Data Science in Spark with Sparklyr : : CHEAT SHEET

イントロ

*sparklyr*とは*Apache SparkTM*へのインタフェースです. これは*dplyr*の完全なバックエンド機能や, *Spark SQL*ステートメントを用いたクエリの直接発行もオプションとして提供します. *sparklyr*によって*Spark MLib*や*H2O Sparkling Water*といった分散機械学習をオーケストレーションする事ができます.

*RStudio*デスクトップ版, サーバ版, *Pro*版の*version 1.044*から*sparklyr*パッケージへの統合サポートが開始されます. これによって*Spark*クラスタやローカルの*Spark*インスタンスの作成や接続管理を*IDE*内で行うことができます.

sparklyrとRStudioの統合

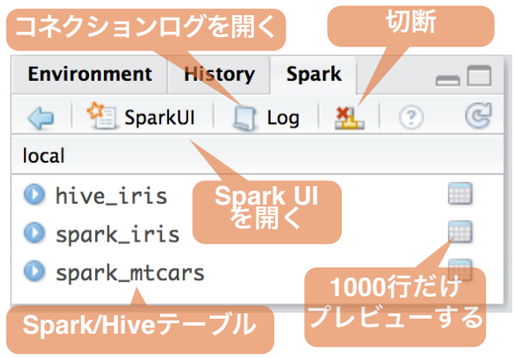

クラスタの展開

マネージドクラスタ

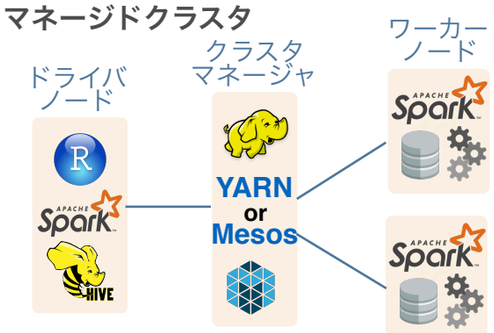

スタンドアロンクラスタ

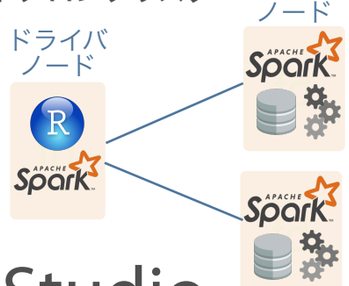

Spark + sparklyrを用いたデータサイエンスツールチェーン

R for Data Science, Grolemund & Wickham

事始め

ローカルモード (クラスタは不要)

1. Sparkのローカル版をインストール:
   spark_install ("2.0.1")
2. コネクションを開く
   sc <- spark_connect (master = "local")

Mesos管理クラスタ

1. RStudio ServerまたはProを既存のノードへインストール
2. クラスタのSparkディレクトリを指定する
3. コネクションを開く
   spark_connect(master="[mesos URL]", version = "1.6.2", spark_home = [Cluster's Spark path])

LIVYの利用 (実験段階)

1. Livy RESTアプリケーションをクラスタ上で起動させておく
2. コネクションを開く
   sc <- spark_connect(method = "livy", master = "http://host:port")

YARN管理クラスタ

1. RStudio ServerまたはProを既存のノードへインストールし, 可能であればエッジノードへもインストールする.
2. クラスタのSparkディレクトリを指定する. 通常、パスは次の場所である. "/usr/lib/spark"
3. コネクションを開く
   spark_connect(master="yarn-client", version = "1.6.2", spark_home = [Cluster's Spark path])

Sparkスタンドアローンクラスタ

1. RStudio ServerまたはProを既存のノード, または同じLAN上のサーバへインストールする
2. ローカルバージョンのSparkを次のコマンドでインストールする
   spark_install (version = "2.0.1")
3. コネクションを開く
   spark_connect(master="spark://host:port", version = "2.0.1", spark_home = spark_home_dir())

Tuning Spark

設定例

```
config <- spark_config()
config$spark.executor.cores <- 2
config$spark.executor.memory <- "4G"
sc <- spark_connect (master="yarn-client",
                     config = config,
                     version = "2.0.1")
```

重要なチューニングパラメータ

※オレンジ文字はデフォルト値

- spark.yarn.am.cores
- spark.yarn.am.memory *512m*
- spark.network.timeout *120s*
- spark.executor.memory *1g*
- spark.executor.cores *1*
- spark.executor.instances
- spark.executor.extraJavaOptions
- spark.executor.heartbeatInterval *10s*
- sparklyr.shell.executor-memory
- sparklyr.shell.driver-memory

sparklyrの活用

Apache Spark, R, sparklyrをローカルモードでデータ分析を行う例

```
library(sparklyr); library(dplyr);
library(ggplot2); library(tidyr);
set.seed(100)

spark_install("2.0.1")

sc <- spark_connect(master = "local")

import_iris <- copy_to(sc, iris, "spark_iris",
  overwrite = TRUE)

partition_iris <- sdf_partition(
  import_iris,training=0.5, testing=0.5)

sdf_register(partition_iris,
c("spark_iris_training","spark_iris_test"))

tidy_iris <- tbl(sc,"spark_iris_training") %>%
  select(Species, Petal_Length, Petal_Width)

model_iris <- tidy_iris %>%
  ml_decision_tree(response="Species",
  features=c("Petal_Length","Petal_Width"))

test_iris <- tbl(sc,"spark_iris_test")

pred_iris <- sdf_predict(
  model_iris,  test_iris) %>%
  collect

pred_iris %>%
  inner_join(data.frame(prediction=0:2,
  lab=model_iris$model.parameters$labels))
%>%
  ggplot(aes(Petal_Length, Petal_Width,
col=lab)) +
  geom_point()

spark_disconnect(sc)
```

Sparkをローカルにインストール
ローカルのSparkに接続
データをSparkメモリへコピー
データのパーティション設定
各パーティションにhiveメタデータを作成
Spark ML 決定木モデル
Sparkテーブルへ参照を作成
プロットするためRのメモリへデータを戻す
切断

RStudio® is a trademark of RStudio, Inc. • CC BY RStudio • info@rstudio.com • 844-448-1212 • rstudio.com • Learn more at **spark.rstudio.com** • sparklyr 0.5 • Updated: 2016-12

Translated by Masato Takahashi // @masato_takahash

Reactivity

Sparkへデータをコピー

sdf_copy_to(sc, iris, "spark_iris")

sdf_copy_to(sc, x, name, memory, repartition, overwrite**)**

ファイルからSparkへインポート

全関数共通の引数:
sc, name, path, options = list(), repartition = 0, memory = TRUE, overwrite = TRUE

CSV **spark_read_csv(** header = TRUE, columns = NULL, infer_schema = TRUE, delimiter = ",", quote = "\"", escape = "\\", charset = "UTF-8", null_value = NULL**)**

JSON **spark_read_json()**

PARQUET **spark_read_parquet()**

Spark SQLコマンド

DBI::**dbWriteTable**(sc, "spark_iris", iris)

DBI::**dbWriteTable(**conn, name, value**)**

Hiveテーブルの操作

my_var <- **tbl_cache**(sc, name= "hive_iris")

tbl_cache(sc, name, force = TRUE**)**

メモリにテーブルを読み込む

my_var <- **dplyr::tbl**(sc, name="hive_iris")

dplyr::**tbl(**scr, …**)**

メモリに読み込まずにテーブルへの参照を作成する

加工

DPLYRの文法でSPARK SQLを利用

Spark SQLへ翻訳されます

```
my_table <- my_var %>%
  filter(Species=="setosa") %>%
  sample_n(10)
```

Spark SQLコマンドの直接発行

```
my_table <- DBI::dbGetQuery( sc ,
  "SELECT * FROM iris LIMIT 10")
```

DBI::**dbGetQuery(**conn, statement**)**

SDF関数を用いたScala APIの利用

sdf_mutate(.data)
dplyrのmutate関数と等価

sdf_partition(x, ..., weights = NULL, seed = sample (.Machine$integer.max, 1)**)**
sdf_partition*(x, training = 0.5, test = 0.5)*

sdf_register(x, name = NULL**)**
Spark DataFrameに名前を付ける

sdf_sample(x, fraction = 1, replacement = TRUE, seed = NULL**)**

sdf_sort(x, columns**)**
1つ以上のカラムについて昇順にソート

sdf_with_unique_id(x, id = "id"**)**
ユニークIDカラムを追加

sdf_predict(object, newdata**)**
予測値を含むSpark DataFrame

ML 変換関数

ft_binarizer(my_table,input.col="Petal_Length", output.col="petal_large", threshold=1.2)

全関数共通の引数:
x, input.col = NULL, output.col = NULL

ft_binarizer(threshold = 0.5**)**
閾値に基いて値を割り当て

ft_bucketizer(splits**)**
数値カラムを離散値カラムへ

ft_discrete_cosine_transform(inverse = FALSE**)**
時間領域から周波数領域へ変換(離散コサイン変換)

ft_elementwise_product(scaling.col**)**
要素ごとの積を求める

ft_index_to_string()
インデックスを文字列に変換

ft_one_hot_encoder()
ラベルインデックスのカラムをバイナリベクトルのカラムに変換

ft_quantile_discretizer(n.buckets=5L**)**
連続値からビン幅毎のカテゴリ値へ変換

ft_sql_transformer(sql**)**

ft_string_indexer(params = NULL**)**
ラベルカラムをラベルインデックスのカラムに変換

ft_vector_assembler()
複数のベクトルを1つに連結する

可視化&通信

Rのメモリへデータをダウンロード

```
r_table <- collect(my_table)
plot(Petal_Width~Petal_Length, data=r_table)
```

dplyr::**collect(**x**)**
R DataFrameにSpark DataFrameをダウンロードする

sdf_read_column(x, column**)**
Rへ1カラムの要素を返す

Sparkからファイルシステムへ保存

全関数へ適用される引数: x, path

CSV **spark_read_csv(** header = TRUE, delimiter = ",", quote = "\"", escape = "\\", charset = "UTF-8", null_value = NULL**)**

JSON **spark_read_json(**mode = NULL**)**

PARQUET **spark_read_parquet(**mode = NULL**)**

データの読み書き Apache Sparkから

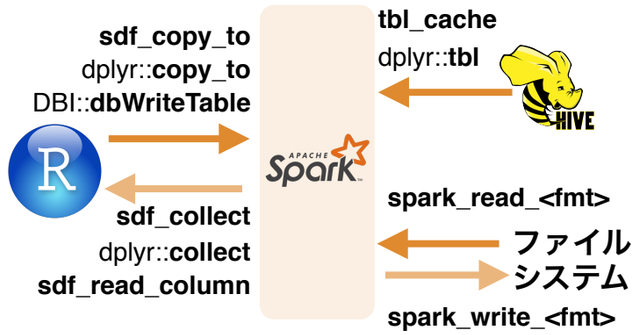

拡張

全Spark APIを呼び出しSparkパッケージへのインタフェースを提供するRパッケージを作成

コア機能

spark_connection() Rとsparkシェルプロセスとの接続

spark_jobj() リモートのSparkオブジェクトへのインタフェース

spark_dataframe() リモートのSpark DataFrameオブジェクトへのインタフェース

RからSparkの呼び出し

invoke() Javaオブジェクトのメソッドを呼び出す

invoke_new() コンストラクタを呼び出して新しいオブジェクトを生成する

invoke_static() オブジェクトの静的メソッドを呼び出す

機械学習エクステンション

ml_create_dummy_variables() **ml_options()**

ml_prepare_dataframe() **ml_model()**

ml_prepare_response_features_intercept()

モデリング(MLlib)

ml_decision_tree(my_table, response = "Species", features = c("Petal_Length" , "Petal_Width"))

ml_als_factorization(x, user.column = "user", rating.column = "rating", item.column = "item", rank = 10L, regularization.parameter = 0.1, iter.max = 10L, ml.options = ml_options()**)**

ml_decision_tree(x, response, features, max.bins = 32L, max.depth = 5L, type = c("auto", "regression", "classification"), ml.options = ml_options()**)**
※**ml_gradient_boosted_trees**とオプションは同じ

ml_generalized_linear_regression(x, response, features, intercept = TRUE, family = gaussian(link = "identity"), iter.max = 100L, ml.options = ml_options()**)**

ml_kmeans(x, centers, iter.max = 100, features = dplyr::tbl_vars(x), compute.cost = TRUE, tolerance = 1e-04, ml.options = ml_options()**)**

ml_lda(x, features = dplyr::tbl_vars(x), k = length(features), alpha = (50/k) + 1, beta = 0.1 + 1, ml.options = ml_options()**)**

ml_linear_regression(x, response, features, intercept = TRUE, alpha = 0, lambda = 0, iter.max = 100L, ml.options = ml_options()**)**
※**ml_logistic_regression**とオプションは同じ

ml_multilayer_perceptron(x, response, features, layers, iter.max = 100, seed = sample(.Machine$integer.max, 1), ml.options = ml_options()**)**

ml_naive_bayes(x, response, features, lambda = 0, ml.options = ml_options()**)**

ml_one_vs_rest(x, classifier, response, features, ml.options = ml_options()**)**

ml_pca(x, features = dplyr::tbl_vars(x), ml.options = ml_options()**)**

ml_random_forest(x, response, features, max.bins = 32L, max.depth = 5L, num.trees = 20L, type = c("auto", "regression", "classification"), ml.options = ml_options()**)**

ml_survival_regression(x, response, features, intercept = TRUE,censor = "censor", iter.max = 100L, ml.options = ml_options()**)**

ml_binary_classification_eval(predicted_tbl_spark, label, score, metric = "areaUnderROC"**)**

ml_classification_eval(predicted_tbl_spark, label, predicted_lbl, metric = "f1"**)**

ml_tree_feature_importance(sc, model**)**

sparklyr
Apache Spark
とRとの
インタフェース

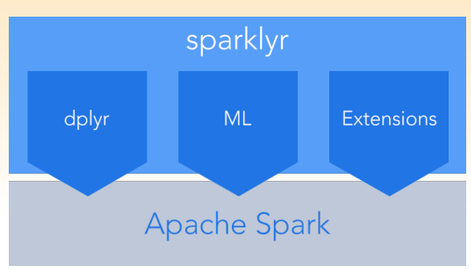

RStudio® is a trademark of RStudio, Inc. • CC BY RStudio • info@rstudio.com • 844-448-1212 • rstudio.com • Learn more at **spark.rstudio.com** • sparklyr 0.5 • Updated: 2016-12

Translated by Masato Takahashi // @masato_takahash