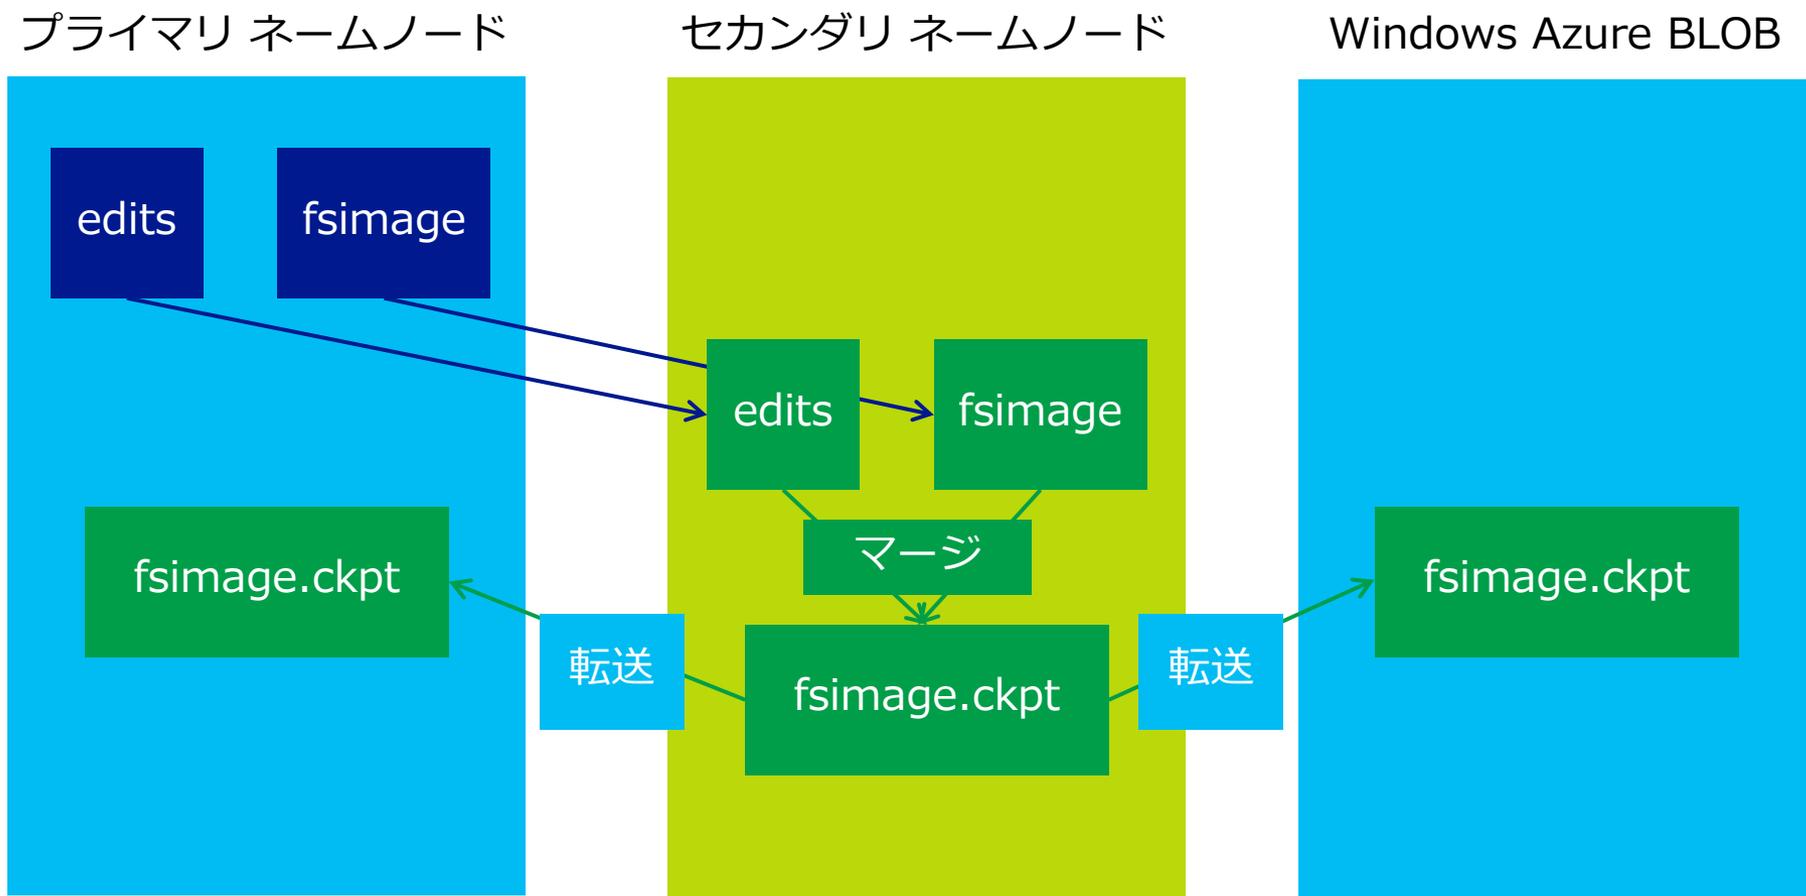
マネージド DLL
(.NET 系の各種言語で利用可能)

```
Action<string> processDirectory = null;
processDirectory = (loopath) =>
{
    using (HdfsFileInfoEntries entries = hdfsSystem.ListDirectory(loopath))
    {
        foreach (HdfsFileInfoEntry entry in entries.Entries)
        {
            string kind
                = entry.Kind == HdfsFileInfoEntryKind.Directory ? "Directory" : "File";
            Console.WriteLine(string.Format(@"{0}:"" {1}""",
                Modified/Accessed:"" {2:G}, {3:G}""", Owner:"" {4}""",
                , kind, entry.Name, entry.LastModified, entry.LastAccessed, entry.Owner));
            if (entry.Kind == HdfsFileInfoEntryKind.Directory)
            {
                processDirectory(entry.Name);
            }
        }
    }
};
```

C# でディレクトリの一覧を取得するコード例

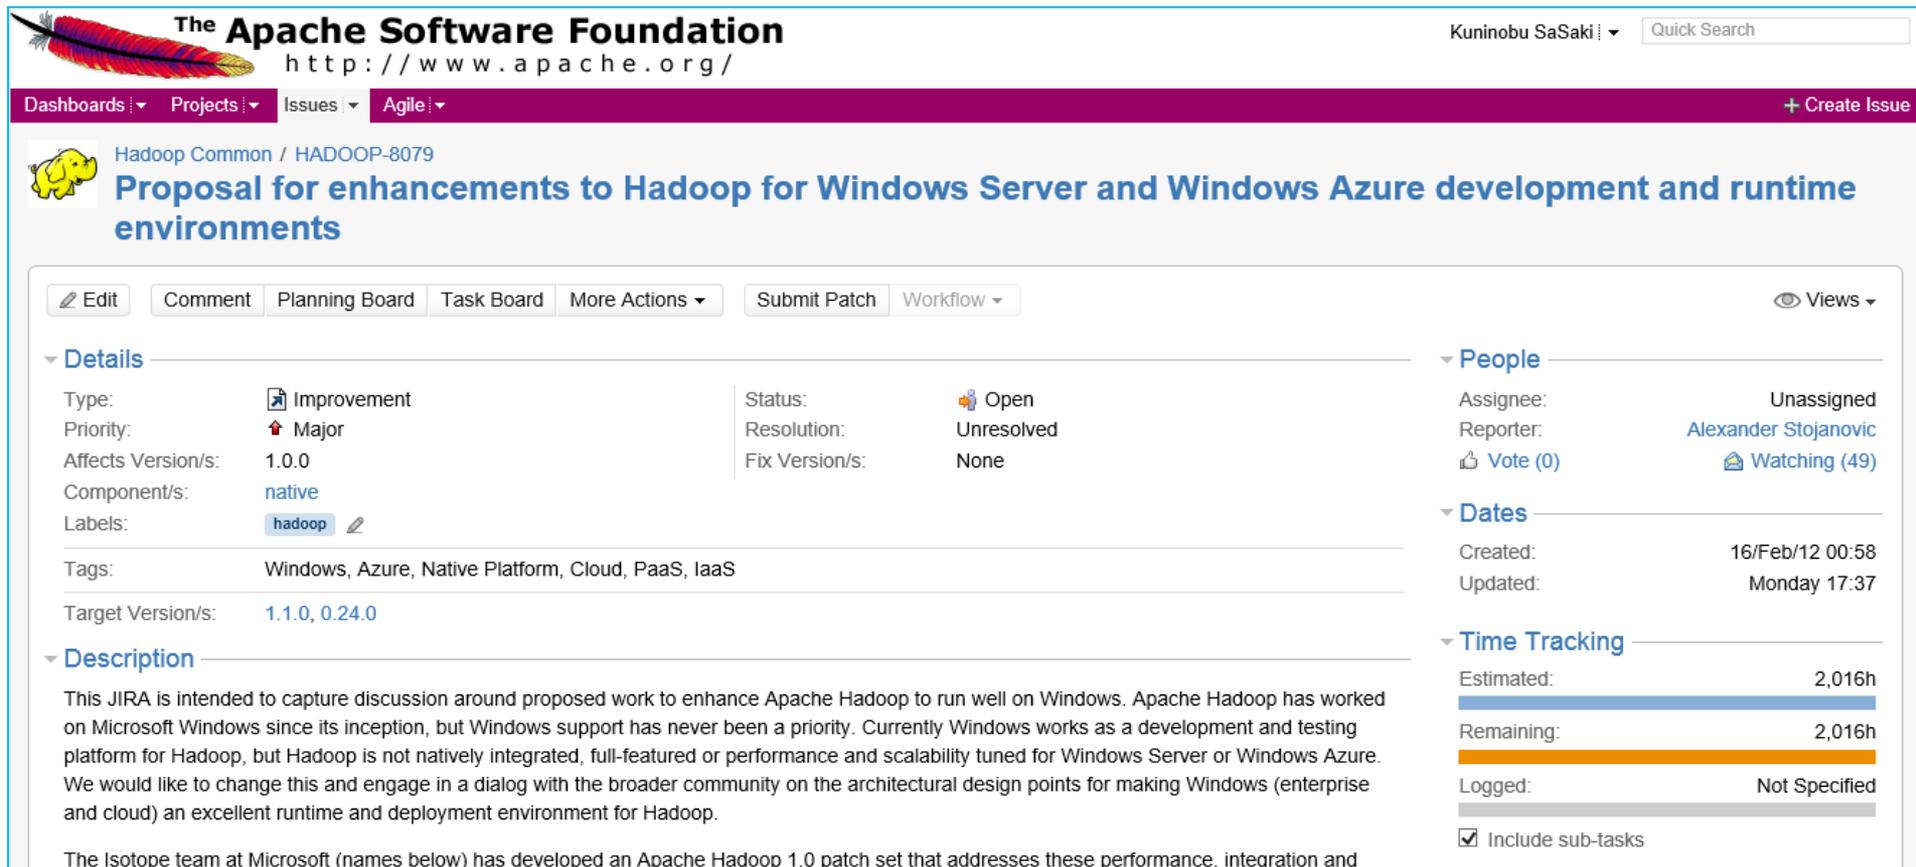
メタデータのバックアップサービス

セカンダリネームノードで作成されるチェックポイントファイルを Windows Azure Storage へ転送して障害に備える機能です



Apache へのフィードバック

[2012/2/16] Isotope の成果を Apache へ還元すべく JIRA チケット作成



The Apache Software Foundation
http://www.apache.org/

Kuninobu SaSaki | Quick Search

Dashboards | Projects | Issues | Agile | + Create Issue

Hadoop Common / HADOOP-8079

Proposal for enhancements to Hadoop for Windows Server and Windows Azure development and runtime environments

Edit Comment Planning Board Task Board More Actions Submit Patch Workflow Views

Details

| | | | |
|--------------------|--|----------------|------------|
| Type: | Improvement | Status: | Open |
| Priority: | Major | Resolution: | Unresolved |
| Affects Version/s: | 1.0.0 | Fix Version/s: | None |
| Component/s: | native | | |
| Labels: | hadoop | | |
| Tags: | Windows, Azure, Native Platform, Cloud, PaaS, IaaS | | |
| Target Version/s: | 1.1.0, 0.24.0 | | |

Description

This JIRA is intended to capture discussion around proposed work to enhance Apache Hadoop to run well on Windows. Apache Hadoop has worked on Microsoft Windows since its inception, but Windows support has never been a priority. Currently Windows works as a development and testing platform for Hadoop, but Hadoop is not natively integrated, full-featured or performance and scalability tuned for Windows Server or Windows Azure. We would like to change this and engage in a dialog with the broader community on the architectural design points for making Windows (enterprise and cloud) an excellent runtime and deployment environment for Hadoop.

The Isotope team at Microsoft (names below) has developed an Apache Hadoop 1.0 patch set that addresses these performance, integration and

People

Assignee: Unassigned
Reporter: Alexander Stojanovic
Vote (0) Watching (49)

Dates

Created: 16/Feb/12 00:58
Updated: Monday 17:37

Time Tracking

| | |
|------------|---------------|
| Estimated: | 2,016h |
| Remaining: | 2,016h |
| Logged: | Not Specified |

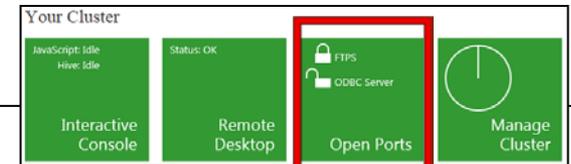
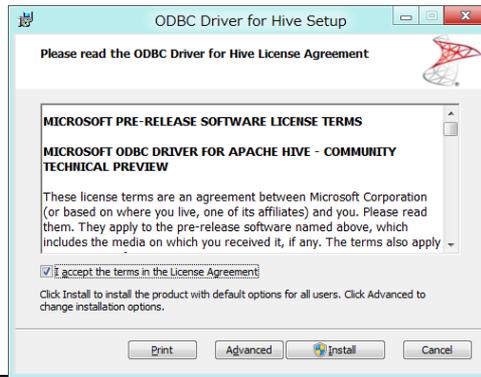
Include sub-tasks

マイクロソフト テクノロジーとの連携

Hive ODBC ドライバー

ODBC 経由で Hadoop クラスターの Hive に接続可能

インストール



Configure Ports

By default all of the ports on your cluster are closed. For more complex configuration, use the remote desktop connection.

Remember that opening ports can present a security risk.

| Name | Port # | Status | Toggle |
|-------------|--------|--------|-------------------------------------|
| FTPS | 2226 | Closed | <input type="checkbox"/> |
| ODBC Server | 10000 | Open | <input checked="" type="checkbox"/> |

Excel Hive アドイン

Excel 上で Hive クエリの編集/結果セットの表示ができます

The screenshot shows the Microsoft Excel interface with the 'Hive Data' add-in ribbon active. The ribbon includes options for '接続' (Connect), 'プロパティ' (Properties), and 'リンクの編集' (Edit Links). A red box highlights the '接続' button. Below the ribbon, the worksheet 'Book1' displays a table with columns for client, query time, mark, device platform, device manufacturer, and device model. The data is as follows:

| | A | B | C | D | E | F |
|----|--------|----------|-------|---------------|-----------|-------------|
| 1 | client | querytin | mark | deviceplatfor | devicemal | devicemodel |
| 2 | 8 | 18:54:20 | en-US | Android | Samsung | SCH-i500 |
| 3 | 23 | 19:19:44 | en-US | Android | HTC | Incredible |
| 4 | 23 | 19:19:46 | en-US | Android | HTC | Incredible |
| 5 | 23 | 19:19:47 | en-US | Android | HTC | Incredible |
| 6 | 28 | 01:37:50 | en-US | Android | Motorola | Droid X |
| 7 | 28 | 00:53:31 | en-US | Android | Motorola | Droid X |
| 8 | 28 | 00:53:50 | en-US | Android | Motorola | Droid X |
| 9 | 28 | 16:44:21 | en-US | Android | Motorola | Droid X |
| 10 | 28 | 16:43:41 | en-US | Android | Motorola | Droid X |
| 11 | 28 | 01:37:19 | en-US | Android | Motorola | Droid X |

Excel Hive アドイン

タスクペインで接続情報や発行クエリを編集

ODBC Hive Setup

Data Source Name:

Description: Hive Demo

Host: xxx.cloudapp.net

Port: 10000

Use Framed Packet Communication

Authentication

No Authentication

Username/Password

Username: admin

Password (will not be saved in configuration):

SSL/TLS Client Certificates File:

SSL/TLS Client Certificates File:

Host : ヘッドノードのサーバ名を指定
Windows Azure の場合、
Hadoop クラスタ作成時の DNS 名を指定
(例 : xxx.cloudapp.net)

Username/Password:
ヘッドノード サーバの
ユーザアカウント/パスワード

Hive Query

Hive Connection

Select or Enter Hive Connection

Hive Demo

Enter Cluster Details...

Hive Objects - Tables/View

Select the Hive Object to Query

hivesampletable [Table]

Columns

Select the Columns to be returned in the query. Functions may also be applied:

| | Column Name | Fun |
|--------------------------|----------------|-----|
| <input type="checkbox"/> | clientid | |
| <input type="checkbox"/> | querytime | |
| <input type="checkbox"/> | market | |
| <input type="checkbox"/> | deviceplatform | |

Criteria

Aggregate Grouping

Ordering

Limit Rows/Sample Data

HiveQL

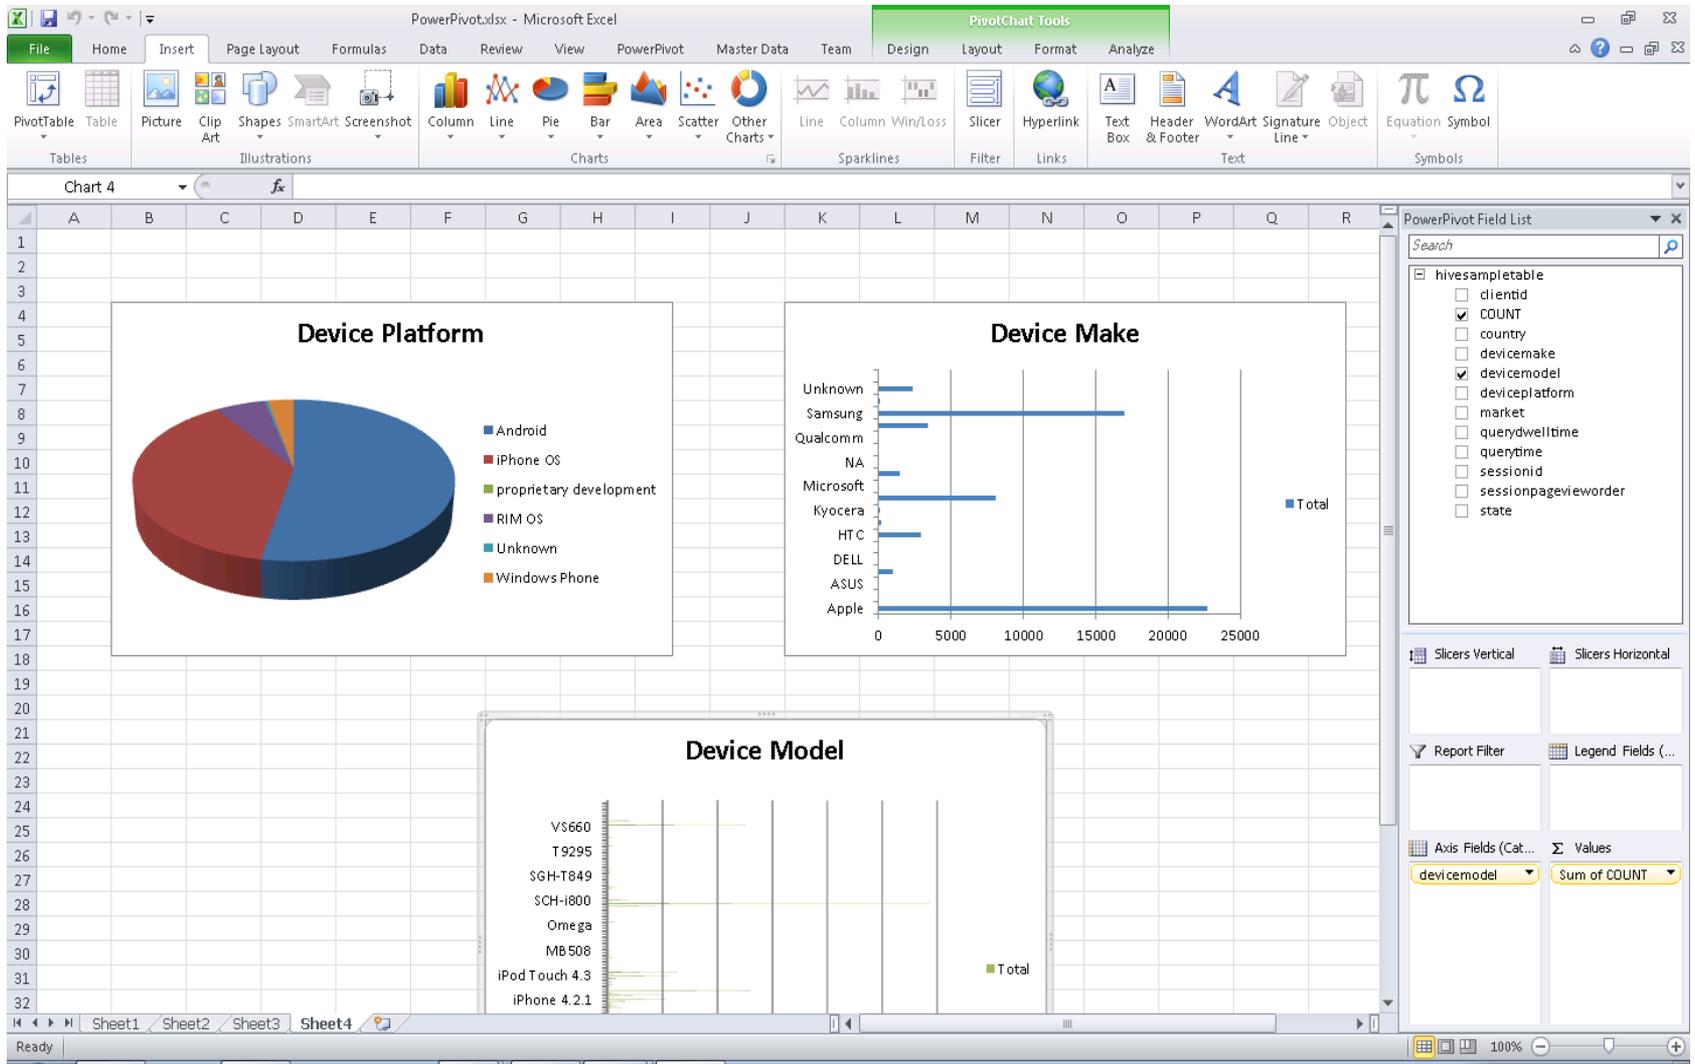
select * from hivesampletable
limit 200

Execute Query Cancel Query

テーブル

発行クエリ

PowerPivot で Hive へ接続



Operations Managerとの連携

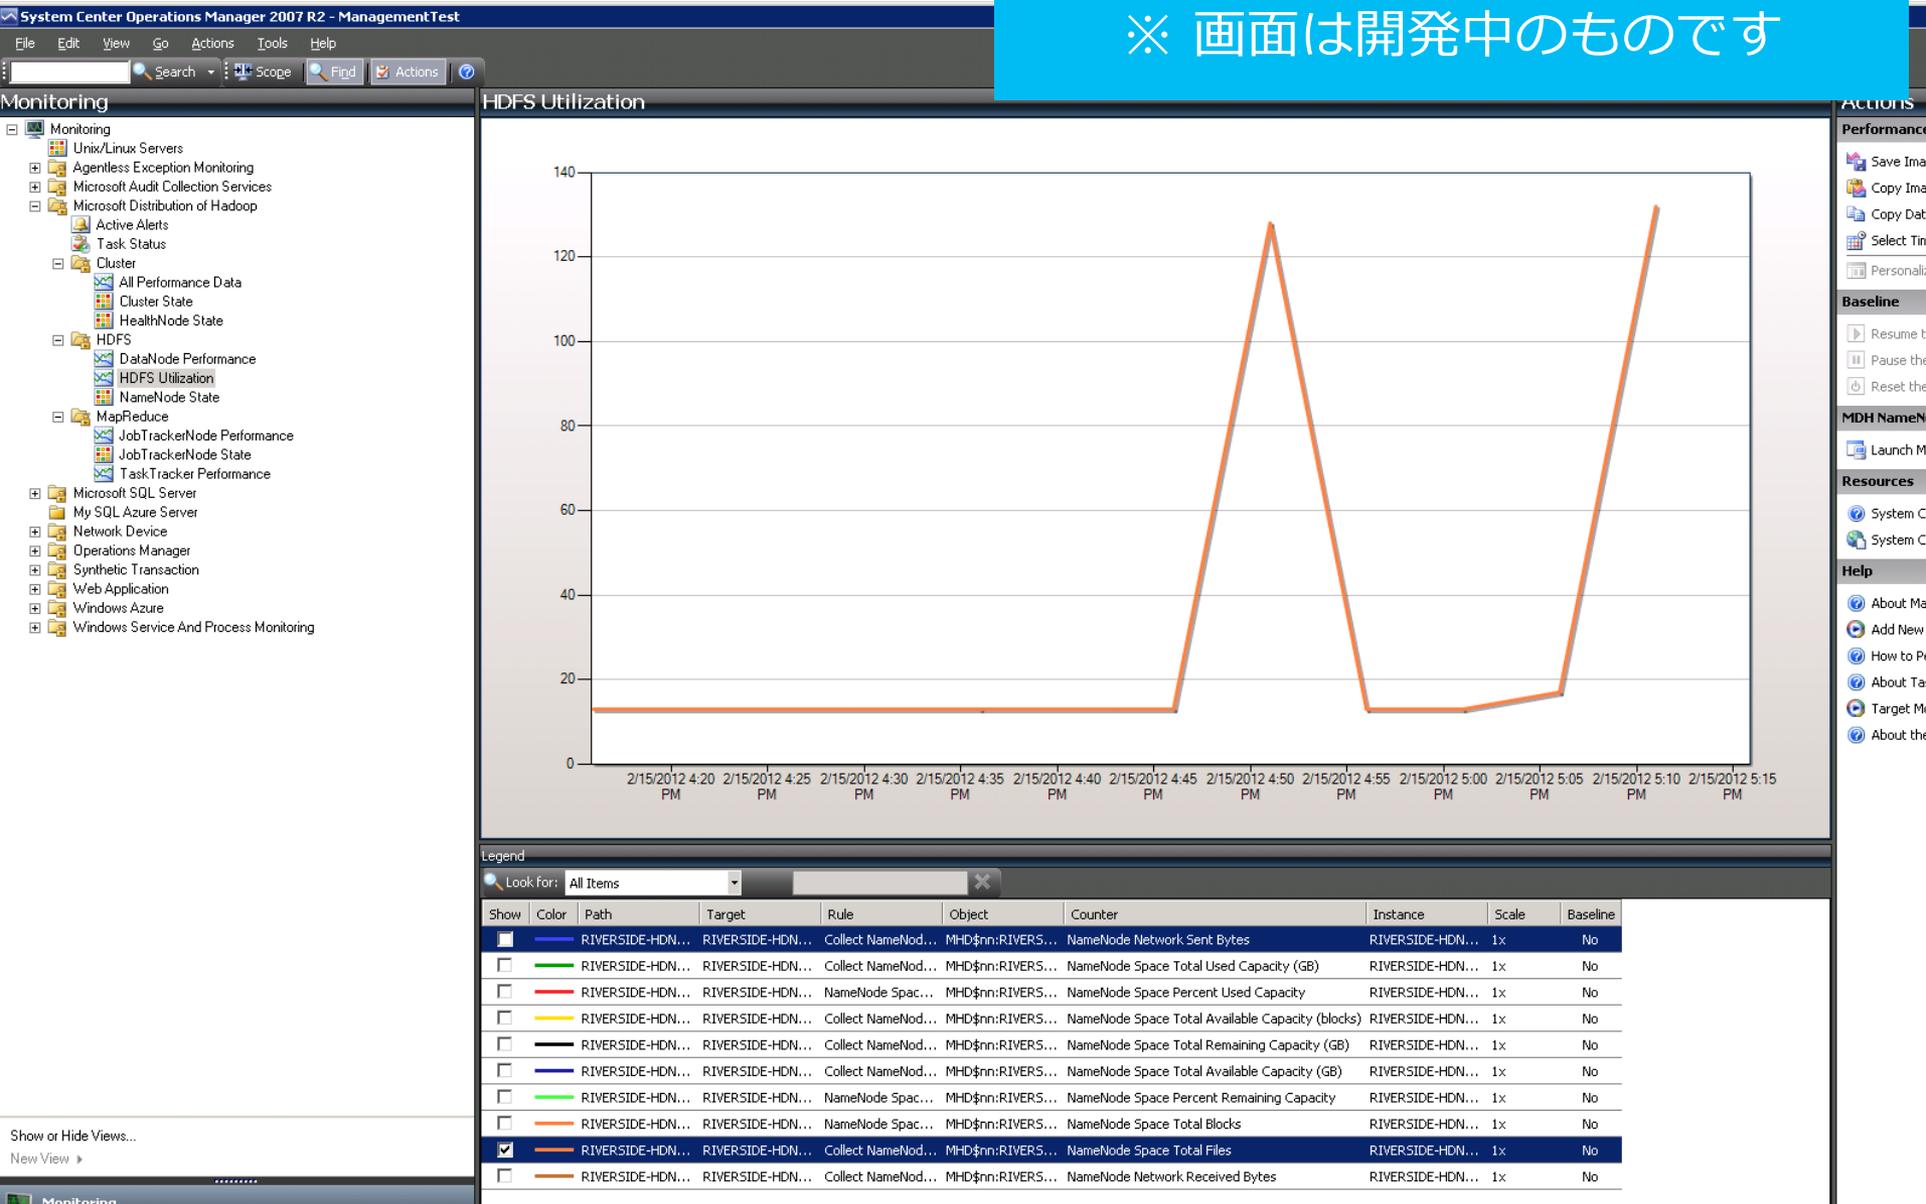
※ 画面は開発中のものです

The screenshot displays the System Center Operations Manager 2007 R2 - ManagementTest interface. The left pane shows a tree view under 'Monitoring' with categories like Unix/Linux Servers, Agentless Exception Monitoring, Microsoft Audit Collection Services, Microsoft Distribution of Hadoop, Cluster, HDFS, MapReduce, Microsoft SQL Server, My SQL Azure Server, Network Device, Operations Manager, Synthetic Transaction, Web Application, Windows Azure, and Windows Service And Process Monitoring. The right pane shows the 'Cluster State (1)' view with a search bar and a table of cluster states.

| State | Name | Path | MDH NameNode | MDH Job Tracker Node |
|---------|--|------|--------------|----------------------|
| Healthy | RIVERSIDE-HDN.redmond.corp.microsoft.com | | Healthy | Healthy |

HDFS 利用率の可視化

※ 画面は開発中のものです



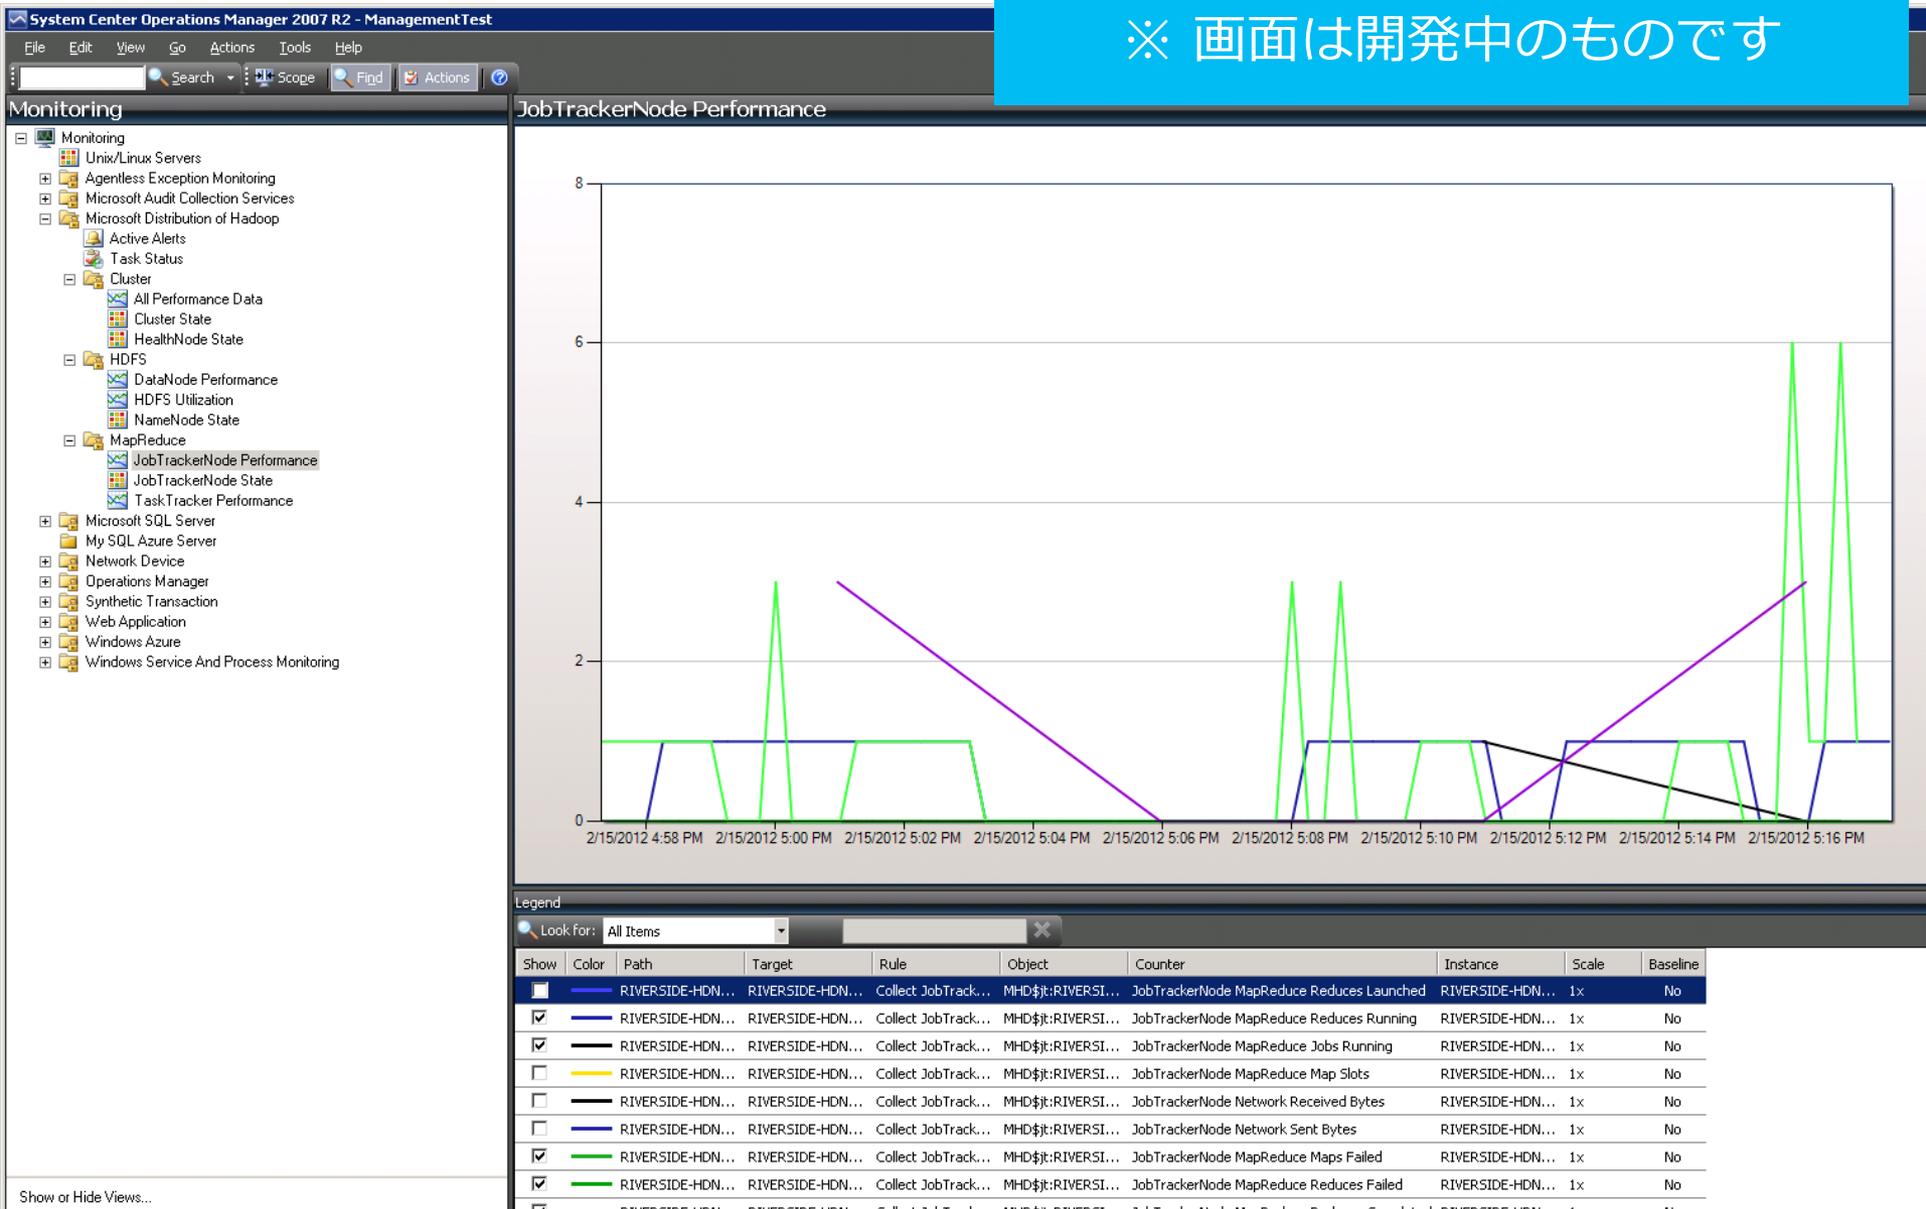
データノードのパフォーマンス

※ 画面は開発中のものです



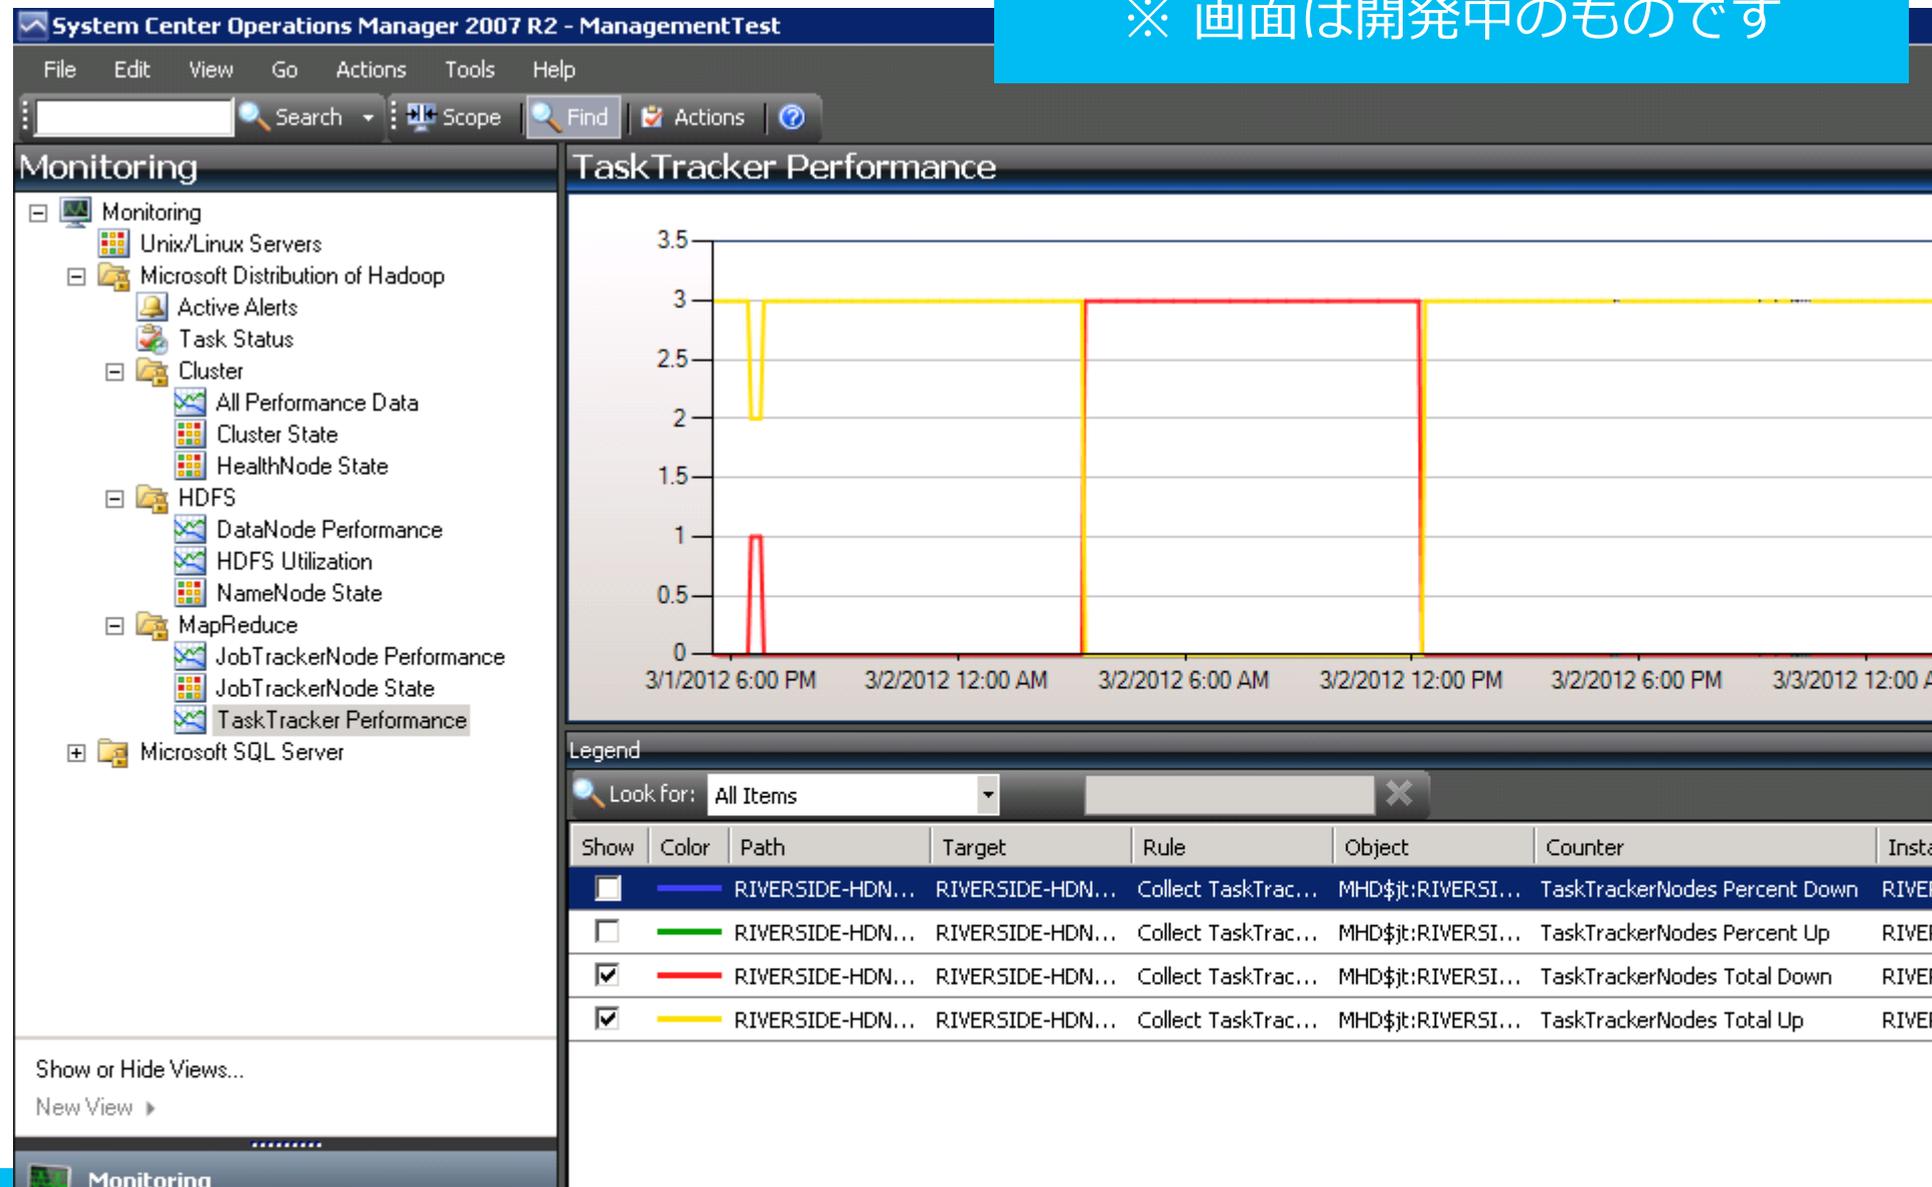
ジョブトラッカーのパフォーマンス

※ 画面は開発中のものです



タスクトラッカーの状況

※ 画面は開発中のものです



(例) ネームノードの障害時

※ 画面は開発中のものです

System Center Operations Manager 2007 R2 - ManagementTest

File Edit View Go Actions Tools Help

Search Scope Find Actions

Monitoring

- Monitoring
 - Unix/Linux Servers
 - Microsoft Distribution of Hadoop
 - Active Alerts
 - Task Status
 - Cluster
 - All Performance Data
 - Cluster State**
 - HealthNode State
 - HDFS
 - DataNode Performance
 - HDFS Utilization
 - NameNode State
 - MapReduce
 - JobTrackerNode Performance
 - JobTrackerNode State
 - TaskTracker Performance
 - Microsoft SQL Server

Show or Hide Views...
New View ▶

Cluster State (1)

Look for: Find Now Clear

| State | Name | Display Name | MDH NameNode | MDH Job Tracker Node |
|----------|---|----------------------|--------------|----------------------|
| Critical | RIVERSIDE-HDNA.redmond.corp.microsoft.com | RIVERSIDE-HDNA.re... | Critical | Healthy |

Detail View

MDH Cluster properties of RIVERSIDE-HDNA.redmond.corp.microsoft.com

| | |
|-----------|--|
| Name | RIVERSIDE-HDNA.redmond.corp.microsoft.com |
| Path name | RIVERSIDE-HDNA.redmond.corp.microsoft.com |
| Name | RIVERSIDE-HDNA.redmond.corp.microsoft.com |
| | MHD\$mhd:RIVERSIDE-HDNA.redmond.corp.microsoft.com |

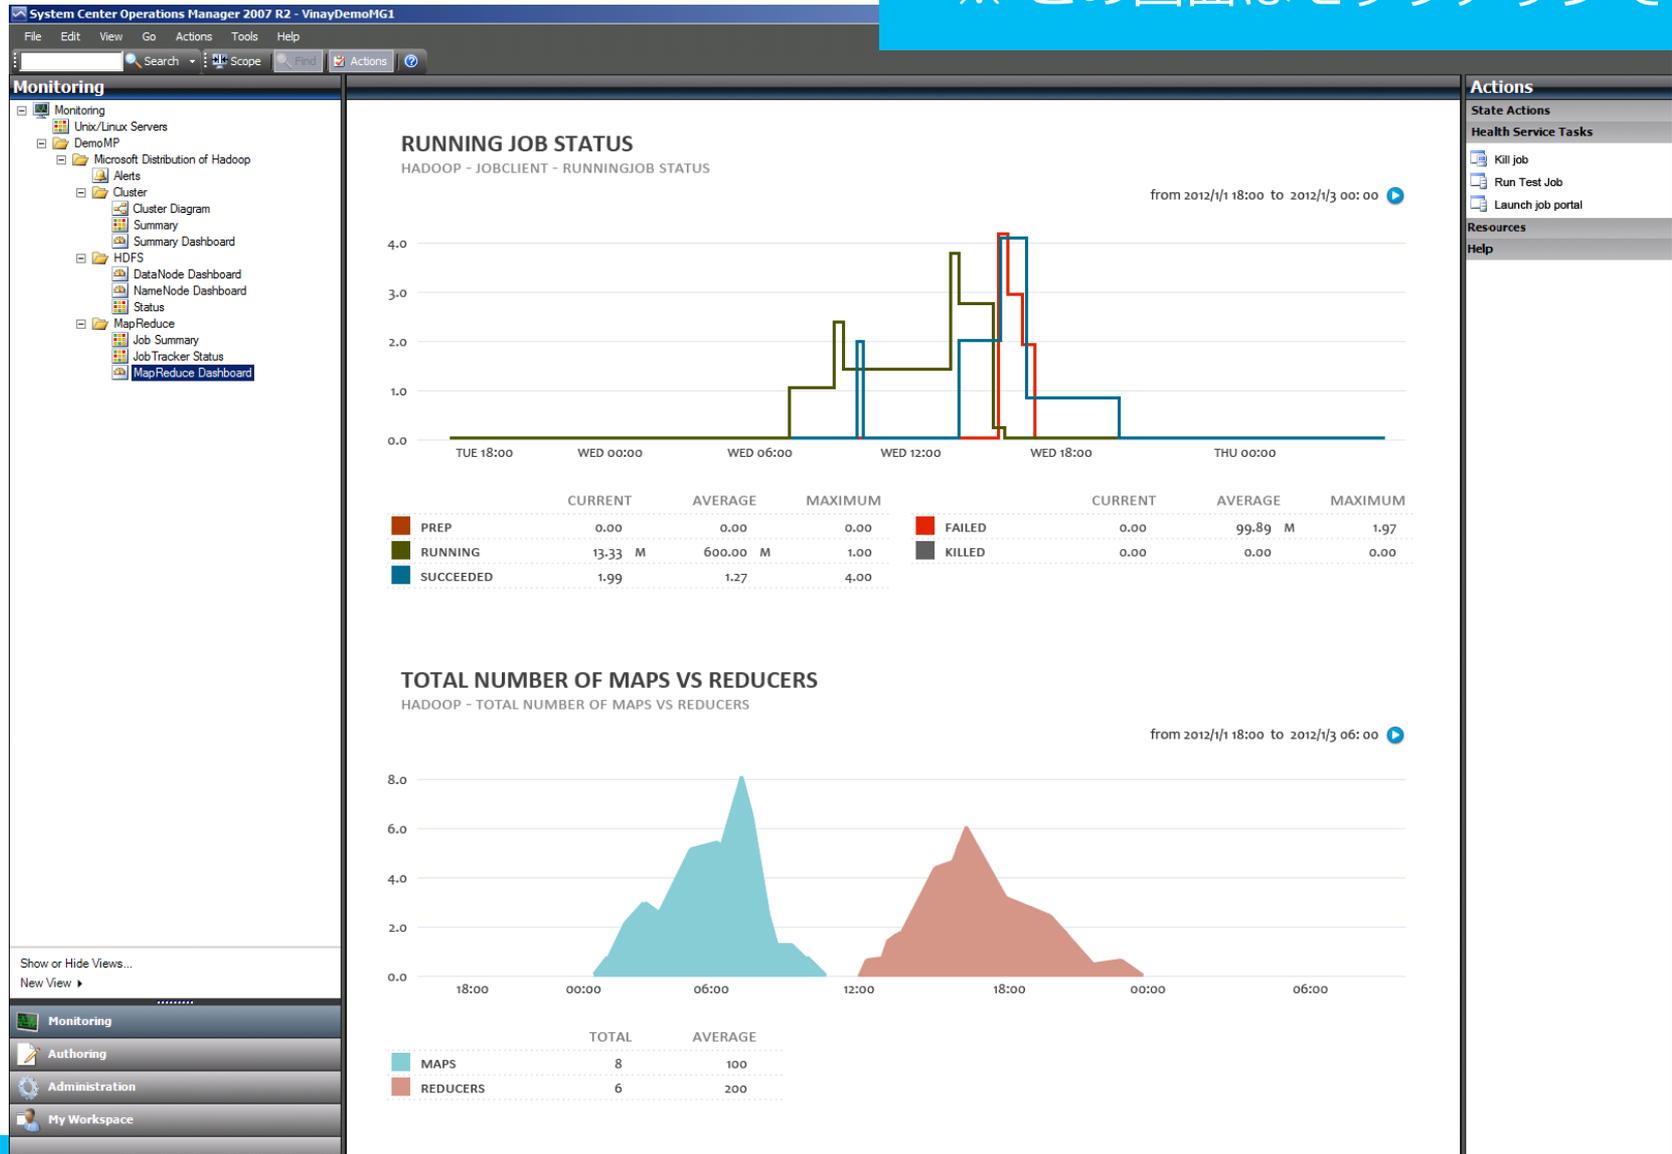
System Center 2012 にも対応予定

※ この画面はモックアップです



MapReduce ダッシュボード

※ この画面はモックアップです



本日の内容

マイクロソフトとビッグデータ

弊社内での大規模データ処理事例

Apache HadoopのWindows対応と関連技術

Windows 向けの調整と機能追加を
Apache ヘフィードバック

WindowsでHadoopを活用する時代に向けて

変わりゆくマイクロソフトと Windows

最近

マイクロソフト

かなり
オープン

概要 .net node.js java php ダウンロード

NODE.JS ホーム

チュートリアル

Web App

Express を使用する Web アプリケーション

Node.js デベロッパー センター

Windows Azure SDK for Node.js

すべてが 1 つのシンプルなインストールに含まれる手軽なインストール

- ✓ Windows Azure PowerShell for Node.js
- ✓ Node.js for Windows

インストール

最終更新: 2012 年 2 月



概要 .net node.js java php ダウンロード

PHP ホーム

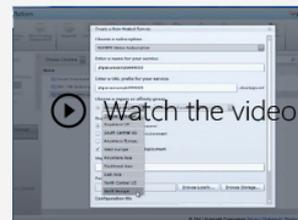
PHP デベロッパー センター

PHP 用 Windows Azure SDK (コミュニティによりサポート)

- ✓ PHP 用 Windows Azure コマンドライン ツール
- ✓ PHP 用 Windows Azure クライアント ライブラリ

ダウンロード (英語)

最終更新: 2011 年 12 月



概要 .net node.js java php ダウンロード

JAVA ホーム

Java デベロッパー センター

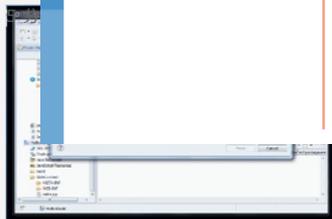
Java 用 Windows Azure SDK

Java サポートのダウンロード

- ✓ Windows Azure エミュレーターおよび Eclipse ツール
- ✓ Java 用 Windows Azure クライアント ライブラリ

開始する

最終更新: 2012 年 2 月



初めてのアプリケーションの作成

"Hello World" Web アプリケーション (このページは英語の場合があります)

コミュニティによってサポートされる PHP 用 Windows Azure SDK を使用して、"Hello World" アプリケーションを作成し、コンピューティング エミュレーターでテストし、最終的に Windows Azure に配置します。

interoperability @ microsoft

Covering interoperability scenarios, the technologies enabling them and the community at large

MSDN Blogs > Interoperability @ Microsoft > [Announcing one more way Microsoft will engage with the open source and standards communities](#)

Announcing one more way Microsoft will engage with the open source and standards communities



Jean Paoli 12 Apr 2012 1:00 PM

17



I am really excited to be able to share with you today that Microsoft has announced a new wholly owned subsidiary known as Microsoft Open Technologies, Inc., to advance the company's investment in **openness** – including **interoperability**, **open standards** and **open source**.

My existing Interoperability Strategy team will form the nucleus of this new subsidiary, and I will serve as President of Microsoft Open Technologies, Inc.

The team has worked closely with many business groups on numerous standards initiatives across Microsoft, including the W3C's HTML5, IETF's HTTP 2.0, cloud standards in DMTF and OASIS, and in many open source environments such as Node.js, MongoDB and Phonegap/Cordova.

We help provide open source building blocks for **interoperable cloud services** and collaborate on cloud standards in DMTF and **OASIS**; support developer choice of programming languages to enable **Node.js**, PHP and Java in addition to .NET in Windows Azure; and work with the **PhoneGap**/Cordova and

360

Tweet

262

Like

Search

Recent Posts

[Announcing one more way Microsoft will engage with the open source and standards communities](#)

4 days ago by [Jean Paoli](#)

[BuildNewGames.com to help developers write cross-browser code](#)

11 days ago by [Olivier Bloch](#)

[Speed and Mobility: An Approach for HTTP 2.0 to Make Mobile Apps and the Web Faster](#)

21 days ago by [Jean Paoli](#)

[New Interoperability Solutions for SQL Server 2012](#)

25 days ago by [Peter Galli](#)

[SAG Awards Drupal Website Moves to Windows Azure](#)

1 month ago by [Peter Galli](#)

Tags

オープンソース界と協力していくために新会社設立

<http://blogs.msdn.com/b/interoperability/archive/2012/04/12/announcing-one-more-way-microsoft-will-engage-with-the-open-source-and-standards-communities.aspx>

Hyper-V 上での Linux の動作をサポート

Microsoft® Download Center

製品グループ▼ ダウンロード カテゴリ▼ ヘルプ▼

ダウンロードセンターを検索



Linux Integration Services Version v3.2 for Hyper-V - 日本語



簡単な説明

日本語版のダウンロードの手引きは現在準備中です。現在のところ英語版のガイドのみご覧いただけます。

このページの内容

- ↓ [ダウンロード情報](#)
- ↓ [概要](#)
- ↓ [システム要件](#)
- ↓ [注意事項](#)
- ↓ [このファイルをダウンロードした人は、次の製品もダウンロードしています。](#)



ダウンロードファイルについて

下記は、このダウンロードに含まれている各ファイルへのリンクです。該当するファイルをダウンロードしてください。

| ファイル名 | サイズ | 以下のファイルをダウンロード |
|---|--------|------------------------|
| Linux IC v3.2.iso | 2.2 MB | ダウンロード |
| Linux Integration Services v3.2 Read Me.pdf | 280 KB | ダウンロード |

Linux カーネルに貢献する企業のリストに登場 (17位)



The Linux Foundation が Linux 開発の年次レポートを公開

By Linux Foundation - April 4, 2012 - 8:23午前

Linux カーネル開発: その開発スピード、開発者、および支援者は?

2012年4月3日 サンフランシスコ発 - Linuxの成長促進に取り組むグローバルな非営利団体である The Linux Foundation (略称: LF) は、『Linuxカーネル開発: その開発スピード、開発者、および支援者は?』の最新レポートの公開を発表しました。

このレポートは年次ベースで公開されており、Linuxのカーネル開発の過程や、コンピューター市場最大の共同開発プロジェクトを定義する活動内容がわかります。このレポートは、Linuxカーネル 3.2 公開版までの作業をカバーしており、特に前回の2010年12月版レポートからこの公開版まで(つまり 2.6.36 から 3.2 まで)に行われた作業を重点的に取り上げています。



最近のBlogエントリー



[Miss our Collaboration or Legal Summits? Here are some resources](#)

April 14, 2012



[Announcing New Open Compliance Template](#)

April 4, 2012



[How is Linux Built? Our new report and video.](#)

April 4, 2012

- **Microsoft が、Linux カーネルに貢献する企業のリストに初めて姿を現しました。**かつて Linux を「癌」と呼んだこの企業が第 17 位にランキングされ、今では自社の仮想化活動とカスタマーをサポートするために共同開発モデルで連携しています。Linux は遍在の域に達し、企業コンピューティング市場もモバイル コンピューティング市場も Linux OS に依存しているため、Microsoft も明らかに変わりつつあります。

マイクロソフトはもう「Windowsだけ、.NETだけ」ではありません

Windows / .NET系の方々

- Hadoop を活用するには、UNIX / Java の知識があるに越したことはありません
- 是非「あちら側」にも親しんでください
- .NET ができれば Java は簡単です

UNIX / Java 系の方々

- 今後、Hadoop は Windows でもスムーズに動くようになります
- 是非「こちら側」も覗いてみてください
- 意外な発見が色々あるはずです
- Java ができれば .NET は簡単です

ありがとう
ございました

Microsoft[®]