
Clase 019 — NumPy: ordenamiento y búsqueda

Parte: 0 — Prerrequisitos · Fuente: VanderPlas, cap. 2 § 2.8 Sorting Arrays · NumPy sorting reference. · Duración estimada: 60 min.

Clase 019 — NumPy: ordenamiento y búsqueda

Parte: 0 — Prerrequisitos · Fuente: VanderPlas, cap. 2 § 2.8 Sorting Arrays · NumPy sorting reference. · Duración estimada: 60 min.

Objetivo

Que el alumno ordene arrays con criterio: sort vs argsort, ordenamiento por eje, partial sort con partition, y búsqueda binaria con searchsorted. Útil para top-K, rankings, alineación de series.

Resultados de aprendizaje

Al finalizar la clase, el alumno podrá:

1. Ordenar con `np.sort(arr)` (devuelve copia) y `arr.sort()` (in-place).
2. Obtener índices del orden con `argsort` — base de top-K y rankings.
3. Ordenar por eje en matrices con `axis=0` o `axis=1`.
4. Top-K eficiente con `np.partition` (no ordena completo, solo separa).
5. Búsqueda binaria con `np.searchsorted` en arrays ordenados ($O(\log n)$).

Temas

#	Tema	Por qué importa
1	<code>np.sort</code> vs <code>arr.sort()</code>	Copia vs in-place.
2	<code>argsort</code> : el truco del top-K	Índices que ordenarían el array.
3	Ordenamiento por eje	Por fila o por columna.
4	<code>np.partition</code> para top-K	Más rápido que sort completo.
5	<code>np.searchsorted</code> — binaria $O(\log n)$	Inserción en array ordenado.
6	<code>np.unique</code>	Únicos + opcionalmente cuentas.

Definiciones y características

`np.sort` vs `arr.sort()`

: `np.sort(arr)` devuelve copia ordenada (no muta). `arr.sort()` ordena in-place y retorna `None`. Mismo patrón que `sorted(list)` vs `list.sort()`.

`argsort`

: Devuelve los índices que ordenarían el array. `idx = arr.argsort()`; `ordenado = arr[idx]`. Base de top-K, rankings, alineación entre arrays correlacionados.

`np.partition`

: Quick-select $O(n)$: garantiza que los K menores quedan en las primeras K posiciones (no necesariamente ordenados entre sí), el resto después. Mucho más rápido que sort completo cuando solo necesitas top-K.

`np.searchsorted`

: Búsqueda binaria $O(\log n)$ en array ordenado. Devuelve el índice donde insertar un valor para mantener

orden. Útil para calcular percentiles, bucketing.

`np.unique`

: Devuelve únicos ordenados. Con `return_counts=True` devuelve también las frecuencias — alternativa rápida a Counter para datos numéricos.

Dataset / recursos

Sintético: puntajes de 1M estudiantes. Sin descarga.

Ejercicios

1. Top-10. Dado array de 1M puntajes, obtén los 10 más altos. Compara `np.sort()[-10:]` vs `np.partition`.
2. Ranking. Con `argsort`, asigna a cada estudiante su ranking (1 = mejor).
3. Ordena matriz por columna. Matriz 10×5; ordena cada columna por su valor.
4. Mediana por bisect. Implementa una función que dado un valor `v` y un array ordenado, devuelve su posición percentil usando `searchsorted`.
5. `np.unique` con cuentas. Dado array de categorías, obtén valores únicos y sus frecuencias.

Homework verificable

Notebook con array de 100k puntajes: (a) top-100 con `partition` y benchmark vs sort completo; (b) ranking con `argsort.argsort()`; (c) percentil de un valor dado con `searchsorted`; (d) `unique` con `return_counts` y `barplot` top-10 categorías.

Criterio de aceptación: `partition` >10× más rápido que sort completo para $N=100k$ y $K=100$.

Errores comunes

Síntoma / mensaje	Causa y cómo arreglar
Ordeno con <code>arr.sort()</code> y la variable queda	<code>sort()</code> es in-place — modifica <code>arr</code> y retorn
Top-K con <code>sort()[-K:]</code> es lento para N gran	Sort completo es $O(N \log N)$. Fix: <code>np.partition</code>
<code>argsort</code> da resultado raro con matriz	Sin <code>axis</code> , ordena cada fila/columna indepen
<code>np.searchsorted</code> da índice fuera del array	Si el valor es mayor que todos, devuelve <code>l</code>
<code>np.unique(arr_2d)</code> aplana el array	Por default, <code>unique</code> trabaja sobre array ap

Preguntas frecuentes

¿Cuándo `argsort` y cuándo `sort`?

Si solo necesitas los valores ordenados, `sort`. Si necesitas el orden para aplicarlo a otros arrays correlacionados (ej: ordenar nombres por puntajes), `argsort` te da los índices.

¿`partition` o `heapq.nlargest`?

`partition` para arrays NumPy (vectorizado, C). `heapq.nlargest(K, lst)` para listas Python. Para K muy pequeño

(3-5) sobre N grande, similares; partition gana en arrays grandes.

¿Cómo ordeno por múltiples claves (lexicográfico)?

`np.lexsort([clave_secundaria, clave_principal])` — devuelve índices. Atención: el orden es al revés (último argumento = key primaria).

¿`np.unique` preserva el orden de primera aparición?

No — siempre ordena. Para preservar orden de aparición: `_, idx = np.unique(arr, return_index=True); arr[np.sort(idx)]`.

¿Existe equivalente a SQL ORDER BY x DESC?

`arr[arr.argsort()[:-1]]` o `arr[arr.argsort()[:-1]]`. NumPy no tiene flag `reverse=` como `sorted()` Python — invierte tú.

Referencias

- VanderPlas, cap. 2 § 2.8.
- NumPy sorting reference

Siguiente clase

Clase 020 — NumPy: álgebra lineal con `numpy.linalg`

Apéndice: notebook (primer bloque)

Primera celda ejecutable del notebook de la clase.

```
import numpy as np
import time
rng = np.random.default_rng(42)
```

Archivos complementarios

- notebook.ipynb