


# S&P 500



Pedro Pablo Beltranena

Andrés Martínez

Nickolas Nolte

Esteban Samayoa



# Hipótesis

El dataset S&P 500 index stocks pueden ser agrupados o clusterizados basados en su rendimiento general respecto a un rango de tiempo, el cual puede ser analizados usando las variables, opening, low, high and close.

El modelo de agrupación K-mean Clustering es más eficiente para agrupar este tipo de datos respecto a su rendimiento contra otro modelo de agrupación como Hierarchical Clustering.

Analizando el conjunto de datos respecto a un modelo predictivo, podemos predecir correctamente si el precio de un stock tiende al alza o a la baja.

Descripción de  
datos

# Descripción de los datos



## Exploración

El set de datos tiene 7 variables principales

1. Date - object
2. Open - float
3. High - float
4. Low - float
5. Close - float
6. Volume - int
7. Name - object

|   | date       | open  | high  | low   | close | volume   | Name |
|---|------------|-------|-------|-------|-------|----------|------|
| 0 | 2013-02-08 | 15.07 | 15.12 | 14.63 | 14.75 | 8407500  | AAL  |
| 1 | 2013-02-11 | 14.89 | 15.01 | 14.26 | 14.46 | 8882000  | AAL  |
| 2 | 2013-02-12 | 14.45 | 14.51 | 14.10 | 14.27 | 8126000  | AAL  |
| 3 | 2013-02-13 | 14.30 | 14.94 | 14.25 | 14.66 | 10259500 | AAL  |
| 4 | 2013-02-14 | 14.94 | 14.96 | 13.16 | 13.99 | 31879900 | AAL  |

|        | open      | high      | low       | close     | volume    |
|--------|-----------|-----------|-----------|-----------|-----------|
| open   | 1.000000  | 0.999939  | 0.999928  | 0.999872  | -0.142705 |
| high   | 0.999939  | 1.000000  | 0.999903  | 0.999936  | -0.142316 |
| low    | 0.999928  | 0.999903  | 1.000000  | 0.999939  | -0.143240 |
| close  | 0.999872  | 0.999936  | 0.999939  | 1.000000  | -0.142802 |
| volume | -0.142705 | -0.142316 | -0.143240 | -0.142802 | 1.000000  |

| # | Column | Non-Null | Count    | Dtype   |
|---|--------|----------|----------|---------|
| 0 | date   | 619029   | non-null | object  |
| 1 | open   | 619029   | non-null | float64 |
| 2 | high   | 619029   | non-null | float64 |
| 3 | low    | 619029   | non-null | float64 |
| 4 | close  | 619029   | non-null | float64 |
| 5 | volume | 619029   | non-null | int64   |
| 6 | Name   | 619029   | non-null | object  |

dtypes: float64(4), int64(1), object(2)
memory usage: 33.1+ MB

```
1 df.shape
```

✓ 0.0s


```
(619029, 7)
```

```
1 df.isnull().sum()
```

✓ 0.2s


```
date      0
open      0
high      0
low       0
close     0
volume    0
Name      0
dtype: int64
```

Evolución temporal del precio de las top 10 empresas en el S&P 500



\*empresas elegidas según su frecuencia en el dataset

Dendrograma del S&P 500



# Remoción de datos

Aspectos a tomar en cuenta


28 NAN

11 en open

8 en high


8 en low

Reducción de data set  
600,000+ observaciones




# Resultados

|        | date       | open  | high  | low    | close | volume   | Name | Cluster |
|--------|------------|-------|-------|--------|-------|----------|------|---------|
| 0      | 2013-02-08 | 15.07 | 15.12 | 14.630 | 14.75 | 8407500  | AAL  | 2       |
| 1      | 2013-02-11 | 14.89 | 15.01 | 14.260 | 14.46 | 8882000  | AAL  | 2       |
| 2      | 2013-02-12 | 14.45 | 14.51 | 14.100 | 14.27 | 8126000  | AAL  | 2       |
| 3      | 2013-02-13 | 14.30 | 14.94 | 14.250 | 14.66 | 10259500 | AAL  | 2       |
| 4      | 2013-02-14 | 14.94 | 14.96 | 13.160 | 13.99 | 31879900 | AAL  | 0       |
| ...    | ...        | ...   | ...   | ...    | ...   | ...      | ...  | ...     |
| 416328 | 2018-02-01 | 36.80 | 37.53 | 36.630 | 37.43 | 2517830  | NOV  | 4       |
| 416329 | 2018-02-02 | 36.92 | 37.06 | 35.620 | 35.69 | 2658658  | NOV  | 4       |
| 416330 | 2018-02-05 | 35.46 | 36.29 | 33.700 | 33.85 | 5453975  | NOV  | 2       |
| 416331 | 2018-02-06 | 33.33 | 35.80 | 33.001 | 35.39 | 6492866  | NOV  | 2       |
| 416332 | 2018-02-07 | 35.23 | 36.10 | 33.930 | 34.05 | 5037110  | NOV  | 4       |



```
Precisi3n del modelo: 0.9712184116009456
0      False
1      False
2      False
3      True
4      False
...
619024  True
619025  False
619026  False
619027  True
619028  True
Length: 619029, dtype: bool
```



# Conclusiones

Tuvimos que hacer una limpieza de datos eliminando datos vacíos que no nos servían para el análisis. 28 en total distribuidos como lo explicamos anteriormente.

Concluimos la hipótesis de que el *K-mean clustering* es mas eficiente para este tipo de datos que otro modelo de agrupación como el *Hierarchical Clustering*.

Aplicamos el *Random Forest Classifier*, no nos dio resultados relevantes para ver cual de los metodos era el más adecuado. El porcentaje de positivos y negativos esta casi que igual.

# Curiosidades

- Empresa de energía tiene una caída bastante pronunciada y coincide en tiempo con los Acuerdo de Paris, que tienen como objetivo: *aumentar la capacidad de adaptación y reducir la vulnerabilidad frente a los impactos del cambio climático de todos los países*
- Mientras que NEE, es la segunda mejor empresa con rendimiento a través del tiempo. Pero su enfoque energetico cumple con acuerdos internacionales o fuentes renovables.

