

SparkSQL - Transformations

```
sqlContext.textFile(
df = readTextFile(dataPath))
```

Créer un DataFrame à partir d'une collection Python (liste)

```
sqlContext.textFile(
df = readTextFile(dataPath,
['name', 'age']))
```

Créer un DataFrame à partir d'une collection Python (liste)

```
sqlContext.textFile(
df = readTextFile('files.txt'))
```

Créer un DataFrame à partir d'un fichier

```
people = sqlContext.textFile(
ageCol = people.age)
```

Créer un DataFrame à partir d'une colonne

```
df.select('*')
```

Sélectionner toutes les colonnes

```
df.select('name', 'age')
```

Sélectionner 1 ou plusieurs colonnes

```
df.select(df.name, df.age + 10).alias('age')
```

Sélectionner 2 colonnes, changer la valeur d'une colonne et renommer la colonne

```
df.drop(df.age)
```

Suppression d'une colonne.

```
df.drop(df.age)
```

Retourne un nouveau DataFrame

```
lambda a, b : a + b
```

Fonction lambda ou nommée et type du retour

```
slen = udf(lambda s: len(s), IntegerType())
```

Retourne un DataFrame dont les lignes respectent la/les condition(s)

```
inletSDF.filter(lambda s: sComment)
```

Retourne un DataFrame dont les lignes respectent la/les condition(s)

```
where (function)
```

Retourne un DataFrame avec les lignes uniques

```
df.distinct()
```

Retourne un DataFrame dans l'ordre croissant ou décroissant

```
orderBy(cols, *kw)
```

Retourne un DataFrame dans l'ordre croissant ou décroissant

```
df.sort("age", ascending = False)
```

Chaque élément est dans une nouvelle ligne

```
df.select(explode(df-
4.index))
```

```
df.select(explode(df-
4.index))
```

```
df.groupBy(df.name).agg({'*': 'count'}).collect()
```

```
df.groupBy(df.name).count()
```

```
df.groupBy().avg().collect()
```

```
df.groupBy('name').avg('age', 'grade').collect()
```

SparkSQL - Actions

```
df.show(n, truncate)
```

Affiche les n premières lignes du DataFrame

```
df.take(n)
```

Affiche les n premières lignes sous forme de une liste

```
df.collect()
```

Retourne les enregistrements sous forme de liste

```
df.count()
```

Retourne le nombre de lignes dans le DataFrame

```
df.describe(*cols)
```

Calcule les statistiques descriptives des colonnes numériques

```
lines = DF.cache()
```

Enregistre le DataFrame dans le cache donc pas besoin de réexécuter toutes les transformations et

```
he()
```

actions. A utiliser si on réutilise souvent le DataFrame.

```
ADDF.unionAll(bDF)
```

Concaténation de deux DataFrame

```
l(bDF)
```

!! ATTENTION !!

- S'assurer qu'on a assez d'espace dans le programme

"driver" pour utiliser

collect().

- Ne jamais utiliser collect() en production. Préférer take(n).