# INTRODUZIONE A

Solr

+


APACHE ZooKeeper™

Antonio Scaiella

21 Gennaio 2022

Corso di Information Retrieval A.A. 2021/2022

# AGENDA

- Introduzione ad Apache Zookeeper
  - Cos’è Apache Zookeeper?
  - Caratteristiche
  - Architettura
- Installazione Zookeeper & SolR Cloud mode
  - Download
  - GUI
- Creazione Collection
- Indexing and searching

Antonio Scaiella
Gennaio 2022

# INTRODUZIONE-ZOOKEEPER

**Apache ZooKeeper è un software, di proprietà di The Apache Software Fondation, in grado di fornire supporto per la gestione e la sincronizzazione di sistemi distribuiti**

È robusto poiché i dati persistenti sono distribuiti tra più nodi e perchè un ***client*** (esempio SolR) si connette a uno di essi potendo migrando se un nodo fallisce; fintanto che una rigida maggioranza di nodi Zookeeper funziona, l'insieme di nodi ZooKeeper è attivo. In particolare, un nodo master viene scelto dinamicamente per consenso all'interno dell'ensemble; se il nodo principale cade, il ruolo del master passa a un altro nodo.

Antonio Scaiella
Gennaio 2022

# INTRODUZIONE-SOLRCLOUD

**Features of Solr Cloud mode**

- Fault tollerant
- Optimized for high traffic. (Affidabilità)
- Easy sharding & replication (Scalabilità & Affidabilità )
- Zookeper (Load Balancing)

- In poche parole:

Solr Cloud è un sistema in cui i dati sono organizzati in più parti, o frammenti, che possono essere ospitati su più macchine, con repliche che forniscono ridondanza sia per la scalabilità che per la tolleranza agli errori. ZooKeeper aiuta a gestire la struttura generale in modo che sia l'indicizzazione che la ricerca possono essere indirizzate correttamente.

Antonio Scaiella
Gennaio 2022

# INTRODUZIONE

**Core & collection**

La **Collection** è un indice logico distribuito su più server. Il **Core** è quella parte del server che esegue una **collection**. Nella ricerca non distribuita, il server singolo che esegue Solr può avere più Collection e ciascuna di queste è anche un **Core**. Quindi la **Collection** e il **Core** sono gli stessi se la ricerca non è distribuita.

Solr Core

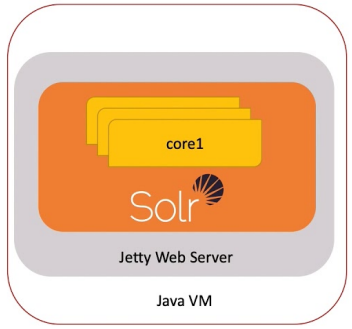


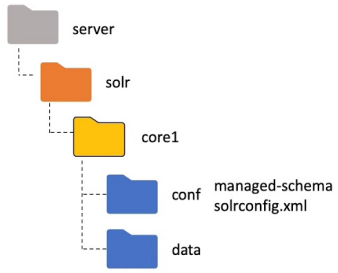


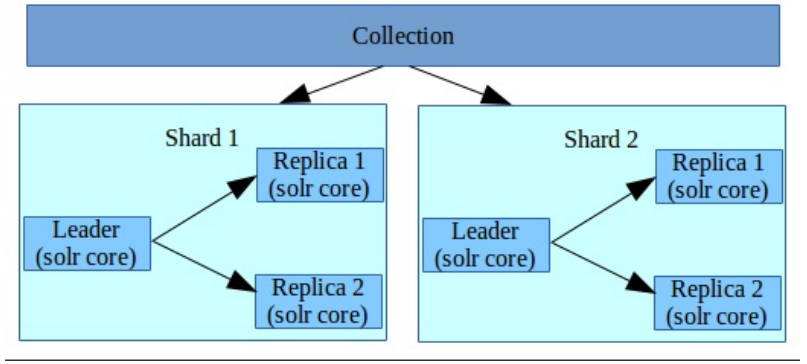


Antonio Scaiella
Gennaio 2022

# INTRODUZIONE

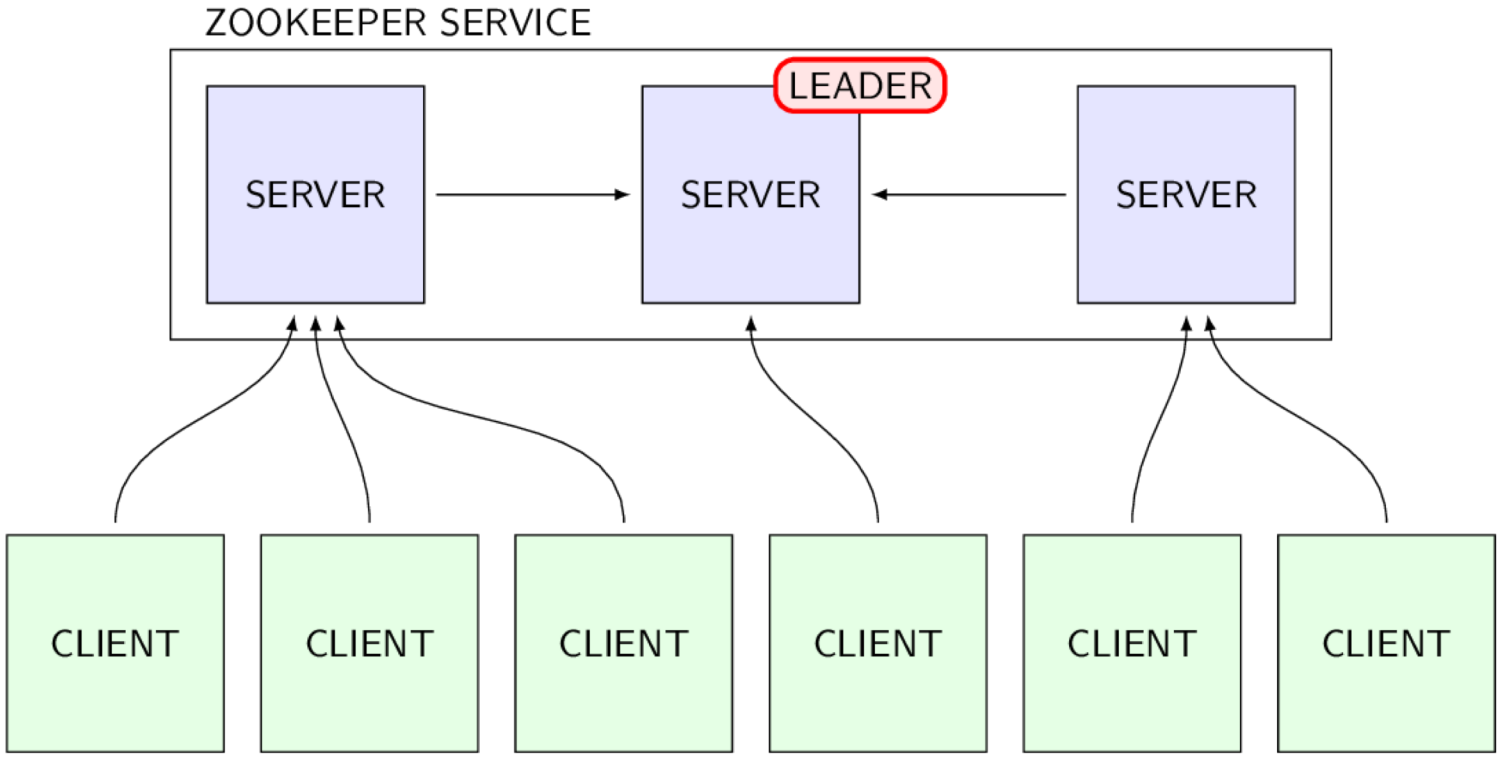


Based on figure from ZooKeeper web ... https://zookeeper.apache.org/doc/current/images/zkservice.jpg

Antonio Scaiella
Gennaio 2022

# INTRODUZIONE

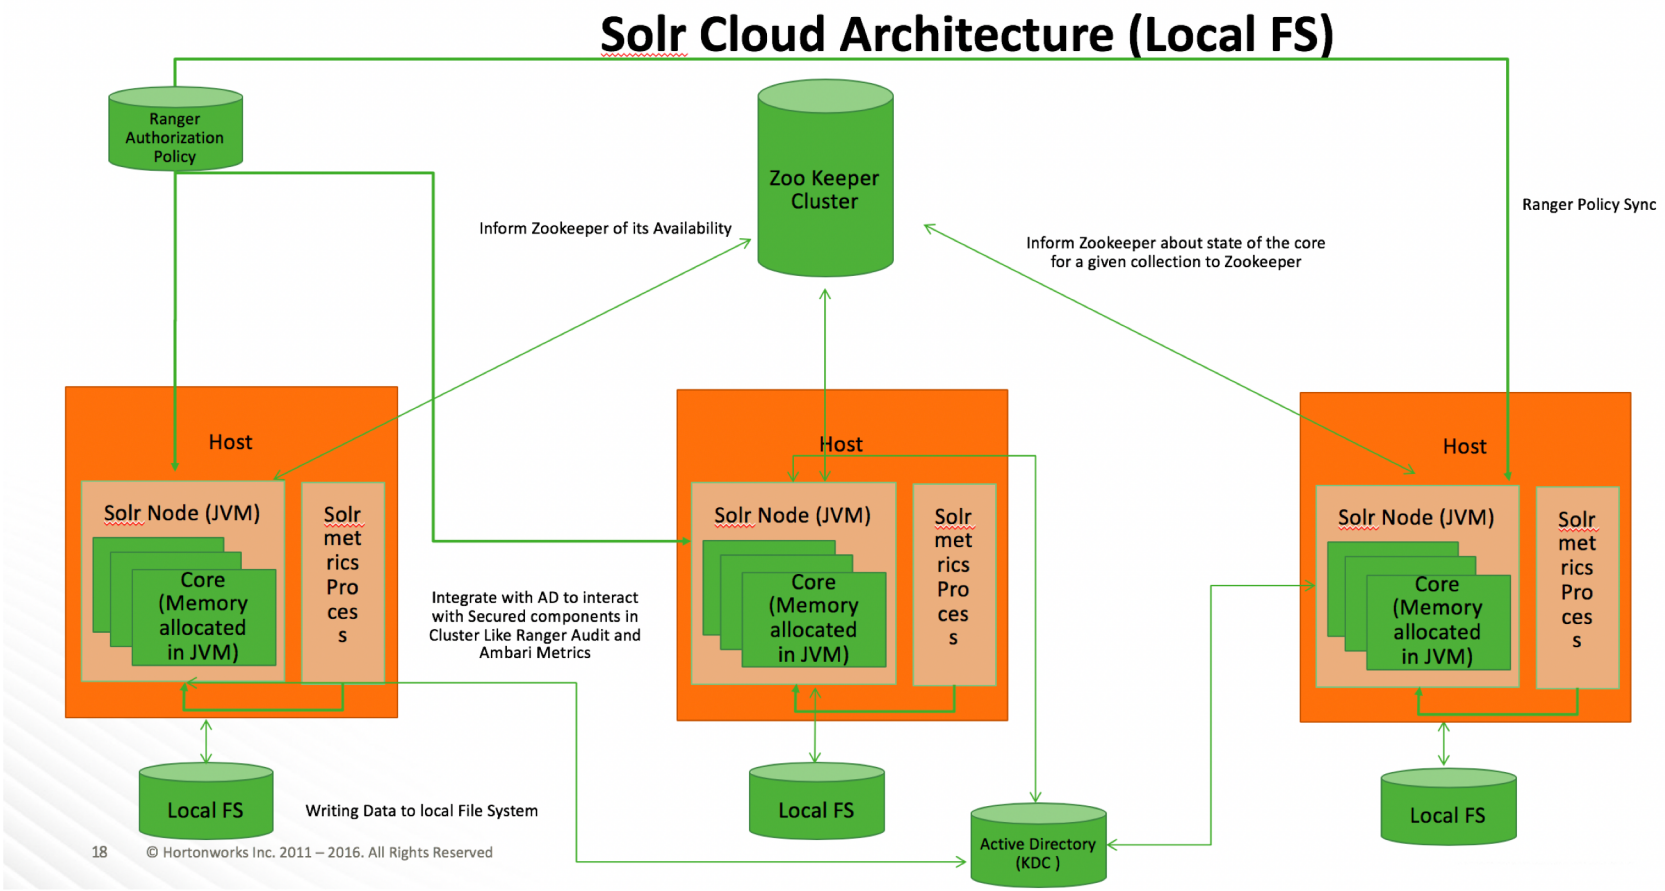


Antonio Scaiella
Gennaio 2022

# INSTALLAZIONE

Download Solr

- Windows
  https://solr.apache.org/downloads.html

  Scarichiamo
  Binary releases: solr-8.11.1.zip
  Ed estraiamo il contenuto
- Linux
  wget https://dlcdn.apache.org/lucene/solr/8.11.1/solr-8.11.1.tgz
  tar xvzf solr-8.11.1.tgz

Antonio Scaiella
Gennaio 2022

# INSTALLAZIONE

Download Zookeeper

- Windows

  https://www.apache.org/dyn/closer.lua/zookeeper/zookeeper-3.6.3/apache-zookeeper-3.6.3-bin.tar.gz

  Scarichiamo https://dlcdn.apache.org/zookeeper/zookeeper-3.6.3/apache-zookeeper-3.6.3-bin.tar.gz ed estraiamo
- Linux

  wget https://dlcdn.apache.org/zookeeper/zookeeper-3.6.3/apache-zookeeper-3.6.3-bin.tar.gz

  tar –xvzf apache-zookeeper-3.6.3-bin.tar.gz

Antonio Scaiella
Gennaio 2022

# CONFIGURAZIONE

- E' opportuno avere sempre un numero dispari >=3 di istanze zookeeper su macchine diverse.
- Il numero di nodi Solr, invece, dipende da quanta replicabilità/scalabilità/affidabilità si vuole garantire.

- Nel nostro caso, per questioni pratiche, andremo a creare sulla stessa macchina 3 istanze di Zookeeper e 3 di Solr in ascolto su porte diverse.

- In uno scenario reale sarebbe opportuno avere, per il nostro caso, almeno 3 macchine e su ognuna di esse configurare una coppia zookeeper/solr.
  - Il massimo sarebbe, sempre per il nostro caso, avere 6 macchine, 3 dedicate a zookeeper e 3 a Solr per garantire il massimo dell'affidabilità

Antonio Scaiella
Gennaio 2022

# CONFIGURAZIONE

- Creiamo una directory "zookeeper" e copiamo al suo interno apache-zookeeper-3.6.3-bin

- All'interno della directory "zookeeper" digitiamo:
  - `cp apache-zookeeper-3.6.3-bin/conf/zoo_sample.cfg apache-zookeeper-3.6.3-bin/conf/zoo1.cfg`
  - `cp apache-zookeeper-3.6.3-bin/conf/zoo_sample.cfg apache-zookeeper-3.6.3-bin/conf/zoo2.cfg`
  - `cp apache-zookeeper-3.6.3-bin/conf/zoo_sample.cfg apache-zookeeper-3.6.3-bin/conf/zoo3.cfg`
  - `mkdir data1`
  - `mkdir data2`
  - `mkdir data3`
  - `mkdir logs`

Antonio Scaiella
Gennaio 2022

# CONFIGURAZIONE FILE ZOO1.CFG

- Apriamo zoo1.cfg e cancelliamo tutto il contenuto di default e settiamo:

```
tickTime=2000
initTime=10
initLimit=5
syncLimit=5
clientPort=2181
dataDir=/zookeeper/data1
server.1=ipdellamacchina:2888:3888
server.2=ipdellamacchina:4888:5888
server.3=ipdellamacchina:6888:7888
autopurge.snapRetainCount=3
autopurge.purgeInterval=1

4lw.commands.whitelist=mntr,conf,ruok
```

Antonio Scaiella
Gennaio 2022

# CONFIGURAZIONE FILE ZOO2.CFG

- Apriamo zoo2.cfg e cancelliamo tutto il contenuto di default e settiamo:

```
tickTime=2000
initTime=10
initLimit=5
syncLimit=5
clientPort=2182
dataDir=/zookeeper/data2
server.1=ipdellamacchina:2888:3888
server.2=ipdellamacchina:4888:5888
server.3=ipdellamacchina:6888:7888
autopurge.snapRetainCount=3
autopurge.purgeInterval=1

4lw.commands.whitelist=mntr,conf,ruok
```

Antonio Scaiella
Gennaio 2022

# CONFIGURAZIONE FILE ZOO3.CFG

- Apriamo zoo3.cfg e cancelliamo tutto il contenuto di default e settiamo:

```
tickTime=2000
initTime=10
initLimit=5
syncLimit=5
clientPort=2183
dataDir=/zookeeper/data3
server.1=ipdellamacchina:2888:3888
server.2=ipdellamacchina:4888:5888
server.3=ipdellamacchina:6888:7888
autopurge.snapRetainCount=3
autopurge.purgeInterval=1

4lw.commands.whitelist=mntr,conf,ruok
```

Antonio Scaiella
Gennaio 2022

# CONFIGURAZIONE LOGS

- creare "apache-zookeeper-3.6.3-bin/conf/zookeepr-env.sh"

- Al suo interno scrivere:

```
ZOO_LOG_DIR="/zookeeper/logs"

ZOO_LOG4J_PROP="INFO,ROLLINGFILE"

SERVER_JVMFLAGS="-Xms2048m -Xmx2048m -verbose:gc -XX:+PrintHeapAtGC -
XX:+PrintGCDetails -XX:+PrintGCDateStamps -XX:+PrintGCTimeStamps -
XX:+PrintTenuringDistribution -XX:+PrintGCApplicationStoppedTime -
Xloggc:$ZOO_LOG_DIR/zookeeper_gc.log -XX:+UseGCLogFileRotation -
XX:NumberOfGCLogFiles=9 -XX:GCLogFileSize=20M"
```

- In genrelae in `ZOO_LOG_DIR` va impostato il path alla cartella "logs" creata in precedenza

Antonio Scaiella
Gennaio 2022

# CONFIGURAZIONE MYID

- Creare in "data1" un file con nome `myid` senza estensione e al suo interno scrivere 1
- Creare in "data2" un file con nome `myid` senza estensione e al suo interno scrivere 2
- Creare in "data3" un file con nome `myid` senza estensione e al suo interno scrivere 3

Antonio Scaiella
Gennaio 2022

# AVVIO ZOOKEEPER

- Possiamo ora avviare le tre istanze di zookeeper:

```
bash apache-zookeeper-3.6.3-bin/bin/zkServer.sh start zoo1.cfg
bash apache-zookeeper-3.6.3-bin/bin/zkServer.sh start zoo2.cfg
bash apache-zookeeper-3.6.3-bin/bin/zkServer.sh start zoo3.cfg
```

Antonio Scaiella
Gennaio 2022

# RECAP

- A questo punto abbiamo 3 istanze di zookeeper che girano sulla stessa macchina.
- In uno scenario reale in cui abbiamo almeno 3 macchine da dedicare a zookeeper possiamo evitare di duplicare i file di configurazione zoo*.cfg e di creare varie cartelle "data". Inoltre è possibile mettere in ascolto tutte le istanze sulle stesse porte.
- Esempio:

  Supponiamo di avere a disposizione tre macchine: 10.5.0.30, 10.5.0.31, 10.5.0.32

  **Su ogni macchina :**

  - Creiamo una directory "zookeeper" e copiamo al suo interno apache-zookeeper-3.6.3-bin
  - **Digitiamo:** `cp apache-zookeeper-3.6.3-bin/conf/zoo_sample.cfg apache-zookeeper-3.6.3-bin/conf/zoo.cfg`
  - `mkdir data`
  - `mkdir logs`

Antonio Scaiella
Gennaio 2022

# RECAP

- **Su ogni macchina :**

  Apriamo zoo.cfg e cancelliamo tutto il contenuto di default e settiamo:

```
tickTime=2000
initTime=10
initLimit=5
syncLimit=5
clientPort=2181
dataDir=/zookeeper/data
server.1=10.5.0.30:2888:3888
server.2=10.5.0.31:2888:3888
server.3=10.5.0.32:2888:3888
autopurge.snapRetainCount=3
autopurge.purgeInterval=1
4lw.commands.whitelist=mntr,conf,ruok
```

Antonio Scaiella
Gennaio 2022

# RECAP

Soffermandoci su questa parte di configurazione:

```
server.1=10.5.0.30:2888:3888
server.2=10.5.0.31:2888:3888
server.3=10.5.0.32:2888:3888
```

Il numero dopo "server" è l'id della macchina ed è lo stesso numero che inseriremo poi nel file myid.

Antonio Scaiella
Gennaio 2022

# RECAP

- **<u>Su ogni macchina in base all'id assegnato :</u>**
- Creare in "data" un file con nome `myid` senza estensione e al suo interno scrivere l'id assegnato alla macchina

Antonio Scaiella
Gennaio 2022

# AVVIO SOLR CLOUD MODE

Spostiamoci nella directory "solr-8.11.1"
Innanzitutto impostare in in solr-8.11.1/bin/solr.in.sh :

```
SOLR_HOST="ipdellamacchina"
```

Nota:non scrivere "localhost"

Avviamo 3 istanze di solr

- `./bin/solr start -c -z ipdellamacchina1:clientPort1, ipdellamacchina2:clientPort2,ipdellamacchina3:clientPort3 -p 8983 -force`
- `./bin/solr start -c -z ipdellamacchina1:clientPort1, ipdellamacchina2:clientPort2,ipdellamacchina3:clientPort3 -p 8984 -force`
- `./bin/solr start -c -z ipdellamacchina1:clientPort1, ipdellamacchina2:clientPort2,ipdellamacchina3:clientPort3 -p 8985 -force`

Dove:

- -z indica la lista delle macchine e rispettiva porta che abbiamo inizializzato in precedenza.
- Ipdellamacchina1, ipdellamacchina2, ipdellamacchina3 nel nostro caso saranno uguali, mentre le porte saranno clientPort1:2181, clientPort2:2182, clientPort3:2183

Antonio Scaiella
Gennaio 2022

# AVVIO SOLR CLOUD MODE

Nel caso di 3 macchine diverse per solr noi avvieremo **su ogni macchina** :

- `./bin/solr start -c -z` *`ipdellamacchina1`*`:2181,` *`ipdellamacchina2`*`:` *`ipdellamacchina1`*`:2181,`*`ipdellamacchina3`*`:2181 -p 8983 -force`

- Quindi potremo avviare solr sulla porta 8983 per tutte le macchine, i zookeeper saranno in ascolto tutti sulla porta 2181 come discusso nel recap precedente e ciò che cambia è solamente gli ip delle macchine

Antonio Scaiella
Gennaio 2022

# Creazione Collection

- Da qualsiasi macchina che ospita solr possiamo digitare:

- `./bin/solr create -c mioesempio -s 1 -rf 3`

- Dove
  - -s indica il numero di shars desiderati
  - -rf indica il numero di repliche desiderate

Antonio Scaiella
Gennaio 2022

# Import Dataset di esempio

- Spostarsi in solr-8.11.1\example\exampledocs
    - java -jar -Dc=mioesempio post.jar *.xml

Antonio Scaiella
Gennaio 2022

# Modifiche dello schema

Nel caso di sorl in modalità Non cloud le modifiche allo schema o la lista di stopword, sinonimi e in generale tutto ciò che riguarda la configurazione vanno applicate nei file in :

```
solr-8.11.1\server\solr\mioesempio\conf
```

Se avviamo, invece, solr in modalità cloud e creiamo la nostra Collection, non troveremo più la configurazione al path sopracitato. Questo perché le configurazioni sono gestite da Zookeeper, quindi le modifiche vanno inviate a Zookeeper.

Antonio Scaiella
Gennaio 2022

# Download e aggiornamento dello schema

Possiamo verificare la configurazione esistente scaricandola da zookeeper con il comando:

```
./bin/solr zk downconfig -n mioesempio -d pathdidestinazione -z
ipdellamacchina1:clientPort1,
ipdellamacchina2:clientPort2,ipdellamacchina3:clientPort3
```

Ad esempio:

```
bin/solr zk downconfig -n mioeempio -d /opt/downlaod -z
10.5.0.31:2181,10.5.0.31:2181,10.5.0.31:2181
```

Antonio Scaiella
Gennaio 2022

# Download e aggiornamento dello schema

Dopo aver modificato la configurazione, secondo le nostre necessità, possiamo fare upload nel seguente modo:

- Da una delle macchine Solr spostiamoci nella directory:

`solr-8.11.1/server/scripts/cloud-scripts`

e digitiamo il comando:

```
./zkcli.sh -zkhost [host_macchina_zookeeper] -cmd upconfig -confdir
[pathDellaConfigurazione] -confname mioesempio
```

dove [host_macchina_zookeeper] è l'indirizzo di una delle macchine che ospita Zookeeper e [pathDellaConfigurazione] è la cartella conf. Ad esempio:

```
./zkcli.sh -zkhost 10.5.0.31 -cmd upconfig -confdir
/opt/configurazione/conf/ -confname mioesempio
```

Antonio Scaiella
Gennaio 2022

# Aggiungere Documenti con la Solr Web Interface