



POLITÉCNICA
"Ingeniamos el futuro"

CAMPUS
DE EXCELENCIA
INTERNACIONAL

Universidad Politécnica de Madrid
ETS de Ingenieros Informáticos



Robustez de la homología persistente: El Teorema de estabilidad

15/06/2021

Alejandro García Castellanos, z17m008

Tutor: Héctor Barge Yañez

Índice

- Introducción
- Conocimientos previos
- Teorema de estabilidad
- Implementación
- Ejemplos
- Conclusiones
- Referencias


Introducción

Análisis topológico de datos

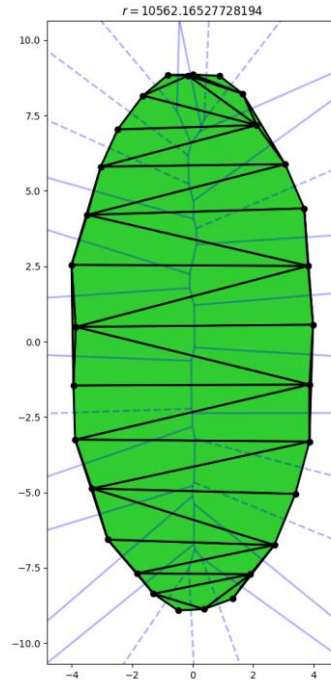

El análisis de datos topológicos (TDA) es un enfoque para el análisis de las propiedades cualitativas geométricas de datasets utilizando técnicas de topología.

- Propiedades cualitativas geométricas: Componentes conexas, agujeros, cavidades...
- **Ventajas:**
 - Estudiar características de la “forma” de datos de dimensión superior que no se pueden visualizar.
 - No dependen de la elección de una métrica
 - Proporcionan estabilidad frente al ruido → **Teorema de estabilidad**

Pipeline



Nube de puntos



Filtración de complejos
simpliciales





Diagrama de persistencia

Conocimientos previos

Complejo simplicial


- Def: Un k -símplice σ en \mathbb{R}^d con $d \geq k$ es un triángulo k -dimensional.




0-símplice



1-símplice




2-símplice




3-símplice

- Def: Un **complejo simplicial** es una colección finita de símplices K que satisface que las intersecciones (no vacías) entre los símplices son símplices de menor dimensión, pertenecientes al complejo simplicial K .

Complejo simplicial



Es un complejo simplicial




No es un complejo simplicial

Complejo de Vietoris-Rips

- Def: Sea $S \subset \mathbb{R}^d$ un conjunto finito de puntos. Llamamos **complejo de Vietoris-Rips** de S de radio r al complejo simplicial abstracto

$$\text{VR}(r) = \{\sigma \subseteq S \mid \text{diam } \sigma \leq 2r\}$$


donde $\text{diam } \sigma$ denota el diámetro del subconjunto σ .



Fuente: [1]

Celdas de Voronoi

- Def: La **celda de Voronoi**, V_u , de un punto $u \in S$ es la intersección de los semiespacios de puntos al menos tan cerca de u como de v para todos los puntos $v \in S$.




Fuente: [1]

Alfa complejo

- Def: Sea $S \subset \mathbb{R}^d$ un conjunto finito de puntos. Llamamos **alfa complejo** de radio r asociado a S como el complejo simplicial abstracto

$$\text{Alpha}(r) = \{ \sigma \in S \mid \bigcap_{u \in \sigma} R_u(r) \neq \emptyset \}$$

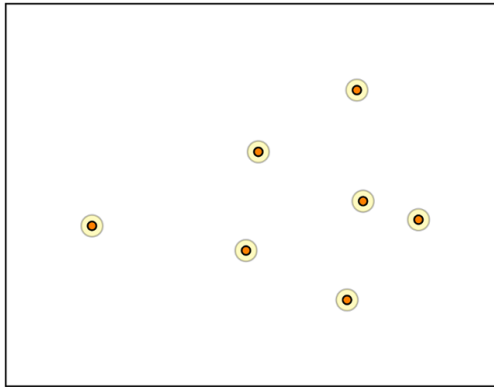
donde $R_u(r) = \overline{B}_r(u) \cap V_u$.




Fuente: [1]

Homología simplicial

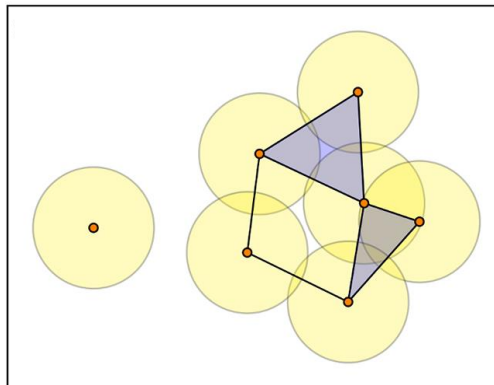
- Formalismo algebraico que nos permitirá contar:
 - Componentes conexas.
 - Agujeros.
 - Cavidades.
 - Etc.
- Def: Sea un objeto geométrico X , definimos $\beta_i(X)$, el i -ésimo **número de Betti** de X , como el número de agujeros i -dimensionales de X .
- Nos va a permitir calcular los números de Betti de un complejo simplicial haciendo uso del álgebra lineal.



- $\beta_0(K) = 7$ (Comp. Conexas)
- $\beta_1(K) = 0$ (Huecos)
- $\beta_2(K) = 0$ (Cavidades)





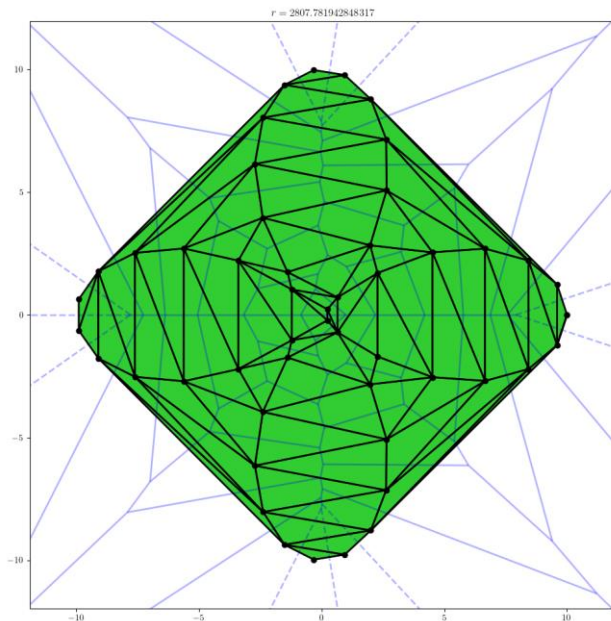
- $\beta_0(K) = 6$ (Comp. Conexas)
- $\beta_1(K) = 0$ (Huecos)
- $\beta_2(K) = 0$ (Cavidades)



- $\beta_0(K) = 2$ (Comp. Conexas)
- $\beta_1(K) = 1$ (Huecos)
- $\beta_2(K) = 0$ (Cavidades)

Homología persistente

- Def: El **diagrama de persistencia** $\text{Dgm}_l(K) \subset \overline{\mathbb{R}}^2$ de K es el multiconjunto de puntos (a_i, a_j) con multiplicidad μ_i^j para todo $0 \leq i < j \leq n + 1$, unión los puntos de la diagonal, con multiplicidad infinito.
 - Hay μ_i^j agujeros l -dimensionales que nacen en el “instante” a_i y mueren en a_j .

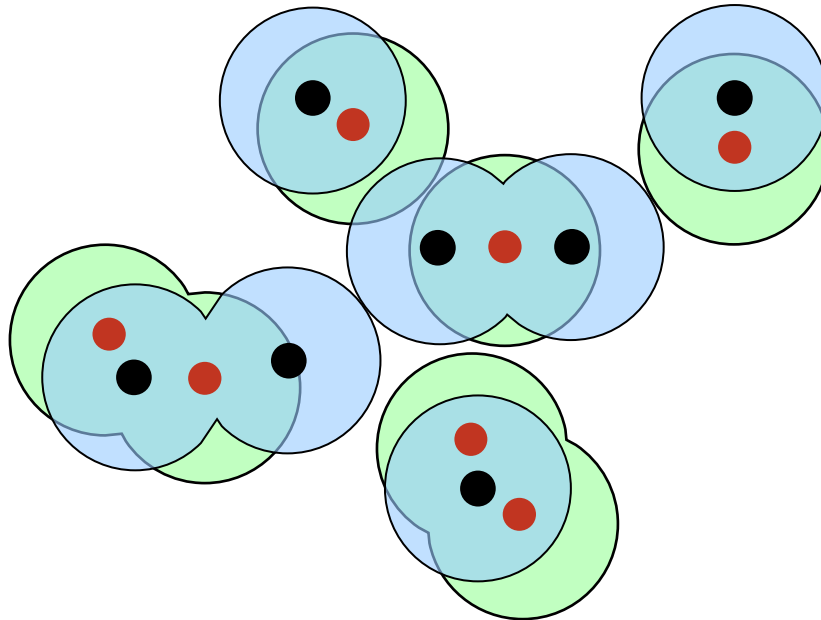


Teorema de estabilidad

Distancia Hausdorff

Sean X e Y dos conjuntos finitos. Entonces, la **distancia Hausdorff** entre X e Y es

$$H(X, Y) = \max \left\{ \sup_{x \in X} \inf_{y \in Y} \|x - y\|_{\infty}, \sup_{y \in Y} \inf_{x \in X} \|y - x\|_{\infty} \right\}$$




Distancia Bottleneck

Sean X e Y dos multiconjuntos. Entonces, la **distancia bottleneck** entre X e Y es

$$W_{\infty}(X, Y) = \inf_{\eta: X \rightarrow Y} \sup_{x \in X} \|x - \eta(x)\|_{\infty}$$

siendo $\eta: X \rightarrow Y$ las biyecciones de X a Y .



Fuente: [2]

Teorema de estabilidad

Sean A y B subconjuntos finitos de \mathbb{R}^d . Entonces, para cada k

$$W_\infty(\text{Dgm}_k(A), \text{Dgm}_k(B)) \leq H(A, B).$$


Nubes de puntos “cercanas” dan lugar a diagramas de persistencia “cercanos”.

Este resultado se puede generalizar de forma que podemos garantizar la robustez de los diagramas de persistencia asociados a una función real definida en un espacio topológico, bajo ciertas hipótesis leves [2].

Implementación

Cálculo de la distancia Hausdorff

$$H(X, Y) = \max \left\{ \sup_{x \in X} \inf_{y \in Y} \|x - y\|_{\infty}, \sup_{y \in Y} \inf_{x \in X} \|y - x\|_{\infty} \right\}$$



Cálculo de las distancias Hausdorff directas:

$\check{H}(X, Y)$

$\check{H}(Y, X)$

Algoritmo NAIVEHDD [3] del orden de $\mathcal{O}(n * m)$, donde $m = |X|$ y $n = |Y|$.

Cálculo de la distancia Bottleneck

$$W_{\infty}(X, Y) = \inf_{\eta: X \rightarrow Y} \sup_{x \in X} \|x - \eta(x)\|_{\infty}$$

Búsqueda de la biyección $\eta: X \rightarrow Y$ de distancia mínima


↓ Modelización

Búsqueda de un emparejamiento óptimo de coste mínimo en un grafo bipartido

↓ Resolución

Variante del método Húngaro, el cual se utiliza para resolver problemas de asignación



Algoritmo [1] del orden de $\mathcal{O}(n^3)$.




Ejemplos

Ejemplo 1: Elipse


$$\gamma(t) = (4 \sin(t), 9 \cos(t)), \text{ con } t \in [0, 2\pi]$$




Alfa complejo ($r = 10562.16527728194$)




Persistence diagram



Alfa complejo + Ruido ($r = 10562.16527728194$)



Persistence diagram



Ruido:

$N(2, 0.09)$

Dist. Hausdorff:

2.4398

Dist. Bottleneck

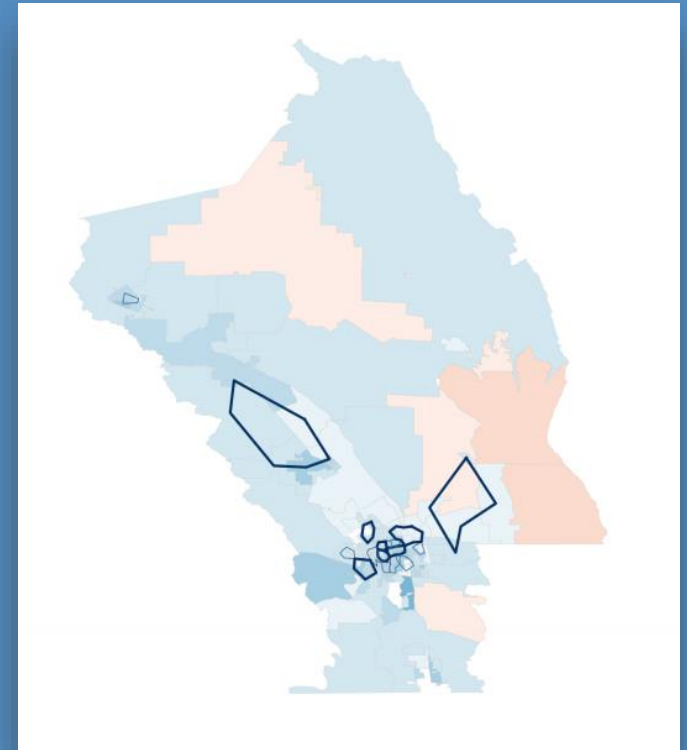
dim. 0: 0.55573

Dist. Bottleneck

dim. 1: 0.98572

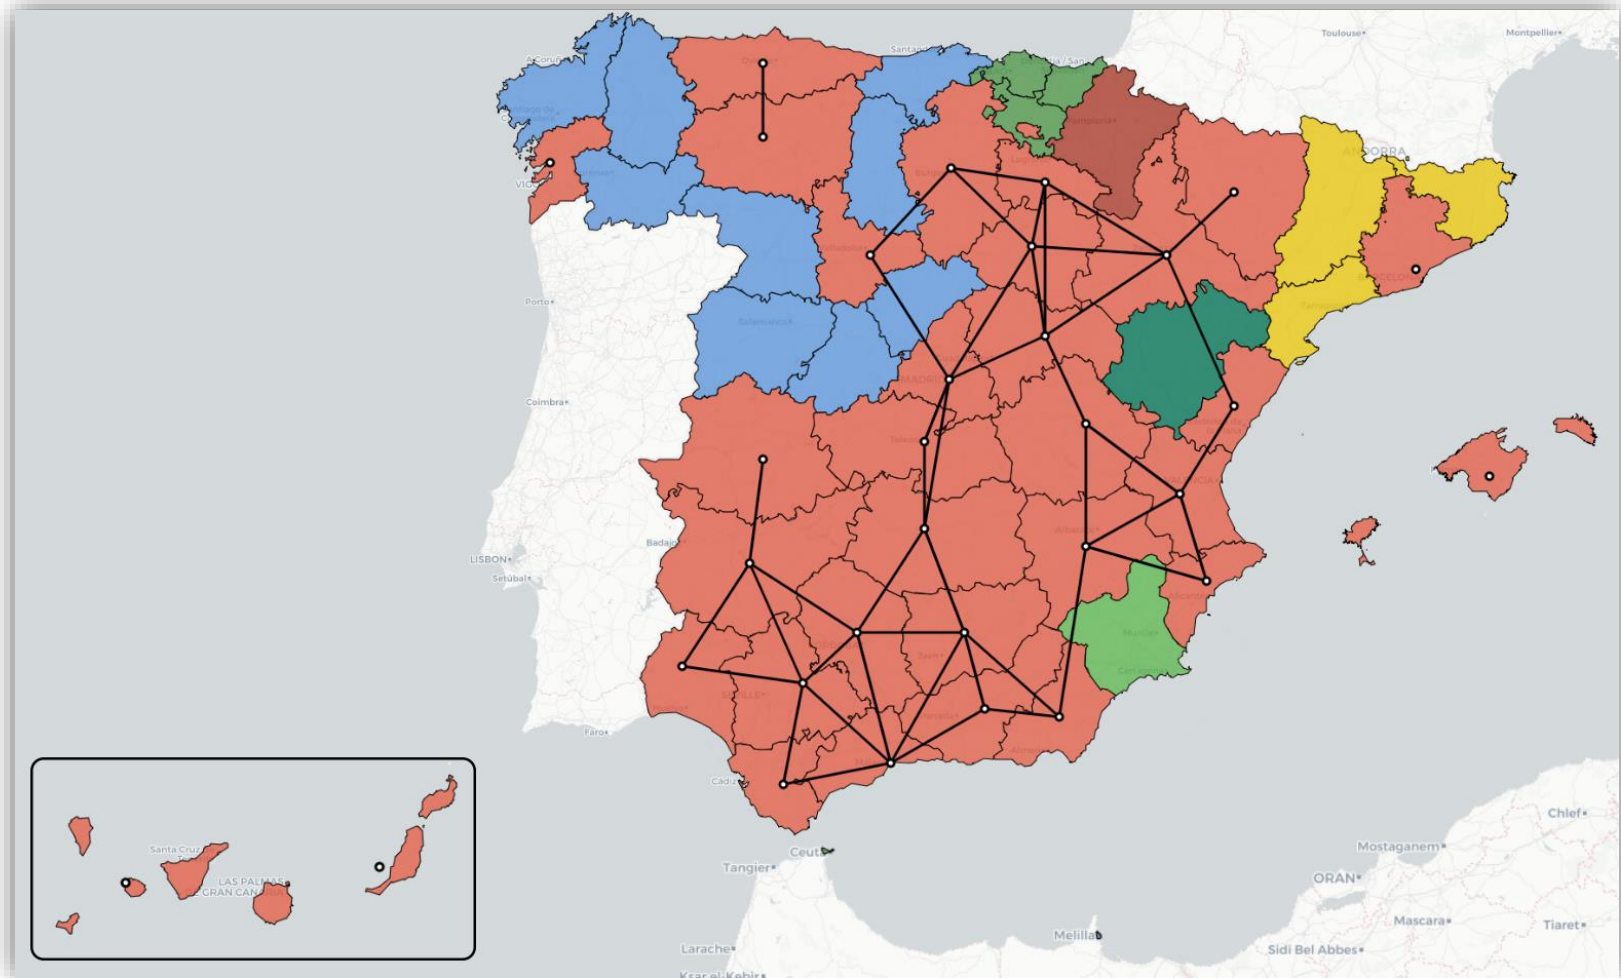
Ejemplo 2: Elecciones 2019

- Simulamos el procedimiento descrito en [4]
 - Usar homología persistente para determinar si hay distritos electorales donde se ha votado diferente respecto al resto de distritos que lo rodean.
 - Agujero \rightarrow “Distrito isla”.
- Resultados de las elecciones generales de noviembre de 2019:
 - Cada provincia con el color del partido con mayor número de votos
 - Coordenada representativa de cada provincia:
 - Wikipedia.
 - Random.
- Comprobar que los resultados obtenidos en [4] son robustos a la elección de la coordenada representativa del territorio.

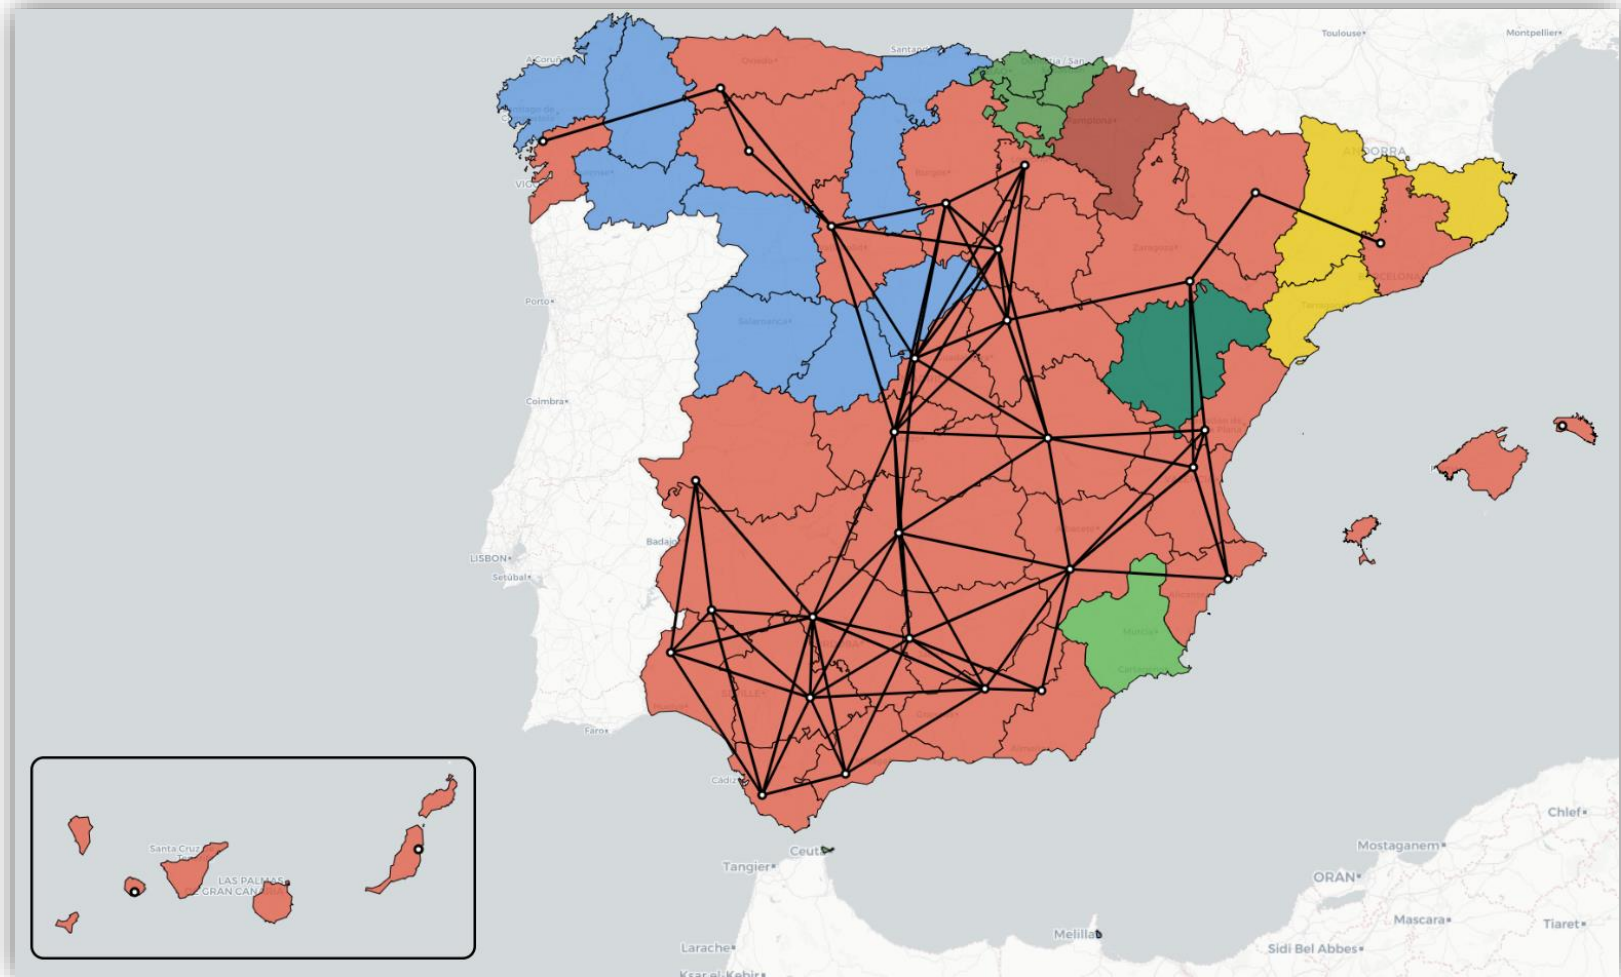


Condado de Napa, California
Fuente: [4]


Complejo VR Wikipedia



Complejo VR Random




Complejo VR Wikipedia



Dist. Hausdorff:
0.89583

Dist. Bottleneck
dim. 0: 0.7323

Complejo VR Random



Dist. Bottleneck
dim. 1: 0.2682

Conclusiones

Conclusiones

- **Gran utilidad** de la homología persistente para el estudio cualitativo de los datos
 - Sin embargo, requiere interpretación de los resultados → **Posibilidad de inconsistencia en las interpretaciones.**
 - Dependen de la selección del complejo simplicial para obtener mejores resultados.
- **Amplias aplicaciones:**
 - Biología computacional: Estudio genético...
 - Neurociencia
 - Lingüística computacional.
 - Medicina: Oncología...
 - Machine Learning.
 - Etc.
- **Posibilidad de mejora** en el cálculo de ambas distancias:
 - Estudiar los algoritmos considerados *State of Art*.

Referencias

Referencias

- [1] H. Edelsbrunner and J. Harer, Computational Topology: An Introduction. American Mathematical Society, 01 2010.
- [2] D. Cohen-Steiner, H. Edelsbrunner, and J. Harer, “Stability of persistence diagrams,” Discrete & Computational Geometry, vol. 37, no. 1, pp. 103–120, Jan 2007. [Online]. Available: <https://doi.org/10.1007/s00454-006-1276-5>
- [3] A. A. Taha and A. Hanbury, “An efficient algorithm for calculating the exact hausdorff distance,” IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 37, no. 11, pp. 2153–2163, Nov. 2015. [Online]. Available: <https://doi.org/10.1109/tpami.2015.2408351>
- [4] M. Feng and M. A. Porter, “Persistent homology of geospatial data: A case study with voting,” 2019.

GRACIAS

Alejandro García Castellanos, z17m008

Tutor: Héctor Barge Yañez