
pyspark Documentation

Release master

Author

Apr 17, 2023

Contents

1	pyspark package	3
1.1	Subpackages	3
1.2	Contents	4
2	Core classes:	5
3	Indices and tables	7

Contents:

CHAPTER 1

pyspark package

1.1 Subpackages

1.1.1 pyspark.sql module

Module Context

[pyspark.sql.types module](#)

[pyspark.sql.functions module](#)

1.1.2 pyspark.streaming module

Module contents

[pyspark.streaming.kafka module](#)

1.1.3 pyspark.ml package

ML Pipeline APIs

[pyspark.ml.param module](#)

[pyspark.ml.feature module](#)

[pyspark.ml.classification module](#)

[pyspark.ml.clustering module](#)

[pyspark.ml.recommendation module](#)

[pyspark.ml.regression module](#)

[pyspark.ml.tuning module](#)

[pyspark.ml.evaluation module](#)

1.1.4 pyspark.mllib package

[pyspark.mllib.classification module](#)

[pyspark.mllib.clustering module](#)

[pyspark.mllib.evaluation module](#)

[pyspark.mllib.feature module](#)

[pyspark.mllib.fpm module](#)

[pyspark.mllib.linalg module](#)

[pyspark.mllib.linalg.distributed module](#)

[pyspark.mllib.random module](#)

[pyspark.mllib.recommendation module](#)

[pyspark.mllib.regression module](#)

[pyspark.mllib.stat module](#)

[pyspark.mllib.tree module](#)

[pyspark.mllib.util module](#)

1.2 Contents

CHAPTER 2

Core classes:

`pyspark.SparkContext`

Main entry point for Spark functionality.

`pyspark.RDD`

A Resilient Distributed Dataset (RDD), the basic abstraction in Spark.

`pyspark.sql.SQLContext`

Main entry point for DataFrame and SQL functionality.

`pyspark.sql.DataFrame`

A distributed collection of data grouped into named columns.

CHAPTER 3

Indices and tables

- search