



Instalación de **Dspace**

Deploy de un repositorio básico
con Dspace 3.0



Bloque 2.2 - Contenido

1. Instalación de requisitos
2. Instalación de Dspace
 - Descarga, Compilación y empaquetado
 - Instalación
 - Activación de xmlworkflow, discovery
 - Deploy
3. Uso desde consola: comando Dspace y Cronjobs
4. Backup
5. Dspace en ejecución: logs, jvm
6. Entorno de debug





Requisitos (1) - PostgreSQL

- Se puede utilizar PostgreSQL 8.4+ y Oracle 10g+

- Instalación:

```
debian* --> apt-get install postgresql
```

Configuración: /etc/postgresql/x.y/main/

- Configuración general: postgresql.conf
- Reglas de autorización de usuarios por origen: pg_hba.conf

Tip: Creación de un superusuario

```
sudo -u postgres createuser --superuser $USER  
sudo -u postgres psql  
#\password $USER
```





Requisitos (2) - java JDK

- Dspace 3.x: OpenJDK 6, OpenJDK 7, Oracle Java 6 u Oracle Java 7
 - apt-get install **openjdk-6-jdk**
- Dspace <= 1.8.2: Oracle Java 6

La licencia de Oracle no permite la redistribución de los paquetes java*. Para instalar Oracle Java 6 o7, es necesario descargarlos y compilarlos.

- Alternativa 1 (<http://www.webupd8.org/2012/11/oracle-sun-java-6-installer-available.html>):
*sudo add-apt-repository ppa:webupd8team/java
sudo apt-get update
sudo apt-get install oracle-java6-installer*
- Alternativa 2 (<https://github.com/flexiondotorg/oab-java6>)
sudo apt-get purge sun-java
mkdir ~/src && cd ~/src
git clone https://github.com/flexiondotorg/oab-java6.git
cd ~/src/oab-java6 && sudo ./oab-java.sh
sudo apt-get install sun-java6-plugin sun-java6-jre sun-java6-bin sun-java6-jdk
#LOG: tail -f ~/src/oab-java6/oab-java.sh.log*





Requisitos (3) - WebContainer

Dspace funciona sobre Jetty, Tomcat, Caucho Resin o casi cualquier web container.

- Instalación: apt-get install tomcat
 - Configuración
 - /etc/default/tomcat7
JAVA_HOME="/usr/lib/jvm/java-6-oracle" #Si no se usa la OpenJDK
 - /etc/tomcat7/server.xml
- ```
<Connector port="8080" protocol="HTTP/1.1"
connectionTimeout="20000" URIEncoding="UTF-8" redirectPort="8443" />
```



# Requisitos (4) - Otras dependencias

- Maven: compilación, empaquetado, filtrado de archivos y generación del paquete de instalación.  
*apt-get install maven  
# maven2 o maven3*
- Ant: automatización de procesos de instalación y actualización.  
*apt-get install ant ant-contrib*
- Git: versionado distribuido de código fuente  
*apt-get install git*





# Instalación (1) - Descarga

Versión reducida (dspace-release-3.0-rc3):

- suficiente para personalización de temas
- Recomendado para instalaciones planas con personalizaciones de temas y traducciones

Versión completa (dspace-source-3.0-rc3)

- contiene todos los módulos de dspace para compilar
- permite modificar cualquier módulo
- Recomendado para instalaciones más complejas, con redefinición de módulos o directa del core

Es posible descargar la versión completa del HEAD desde github <https://github.com/DSpace/DSpace/archive/master.zip> o de un release/rc desde sourceforge <http://sourceforge.net/projects/dspace/files/>





# Instalación (2) - Usuarios

- Crear un usuario para tomcat/dspace
  - adduser dspace
  - es conveniente vincular los usuarios de tomcat y dspace para evitar **conflictos de permisos**:
    - con mismo grupo y umask: (no funciona con ubuntu y tomcat)
    - con mismo username: menos elegante pero sí funciona.

```
$TOMCAT_USER, $TOMCAT_GROUP
```

```
sudo find -L /var/lib/tomcat7/ -user tomcat7 -exec chown dspace {} \; -print
sudo find -L /var/lib/tomcat7/ -group tomcat7 -exec chgrp dspace {} \; -print
```

- Creación del user en postgres y base de datos
  - sudo -u postgres createuser -d -R -S -P dspace
  - sudo -u dspace createdb -E UNICODE dspace





# Instalación (3) - Creación de directorios

- Descomprimir en \${dspace-src}
  - tar -xzf dspace-release-3.0-rc3.tar.gz
- Directorio de instalación \${dspace.dir}
  - ejemplos: /opt/dspace , /var/dspace , /home/dspace
    - `mkdir ${dspace.dir}`
    - `sudo chown dspace.dspace ${dspace.dir}`
  - por default alojará casi todos los datos de dspace: assetstore, logs de aplicación, datos de solr
  - Los datos de postgres, logs de tomcat y apache2, quedan afuera.





# Instalación (4) - build.properties

- A partir de 3.0
  - simplifica el proceso de desarrollo
  - posibilidad de usar múltiples entornos
    - -Denv=dev --> dev.properties
  - para compilación. Luego no existe más
  - Atención: **no** eliminar properties
- Editar [dspace-source]/build.properties

dspace.dir = /var/dspace

dspace.hostname = localhost

dspace.baseUrl = localhost:8080

dspace.name = Mi Repositorio de pruebas

solr.server = localhost:8080/solr

default.language = es

...

db.url=jdbc:postgresql://localhost:5432/dspace

db.username=dspace

db.password=dspace



# Instalación (5) - Compilación, empaquetado e instalación

- **Compilación y empaquetado maven**

- cd [dspace-src]
- mvn package

- **Instalación vía ant**

- cd [dspace-source]/dspace/target/dspace-3.0-rc3-build
- ant fresh\_install

- **Revisar permisos de \${dspace.dir}**

- chmod -R ug+rw,o-w log assetstore upload solr exports reports
- chown -R dspace \${dspace.dir}

- **Crear usuario administrador**

- \${dspace.dir}/bin/dspace create-administrator

*TIP: para evitar conflictos de permisos, se recomienda utilizar siempre el usuario dspace para todas las tareas.*





# Activación de XMLWorkflow

- Actualización del Schema de la BBDD

- *dspace dsrun org.dspace.storage.rdbms.InitializeDatabase etc/postgres/xmlworkflow/xml\_workflow.sql*
- *dspace dsrun org.dspace.storage.rdbms.InitializeDatabase etc/postgres/xmlworkflow/workflow\_migration.sql*

- Habilitación

- workflow: config/modules/workflow.cfg
  - workflow.framework=originalworkflow
  - + workflow.framework=xmlworkflow
- Aspectos: config/xmlui.xmap
  - <aspect name="Original Workflow" path="resource://aspects/Workflow/" />
  - + <aspect name="XMLWorkflow" path="resource://aspects/XMLWorkflow/" />

- Configuración

- config/workflow.xml

<https://wiki.duraspace.org/display/DSDOC3x/Configurable+Workflow>





# Activación de Discovery (1)

- Configuración del módulo
  - modules/discovery.cfg
    - solr.search.server = http://localhost:8080/solr/search
- Habilitar Aspecto XMLUI
  - sitemap.xmap
    - <aspect name="Discovery" path="resoource://aspects/Discovery/" />
- Agregar Event Listeners
  - dspace.cfg >  
event.dispatcher.default.consumers =  
versioning, search, browse, **discovery**, eperson, harvester





# Activación de Discovery (2)

- Deshabilitar últimos submissions de dspace
  - dspace.cfg >
    - recent.submissions.count = 0
- indexar los documentos por primera vez  
**(reindexar)**
  - ./bin/dspace update-discovery-index

<https://wiki.duraspace.org/display/DSDOC3x/Discovery#Discovery-EnablingDiscovery>





# Instalación (6) - Alternativas de Deploy

1. Copiar cada aplicación \${dspace.dir}/webapps/\* en \${tomcat.dir}/webapps/
2. Cambiar el appbase de tomcat a \${dspace.dir} /webapps/
3. Crear contextos para cada aplicación en server.xml

```
<Context path="/xmlui" docBase="${dspace.dir}/webapps/xmlui"
debug="0" reloadable="true" cachingAllowed="false" allowLinking="true"/>
```
4. Crear link simbólicos para cada aplicación (+simple)  
ln -s \${dspace.dir}/webapps/xmlui \${tomcat.dir}/webapps/xmlui  
ln -s \${dspace.dir}/webapps/oai \${tomcat.dir}/webapps/oai  
ln -s \${dspace.dir}/webapps/solr \${tomcat.dir}/webapps/solr

Si se desea acceder a partir de /, debe reemplazarse el directorio ROOT de \${tomcat.dir}/webapps/ROOT



# Instalación (7) - Dspace en puerto 80

1. Cambiar el puerto del conector HTTP de tomcat
  - a. + simple
  - b. - configuración limitada
2. Configurar un proxy reverso desde un servidor web

Ejemplo con apache2, mod\_proxy y mod\_proxy\_ajp:

- a. Habilitar ajp en tomcat (server.xml):

```
<Connector port="8009" protocol="AJP/1.3" redirectPort="8443" />
```

- b. Habilitar módulos en apache2: "a2enmod proxy proxy\_ajp"

- c. Deshabilitar forward proxy: "ProxyRequests Off"

A) Con Location

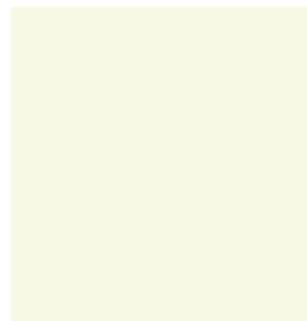
```
<Location />
ProxyPass ajp://localhost:8009/ retry=10
ProxyPassReverse ajp://localhost:8009/
</Location>
```

B) Con mod\_rewrite

```
RewriteCond %{REQUEST_FILENAME} !-f
RewriteRule ^(.*)$ ajp://localhost:8009/$1 [P]
```



# Comando *dspace*, *Cronjobs*





# Comando *dspace*

- Script shell (`#!/bin/sh`)
  - Inicia una nueva instancia de la JVM
  - Utiliza sus propios parámetros de VM:  
tamaño de pila, PermGen, etc
  - incluye el directorio **{dspace.dir}/lib** en el  
classpath
- Uso
  - `./dspace tarea parametros`
  - `./dspace --help`
  - `./dspace tarea --help`





# Comando *dspace*

## Orden: **create-administrator**

- Se usa para crear un usuario Administrador en el sistema
- Debe invocarse luego de la instalación para crear el primer usuario en el sistema





# Comando *dspace*

## Orden: curate

Ejecuta una "curation task" para realizar algún tipo de análisis o modificación sobre los ítems

Puede aplicarse sobre:

- Repositorio completo
- Una comunidad específica
- Una colección específica
- Un ítem específico





# Comando *dspace*

## Orden: curate, ejemplos

### Ejemplos de curation tasks

- Verificación de links muertos
- Validaciones de integridad de datos
- Análisis de formatos de archivos usados
- Análisis de los archivos en busca de virus
- etc.



# Comando dspace Órdenes para estadísticas

- Se utilizan para recopilar información estadística de acceso, descargas, etc.
- Se realiza un análisis de los logs de DSpace  
 `${dspace.dir}/logs/stats-*.log`
- Existen múltiples comandos asociados: stat-general, stat-initial, stat-monthly, stat-report-general, stats-utils, etc



# **Comando dspace**

## **Orden: update-discovery-index**

- Actualiza el índice de búsquedas de Apache Solr (**/search**)
- Se utiliza cuando es necesario indexar por primera vez el repositorio o cuando se desea reindexarlo todo.





# Comando dspace

## Orden: oai

- Controla el módulo OAI 2.0
  - import:
    - Actualiza el índice de Apache Solr (**/oai**)
    - documentos indexados en /oai
    - necesaria periódicamente
    - ejecución frecuente (según el movimiento del repositorio)
  - clean-cache
    - vacía la cache
    - necesario ante cambios en mapeos XSL





# Comando dspace

## Orden: dsrun

- Ejecuta una clase parametrizable
  - \${dspace.dir}/bin/dspace dsrun *fqcn arguments*
    - *fqcn* es el nombre de la clase completo (incluido el package) que implementa un método main()
- Permite definir cualquier tipo de clase para luego ejecutarlas desde la línea de comandos. Ejemplos:
  - import/export de registries
    - ./bin/dspace dsrun org.dspace.administer.MetadataImporter -f config/registries/sedici-metadata.xml
  - scripts de Base de datos
    - ./bin/dspace dsrun org.dspace.storage.rdbms.InitializeDatabase xml\_workflow.sql



# Comando dspace

## Otras órdenes

- **checker**: para verificar la integridad del assetstore
- **import/export**: Importación/ Exportación de ítems o colecciones
- **filter-media**: aplica el proceso de mediafilter sobre un conjunto específico de items
- **harvest**: gestiona las cosechas de las colecciones cuyos datos son recolectados vía OAI-PMH
- **metadata-export/metadata-import**: permite importar/exportar un csv con metadatos
- Muchos más: gestión de handle, índices, discovery, usuarios, importación de usuarios y colecciones, etc



# Cronjobs (1) - Acciones sobre bitstreams

- IMPORTANTE: Las tareas deben ejecutarse con el usuario de dspace. No usar root  
*crontab -u dspace -e*
- Procesamiento con plugins de mediafilter para:
  - generación de thumbnails en base a la primer página de los pdf
  - generación de thumbnails a partir de imágenes JPEG
  - extracción de texto de archivos pdf, word, powerpoint, html *\${dspace.dir}/bin/dspace filter-media*
- Chequeo de checksums y reporte  
 *\${dspace.dir}/bin/dspace checker -lp*  
 *\${dspace.dir}/bin/dspace checker-emailer -c*





# Cronjobs (2) - Actualizaciones diarias

- OAI
  - Actualización de datos del core OAI de solr  
 `${dspace.dir}/bin/dspace oai import`
- Embargo-Lifter
  - Revisa los ítems que tienen fecha de fin de embargo y *levanta el embargo*  
 `${dspace.dir}/bin/dspace embargo-lifter`
- Limpieza de la BBDD
  - `vacuumdb --analyze dspace > /dev/null 2>&1`
- Sitemaps
  - Actualización de archivos de sitemap (para crawlers)  
 `${dspace.dir}/bin/dspace generate-sitemaps`





# Cronjobs (3) - Acciones para estadísticas

- Análisis diario de accesos

`${dspace.dir}/bin/dspace stat-general`

`${dspace.dir}/bin/dspace stat-monthly`

`${dspace.dir}/bin/dspace stat-report-general`

`${dspace.dir}/bin/dspace stat-report-monthly`

- Actualización de ips de spiders

- descarga listados de de ips de internet para poder filtrarlos en los logs

`${dspace.dir}/bin/dspace stats-util -u`

- Marcado de accesos de spiders

- para poder distinguirlos en las estadísticas

`${dspace.dir}/bin/dspace stats-util -m`





# Cronjobs (3) - Acciones para estadísticas

- GEOLITE
  - Actualización de BBDD de geolocalización para estadísticas

```
ant -f ${dspace-src}/distribution/target/dspace-.../build.xml update_geolite
```

- Envío de mails de suscripción
  - de suscripciones de usuarios a colecciones

```
 ${dspace.dir}/bin/dspace sub-daily
```





# Backups (1) - Alternativa 1: AIP

- AIP (Archival Information Package)

```
 ${dspace.dir}/bin/dspace packager --disseminate -a -t AIP -e arieljlira@gmail.com -u -i 10915/0 /root/aip-site.zip
```

- Archivos de datos

- \${dspace.dir}/var

- Configuración y logs

- \${dspace.dir}/config y \${dspace.dir}/logs



# Backups (2) - Alternativa 2, Dump+rsync

- Archivos de datos
  - \${dspace.dir}/assetstore
  - \${dspace.dir}/var
- Configuración y logs
  - \${dspace.dir}/config y \${dspace.dir}/logs !!!
- Postgres
  - Dump

```
pg_dump -h localhost -U {dbuser} -a -b -x -O -f {output_file.tar} -F t {dbname}
```

#Pasar el dump a SQL, para que sirva en cualquier versión de PostgreSQL

```
pg_restore -Ft -O -f {output_file.sql} {output_file.tar}
```

- Restore

```
dropdb {dbname}
```

```
createdb {dbname}
```

```
psql -h localhost -U {dbuser} -d {dbname} -f {output_file.sql}
```





# Backups (3) - Caminos posibles

- Backups periódicos
  - AIP
  - archivos
  - configuraciones y logs
  - solr
- Herramientas complementarias
  - Bacula / backuppc / backupninja / etc
  - Backups externos: AmazonS3, Duracloud, etc
- Ejemplo de Plan de backup
  - backup de AIP semanal
  - backup rsync + dump **onserver** c/12 hs
  - backup rsync + dump **offserver** c/24hs
  - backup offsite semanal aip+rsync+dump



# Dspace en Ejecución





# Herramientas para mantenimiento

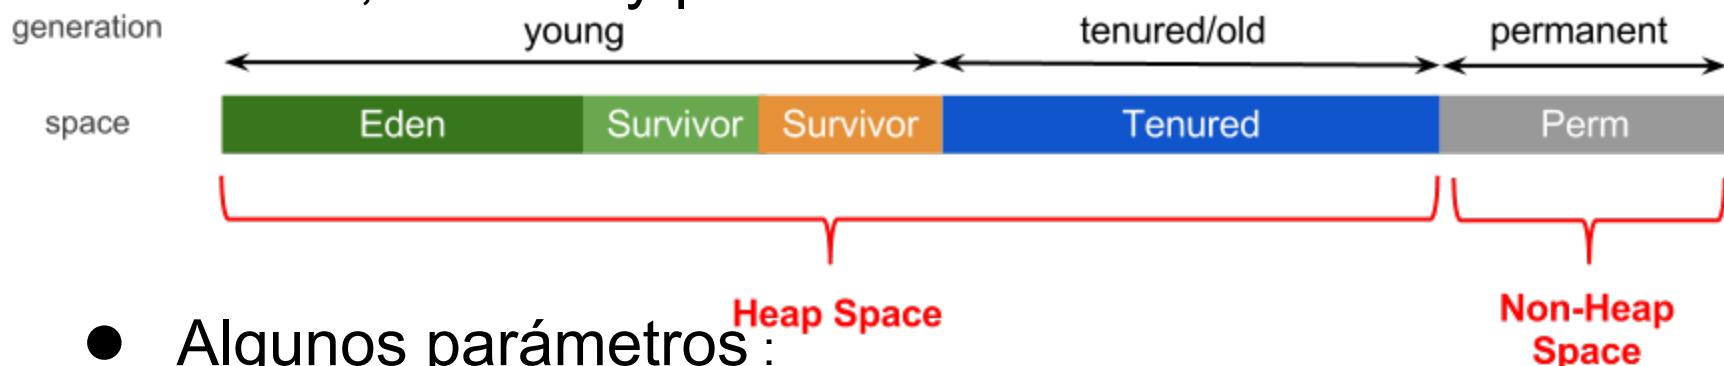
- Postgres
  - pgadmin3
  - phppgadmin
- Detección de excepciones
  - monitoreo de dspace.log y catalina.\*
  - reporte de excepciones
- Monitoreo del servicio
  - watchdog (interno, estado del servidor)
  - monit (interno, estado de servicios)
  - pingdom, nagios, etc (externo)





# Uso de Memoria en la JVM

- La jvm aloca memoria del SO y gestiona internamente la liberación y alocación de memoria para objetos, clases, threads y para sí misma.



- Algunos parámetros :
  - Tamaño de heap: Máximo (**-Xmx1548m**) , mínimo inicial(**-Xms512m**)
  - Tamaño de Perm space: Máximo (**-XX:MaxPermSize**), mínimo inicial **-XX:PermSize=128m**
- Selección del GC:
  - **-XX:+UseSerialGC** --> aplicaciones muy chicas
  - **-XX:+UseParallelGC**
  - **-XX:+UseConcMarkSweepGC**





# Uso de Memoria en Dspace

- En el webcontainer
  - /etc/defaults/tomcat7
    - JAVA\_OPTS="... -Xmx1548m -XX:PermSize=128m ..."
- En las tareas ejecutadas desde consola
  - Handle Server:
    - bin/start-handle-server
  - Comando dspace y Cronjobs
    - bin/dspace
- Es posible predefinir JAVA\_OPTS antes de cada tarea





# Causas típicas de OutOfMemory

- OutOfMemoryError: PermGen space
  - PermSize muy chico
- OutOfMemoryError: Java heap size
  - Xmx muy chico
  - Loops en código
  - Recursiones muy largas con creación de muchos objetos
  - Uso en exceso de variables estáticas
- Otros posibles, menos frecuentes
  - Demasiados threads
  - Arrays gigantes
- Herramientas de análisis
  - livianas y free: jvmstat+visualgc, jmap+jhat
  - completas y pagas: yourkit y muchisimas más.

<http://blog.codecentric.de/en/2010/01/the-java-memory-architecture-1-act/>

<http://javarevisited.blogspot.com.ar/2011/05/java-heap-space-memory-size-jvm.html>

<http://java-source.net/open-source/profilers>





# Logging - Log de aplicación vía log4j

- Configuración
  - config/log4j.properties
  - log4j-handle-plugin.properties
- Appenders preconfigurados
  - \$dspace.dir/log/dspace.log
  - \$dspace.dir/log/checker.log
  - \$dspace.dir/log/cocoon.log
  - \$dspace.dir/log/handle-plugin.log



# Logging - Log de aplicación vía log4j

- Log personalizado, ejemplo

*log4j.logger.ar.edu.unlp.sedici=INFO, A4*

*log4j.logger.ar.edu.unlp.sedici.xyz=WARN*

*log4j.additivity.ar.edu.unlp.sedici=false*

*log4j.appendер.A4=org.dspace.app.util.DailyFileAppender*

*log4j.appendер.A4.File=\${dspace.dir}/log/sedici.log*

*# yyyy-MM-DD for daily log files, or yyyy-MM for monthly files*

*log4j.appendер.A4.DatePattern=yyyy-MM*

*log4j.appendер.A4.MaxLogs=3*

*log4j.appendер.A4.layout=org.apache.log4j.PatternLayout*

*log4j.appendер.A4.layout.ConversionPattern=%d %-5p %c @ %m%n*



# Logging - Logs de tomcat y otros

## Tomcat

- Logs predefinidos: /var/log/tomcat7
  - catalina.out
  - catalina.yyyy-mm-dd.log
  - localhost.yyyy-mm-dd.log
- Configuración
  - logging.properties
  - server.xml (Access log, opcional)

```
<Valve className="org.apache.catalina.valves.AccessLogValve" directory="logs"
prefix="localhost_access_log." suffix=".txt" pattern="%h %l %u \"%r\" %s %b" />
```

- Para mejorar el logging, es posible habilitar **log4j**



# Entorno de desarrollo

- Eclipse 3.5 (Galileo) o superior.
- Plugins:
  - Egit
  - m2e Maven integration for Eclipse
  - m2e-Egit Maven SCM handler for EGit (opcional)
- Clone del repositorio Dspace:
  - a. EGit>clone Git repository
    - i. git://github.com/DSpace/DSpace.git
    - ii. seleccionar branch master
  - b. importar proyectos maven:
    - i. con Maven SCM connector for EGit: EGit>import maven projects
    - ii. sin Maven SCM connector: Java> import existing maven projects





# Lectura de stacktraces

- Elementos fundamentales
  - Cause
  - Clase que genera el error y número de línea
- Información extra, XMLUI
  - URL causante
  - parámetros de request
  - usuario causante e info de sesión
  - ip de origen
- Ver ejemplo

...

# Muchas gracias

*Dudas y comentarios?*  
***alira@sedici.unlp.edu.ar***  
***nestor@sedici.unlp.edu.ar***  
***marisa.degiusti@sedici.unlp.edu.ar***