

Universidad Autónoma de Aguascalientes
Propuesta de curso de tecnologías Cloud Computing y Big Data

Elaboró: Luis Eduardo Bautista Villalpando, PhD.

Objetivo: Introducción, aplicación y administración de tecnologías emergentes en computo distribuido relacionados a Cloud Computing y Big Data como servicios sobre demanda, vitalización y análisis de datos.

1. Introducción a Cloud Computing
 - 1.1. ¿Qué es Cloud Computing?
 - 1.2. Servicios en Cloud Computing (SaaS, PaaS, IaaS, NaaS)
 - 1.3. Cloud Computing y Big Data
 - 1.4. Introducción a la plataforma Hadoop
 - 1.5. Sub proyectos Hadoop (Avro, Cassandra, Chukwa, HBase, Hive, Mahout, Pig, ZooKeeper)
 - 1.6. El ecosistema Hadoop (Distribuciones - Cloudera, HortonWorks, IBM, etc.)
 - 1.7. Sistema de archivos distribuidos Hadoop (HDFS)
 - 1.8. Arquitectura del HDFS
 - 1.9. Mecanismo de replicación del HDFS
2. Framework para el desarrollo de aplicaciones MapReduce
 - 2.1. Arquitectura de aplicaciones MapReduce (Job tracker and Task tracker)
 - 2.2. Modelo de programación funcional
 - 2.3. Mappers y Reducers
 - 2.4. Etapas de ejecución del Framework
 - 2.5. Particionadores y combinarores
 - 2.6. Tipos y formatos de datos
3. Sistema de coordinación de aplicaciones distribuidas ZooKeeper
 - 3.1. ¿Qué es ZooKeeper?
 - 3.2. Mecanismo de prevención y restablecimiento de fallas en aplicaciones distribuidas
 - 3.3. Arquitectura de ZooKeeper
 - 3.4. Modelo de datos
 - 3.5. Interface de programación de aplicaciones (API)
 - 3.6. Bloqueo y ACL's con ZooKeeper
4. HBase, sistema de Base de Datos para Big Data
 - 4.1. RDBMS y almacenamiento para Big Data
 - 4.2. Vistas conceptuales y físicas
 - 4.3. Estructura de tablas (renglones, columnas, familias y celdas)
 - 4.4. Modelo de datos para Operaciones
 - 4.5. Esquemas (llaves, versiones, tipos de datos soportados)

- 4.6 Joins y queries alternativos
- 4.7 Integración de HBase y MapReduce

Recursos:

- Hadoop, The Definitive Guide, O'Reilly / Yahoo Press, by Tom White
- HBase, The Definitive Guide, O'Reilly, by Lars George
- Data-intensive Text Processing with MapReduce, Morgan & Claypool, by Jimmy Lin and Chris Dyer (<http://www.umi.acs.umd.edu/~jimmylin/>)
- Hadoop Project: <http://hadoop.apache.org/>
- Cloudera Hadoop Distribution:
<https://ccp.cloudera.com/display/SUPPORT/Downloads>

Papers:

- Jeffrey Dean and Sanjay Ghemawat. (2004) MapReduce: Simplified Data Processing on Large Clusters. Proceedings of the 6th Symposium on Operating System Design and Implementation (OSDI 2004), pages 137-150.
- Sanjay Ghemawat, Howard Gobioff, and Shun-Tak Leung. (2003) The Google File System. Proceedings of the 19th ACM Symposium on Operating Systems Principles (SOSP-03), pages 29-43.
- Jeffrey Dean and Sanjay Ghemawat. (2010) MapReduce: A Flexible Data Processing Tool. Communications of the ACM, 53(1):72-77.
- Fay Chang, Jeffrey Dean, Sanjay Ghemawat, Wilson C. Hsieh, Deborah A. Wallach, Michael Burrows, Tushar Chandra, Andrew Fikes, and Robert Gruber. (2006) Bigtable: A Distributed Storage System for Structured Data. Proceedings of the 7th Symposium on Operating System Design and Implementation (OSDI 2006), pages 205-218.