

Algoritmos de Similitud y Distancia



UCR – ECCI

CI-2414 Recuperación de Información

Prof. Kryscia Daviana Ramírez Benavides



Búsquedas en RI

- Dos opciones principales:
 - Búsquedas estructuradas.
 - Basadas en palabras clave: clasificación más sencilla.
 - Por palabra única
 - Por contexto
- *Modelo de Similitud*: Soporte para realizar búsquedas basadas en patrones erróneos de digitación, deletreo, escaneo, etc.
- *Funciones de Distancia*: Establecen metodología y nivel de error permitido, unas miden si la hilera es aceptable o no y otras dan la similitud.



Conceptos Generales

- *Noción de Distancia:* Comparar hileras y ver que diferencia hay entre ellas.
- *Modelos de Similaridad:* Calcular la cercanía en que están las hileras. Ayuda a búsquedas sobre patrones con errores.
- *Algoritmos de Distancia:* Funciones que permiten ver que tan diferentes son las hileras.

Propiedades

- Las funciones de distancia deben de cumplir con las siguientes condiciones:
 - $d(i, i) = 0$
 - $d(i, j) \geq 0$
 - $d(i, j) = d(j, i)$
 - $d(i, j) \leq d(i, h) + d(h, j)$



Distancia de Hamming

- Se le aplica a hileras del mismo tamaño:
 - Hileras de igual tamaño, vectores con la misma dimensión.
 - Hileras de diferente tamaño se rellena la hilera más pequeña hacia la derecha con vacíos.
- Podemos definir la distancia entre ellas como el número de caracteres en las mismas posiciones que son distintos, número de entradas diferentes entre los vectores.
- **Entre más cerca de cero más parecidas son las hileras.**

Distancia Hamming – Ejemplo #1

h1 = GRANDE

h2 = GRANOS

G	R	A	N	D	E
G	R	A	N	O	S

Distancia Hamming – Ejemplo #1

G	R	A	N	D	E
G	R	A	N	O	S
✓					

Distancia Hamming – Ejemplo #1

G	R	A	N	D	E
G	R	A	N	O	S
✓	✓				

Distancia Hamming – Ejemplo #1

G	R	A	N	D	E
G	R	A	N	O	S
✓	✓	✓			

Distancia Hamming – Ejemplo #1

G	R	A	N	D	E
G	R	A	N	O	S
✓	✓	✓	✓		

Distancia Hamming – Ejemplo #1

G	R	A	N	D	E
G	R	A	N	O	S
✓	✓	✓	✓	✗	

Distancia Hamming – Ejemplo #1

G	R	A	N	D	E
G	R	A	N	O	S
✓	✓	✓	✓	✗	✗

Nº de ✗ = $HD(h1, h2) = 2$

Distancia Hamming – Ejemplo #2

h1 = DISTANCIA

h2 = DISTORSION

D	I	S	T	A	N	C	I	A	
D	I	S	T	R	O	S	I	O	N

Distancia Hamming – Ejemplo #2

D	I	S	T	A	N	C	I	A	
D	I	S	T	R	O	S	I	O	N
✓									

Distancia Hamming – Ejemplo #2

D	I	S	T	A	N	C	I	A	
D	I	S	T	R	O	S	I	O	N
✓	✓								

Distancia Hamming – Ejemplo #2

D	I	S	T	A	N	C	I	A	
D	I	S	T	R	O	S	I	O	N
✓	✓	✓							

Distancia Hamming – Ejemplo #2

D	I	S	T	A	N	C	I	A	
D	I	S	T	R	O	S	I	O	N
✓	✓	✓	✓						

Distancia Hamming – Ejemplo #2

D	I	S	T	A	N	C	I	A	
D	I	S	T	R	O	S	I	O	N
✓	✓	✓	✓	✗					

Distancia Hamming – Ejemplo #2

D	I	S	T	A	N	C	I	A	
D	I	S	T	R	O	S	I	O	N
✓	✓	✓	✓	✗	✗				

Distancia Hamming – Ejemplo #2

D	I	S	T	A	N	C	I	A	
D	I	S	T	R	O	S	I	O	N
✓	✓	✓	✓	✗	✗	✗			

Distancia Hamming – Ejemplo #2

D	I	S	T	A	N	C	I	A	
D	I	S	T	R	O	S	I	O	N
✓	✓	✓	✓	✗	✗	✗	✓		

Distancia Hamming – Ejemplo #2

D	I	S	T	A	N	C	I	A	
D	I	S	T	R	O	S	I	O	N
✓	✓	✓	✓	✗	✗	✗	✓	✗	

Distancia Hamming – Ejemplo #2

D	I	S	T	A	N	C	I	A	
D	I	S	T	R	O	S	I	O	N
✓	✓	✓	✓	✗	✗	✗	✓	✗	✗

Nº de ✗ = $HD(h1, h2) = 5$

Distancia Hamming – Resumen Ejemplos

- Ejemplo 1:
 - $h1 = \text{grande}$
 - $h2 = \text{granos}$
 - $HD(h1, h2) = 2$
- Ejemplo 2:
 - $h1 = \text{distancia}$
 - $h2 = \text{distorsión}$
 - $HD(h1, h2) = 5$



Distancia de Levenstein

- Llamada también distancia de edición.
- Medida similaridad entre dos hileras:
 - Hilera fuente (f)
 - Hilera meta (m).
- La similaridad entre dos palabras se calcula como el mínimo número de operaciones que transforma a una de las palabras en la otra (transformar f en m).
- Las tres operaciones son:
 - destrucción()
 - inserción()
 - sustitución()



Distancia de Levenshtein (cont.)

- A más distancia Levenshtein ~ Mayor diferencia en las hileras.
- **Entre más cerca de cero más parecidas son las hileras.**
- Algoritmo:
 - El tamaño de la hilera f es x , y el tamaño de la hilera m es y . Si $x = 0$, retornar y ; y si $y = 0$, retornar x .
 - Construir una matriz con $y + 1$ filas y $x + 1$ columnas. Inicializar la primer fila de la matriz con la secuencia $0, 1, 2, \dots, x$; y la primer columna de la matriz con la secuencia $0, 1, 2, \dots, y$.
 - Colocar cada carácter de la hilera f en su correspondiente celda i (i va de 1 a x).
 - Colocar cada carácter de la hilera m en su correspondiente celda j (j va de 1 a y).

Distancia de Levenshtein (cont.)

- Algoritmo (cont.):
 - Si $f(i)$ es igual a $m(j)$ el costo de la celda es 0.
 - Si $f(i)$ es diferente de $m(j)$ el costo de la celda es 1.
 - El valor de la celda $d(i,j)$ es el mínimo de:
 - Valor de la celda $(i - 1, j) + 1$.
 - Valor de la celda $(i, j - 1) + 1$.
 - Valor de la celda $(i - 1, j - 1) + \text{costo}$.
 - La distancia es la celda $d(x,y)$.

Distancia de Levenshtein – Ejemplo

$h1 = \text{CENA}$

$\text{tam}(h1) = 4$

$h2 = \text{COMA}$

$\text{tam}(h1) = 4$

	0	1	2	3	4
0					
1					
2					
3					
4					

Distancia de Levenshtein – Ejemplo

	0	1	2	3	4
0		C	O	M	A
1	C				
2	E				
3	N				
4	A				

Distancia de Levenshtein – Ejemplo

	0	1	2	3	4
0		C	O	M	A
1	C	0	1	1	1
2	E	1	1	1	1
3	N	1	1	1	1
4	A	1	1	1	0

Distancia de Levenshtein – Ejemplo

	0	1	2	3	4
0		C	O	M	A
1	C	0	1	2	3
2	E	1	1	1	1
3	N	1	1	1	1
4	A	1	1	1	0

Distancia de Levenshtein – Ejemplo

	0	1	2	3	4
0		C	O	M	A
1	C	0	1	2	3
2	E	1	1	2	3
3	N	1	1	1	1
4	A	1	1	1	0

Distancia de Levenshtein – Ejemplo

	0	1	2	3	4
0		C	O	M	A
1	C	0	1	2	3
2	E	1	1	2	3
3	N	2	2	2	3
4	A	1	1	1	0

Distancia de Levenshtein – Ejemplo

	0	1	2	3	4
0		C	O	M	A
1	C	0	1	2	3
2	E	1	1	2	3
3	N	2	2	2	3
4	A	3	3	3	2

Distancia de Levenshtein – Ejemplo

	0	1	2	3	4
0		C	O	M	A
1	C	0	1	2	3
2	E	1	1	2	3
3	N	2	2	2	3
4	A	3	3	3	2 ← $LD(h1, h2)$

Distancia de Levenshtein – Resumen Ejemplo

- Intuitivamente:

- Se tienen las hileras: $f = \text{coma}$ y $m = \text{coma}$. $LD(f,m) = 0$, porque no hay que realizar transformaciones.
- Se tienen las hileras: $f = \text{coma}$ y $m = \text{cena}$. $LD(f,m) = 2$, porque con dos sustituciones se transforma f en m .

- Con el algoritmo:

	0	1	2	3	4
0		c	o	m	a
1	c	0	1	2	3
2	e	1	1	2	3
3	n	2	2	2	3
4	a	3	3	3	2

- http://www.cut-the-knot.org/do_you_know/Strings.shtml

Distancias con N-gramas

- La medida de similaridad puede establecerse mediante la fórmula definida como:

$$d = \frac{N * C}{A_1 + A_2 + \dots + A_N}$$

la cual se conoce como el coeficiente de Dice.

- Donde:
 - N = Número de gramas utilizados.
 - C = Número de digramas que comparten las hileras.
 - A_x = Número de digramas de una hilera.

Distancias con N-gramas (cont.)

- **Entre más cerca de cero más diferentes son las hileras.**
- Los valores están en el intervalo $[0,1]$.
- Dos hileras: colaboración y colaborador, y haciendo $N = 2$:
 - Colaborador: co ol la ab bo or ra ad do or
bigramas únicos: co ol la ab bo or ra ad do
 - Colaboración: co ol la ab bo or ra ac ci ió ón
bigramas únicos: co ol la ab bo or ra ac ci ió ón
- La hilera *colaborador* tiene 10 bigramas, de los cuáles 9 son únicos; y la hilera *colaboración* tiene 11 bigramas, todos únicos. Comparten 7 bigramas: co ol la ab bo or ra.
- Aplicando la fórmula: $D(s_1, s_2) = \frac{2*7}{9+11} = 0.7$

Distancia con Bigramas

- Tomar cada par de caracteres juntos, contando la cantidad total de pares.
- Por palabra se cuentan solo los bigramas únicos.
- Ejemplo: *casaca*
 - Bigramas = ca as sa ac ca = 5
 - Bigramas únicos = ca as sa ac = 4
- Se cuentan bigramas comunes entre palabras (para medir distancia).
- $D(A,B) = 2 * \text{bigramas comunes} / (\text{bigramas únicos A} + \text{bigramas únicos B})$.
- Si $D(A,B) = 1 \Rightarrow$ palabras iguales.

Distancia con Bigramas – Ejemplo #1

- $h1 = \text{escuela} = \text{es sc cu ue el la} = 6$
- $h2 = \text{escuela} = \text{es sc cu ue el la} = 6$
- Bigramas únicos de $A = 6$
- Bigramas únicos de $B = 6$
- Bigramas comunes = 6
- $2 * 6 / (6 + 6) = 1$
- $BiD(h1, h2) = 1$

Distancia con Bigramas – Ejemplo #2

- $h1 = \text{escuela} = \text{es sc cu ue el la} = 6$
- $h2 = \text{comidas} = \text{co om mi id da as} = 6$
- Bigramas únicos de $A = 6$
- Bigramas únicos de $B = 6$
- Bigramas comunes = 0
- $2 * 0 / (6 + 6) = 0$
- $BiD(h1, h2) = 0$

Distancia Euclidiana

- Muy usada por su simplicidad
- Cálculo a partir de los valores numéricos de cada posición en un vector. Distancia entre vectores, se da peso a los caracteres.
- Sean u y v hileras de caracteres, entonces:

$$d(u, v) = \sqrt{\sum_{k=1}^f (u_k - v_k)^2} = \sqrt{|u_1 - v_1|^2 + \dots + |u_f - v_f|^2}$$

- Con f = tamaño de la hilera más grande.
- **Entre más cerca de cero más parecidas son las hileras.**

Distancia Euclidiana – Ejemplo #1

- $h1 = \text{escuela}$
- $h2 = \text{escuelas}$
- Valor ASCII de los caracteres:
 - $e = 101, s = 115, c = 99, u = 117, l = 108, a = 97,$
espacio en blanco = 32.

$$ED(h1, h2) = \sqrt{|101-101|^2 + |115-115|^2 + |99-99|^2 + |117-117|^2 + |101-101|^2 + |108-108|^2 + |97-97|^2 + |32-115|^2}$$

$$ED(h1, h2) = \sqrt{0+0+0+0+0+0+0+6889} = \sqrt{6889} = 83$$

- $ED(h1, h2) = 83$

Distancia Euclidiana – Ejemplo #2

- $h1 = \text{escuela}$
- $h2 = \text{comidas}$
- Valor ASCII de los caracteres:
 - $e = 101, s = 115, c = 99, u = 117, l = 108, a = 97, o = 111, m = 109,$
 $i = 105, d = 100.$

$$ED(h1, h2) = \sqrt{|101-99|^2 + |115-111|^2 + |99-109|^2 + |117-105|^2 + |101-100|^2 + |108-97|^2 + |97-115|^2}$$

$$ED(h1, h2) = \sqrt{4+16+100+144+1+121+324} = \sqrt{710} = 26.65$$

- $ED(h1, h2) = 26.65$

Distancia Ultramétrica

- Al igual que la de n-gramas define distancias no enteras, y es para prefijos.
- Sean u y v dos palabras: $u = u_1 \dots u_{|u|}$ y $v = v_1 \dots v_{|v|}$ defínase como la frontera inferior del conjunto $\{k \mid u_k \neq v_k\}$.
- La distancia se define como:

$$\begin{aligned} T^* x T^* &\rightarrow \mathfrak{R} \\ (u, v) &\rightarrow \frac{1}{k_{(u,v)}} \quad \text{si } u \neq v \\ (u, u) &\rightarrow 0 \end{aligned}$$

- **Entre más cerca de cero más parecidas son las hileras.**

Distancia Ultramétrica – Ejemplo #1

h1 = ESCUELA

h2 = ESCUELAS

E	S	C	U	E	L	A	
E	S	C	U	E	L	A	S



Distancia Ultramétrica – Ejemplo #1

E	S	C	U	E	L	A	
E	S	C	U	E	L	A	S



Distancia Ultramétrica – Ejemplo #1

E	S		C	U	E	L	A	
E	S		C	U	E	L	A	S



Distancia Ultramétrica – Ejemplo #1

E	S	C		U	E	L	A	
E	S	C		U	E	L	A	S



Distancia Ultramétrica – Ejemplo #1

E	S	C	U		E	L	A	
E	S	C	U		E	L	A	S



Distancia Ultramétrica – Ejemplo #1

E	S	C	U	E		L	A	
E	S	C	U	E		L	A	S



Distancia Ultramétrica – Ejemplo #1

E	S	C	U	E	L	A	
E	S	C	U	E	L	A	S



Distancia Ultramétrica – Ejemplo #1

E	S	C	U	E	L	A		
E	S	C	U	E	L	A	S	

Posición de la primera **X** = $UD(h1, h2) = 1/8$

X

Distancia Ultramétrica – Ejemplo #2

$h1 = \text{ESCUELA}$

$h2 = \text{COMIDAS}$

E	S	C	U	E	L	A
C	O	M	I	D	A	S

X

Posición de la primera **X** = $UD(h1, h2) = 1/1 = 1$

Distancia Ultramétrica – Resumen Ejemplos

■ Ejemplo 1:

■ $h1 = \text{escuela}$

■ $h2 = \text{escuelas}$

En el octavo carácter es diferente

■ $UD(h1, h2) = 1/8 = 0.125$

■ Ejemplo 2:

■ $h1 = \text{escuela}$

■ $h2 = \text{comidas}$

En el primer carácter es diferente

■ $UD(h1, h2) = 1/1 = 1$

Distancias Generadas por Secuencias Positivas

- Introducen un costo sobre las diferencias entre dos hileras.
- Da peso a cada posición.
- Sean $\delta_{x,y}$, que toma valores de 1 si $x = y$ y 0 en el otro caso y $(a_i)_{i \in \mathbb{N}}$, una secuencia de reales estrictamente positivos. Se define como $d[a_i]$:

$$T^* x T^* \rightarrow R$$

$$(u, v) \rightarrow \sum_i a_i \delta_{u_i v_i}$$

- **Entre más cerca de cero más diferentes son las hileras.**

Distancias Generadas por Secuencias Positivas – Ejemplo #1

h1 = ESCUELA

h2 = ESCUELAS

E	S	C	U	E	L	A	
E	S	C	U	E	L	A	S

Distancias Generadas por Secuencias Positivas – Ejemplo #1

E	S	C	U	E	L	A	
E	S	C	U	E	L	A	S
1							

Distancias Generadas por Secuencias Positivas – Ejemplo #1

E	S	C	U	E	L	A	
E	S	C	U	E	L	A	S
1	1						

Distancias Generadas por Secuencias Positivas – Ejemplo #1

E	S	C	U	E	L	A	
E	S	C	U	E	L	A	S
1	1	1					

Distancias Generadas por Secuencias Positivas – Ejemplo #1

E	S	C	U	E	L	A	
E	S	C	U	E	L	A	S
1	1	1	1				

Distancias Generadas por Secuencias Positivas – Ejemplo #1

E	S	C	U	E	L	A	
E	S	C	U	E	L	A	S
1	1	1	1	1			

Distancias Generadas por Secuencias Positivas – Ejemplo #1

E	S	C	U	E	L	A	
E	S	C	U	E	L	A	S
1	1	1	1	1	1		

Distancias Generadas por Secuencias Positivas – Ejemplo #1

E	S	C	U	E	L	A	
E	S	C	U	E	L	A	S
1	1	1	1	1	1	1	

Distancias Generadas por Secuencias Positivas – Ejemplo #1

Secuencia $a_i = [1,1,1,1,1,1,1,1]$

E	S	C	U	E	L	A	
E	S	C	U	E	L	A	S
1	1	1	1	1	1	1	0

$$SPD(h1,h2) = 1*1 + 1*1 + 1*1 + 1*1 + 1*1 + 1*1 + 1*1 + 1*0 = 7$$

Distancias Generadas por Secuencias Positivas – Ejemplo #1

h1 = ESCUELA

h2 = COMIDAS

E	S	C	U	E	L	A
C	O	M	I	D	A	S

Distancias Generadas por Secuencias Positivas – Ejemplo #1

Secuencia $a_i = [1,1,1,1,1,1,1,1]$

E	S	C	U	E	L	A
C	O	M	I	D	A	S
0	0	0	0	0	0	0

$$SPD(h1,h2) = 1*0 + 1*0 + 1*0 + 1*0 + 1*0 + 1*0 + 1*0 + 1*0 = 0$$

Distancias Generadas por Secuencias Positivas – Resumen Ejemplos

■ Ejemplo 1:

■ $h1 = \text{escuela}$

■ $h2 = \text{escuelas}$

En el octavo carácter es diferente, son iguales en 7 caracteres.

■ $a_i = [1,1,1,1,1,1,1,1]$

■ $SPD(h1, h2) = 1*1 + 1*1 + 1*1 + 1*1 + 1*1 + 1*1 + 1*1 + 1*0 = 7$

Distancias Generadas por Secuencias Positivas – Resumen Ejemplos

■ Ejemplo 2:

- $h1 = \text{escuela}$
- $h2 = \text{comidas}$

En el primer carácter es diferente, son iguales en 0 caracteres.

- $a_i = [1,1,1,1,1,1,1,1]$
- $SPD(h1, h2) = 1*0 + 1*0 + 1*0 + 1*0 + 1*0 + 1*0 + 1*0 + 1*0 = 0$



Otros Usos

- Estrategia de control de redes de interconexión.
- Reconocimiento de patrones.
- Aprendizaje automático de controladores basados en reglas.
- La biología computacional para búsqueda sobre secuencias de ADN y el reconocimiento de cadenas completas de proteínas.



Práctica

- Sean:
 - $s1 = \text{perro}$, $s2 = \text{perros}$, $s3 = \text{pescado}$.
- Calcular las distancias $d(s1, s2)$ y $d(s1, s3)$ empleando Hamming, Levenstein, N-gramas (con $N = 2$, o sea, Bigramas), Euclideano, Ultramétrico y Secuencias Positivas.



Práctica – Hamming

- Número de caracteres en la misma posición que no coinciden (se rellena con vacíos los espacios en blanco de la hilera más corta):
 - $d(s1, s2) = 1$.
 - $d(s1, s3) = 5$.



Práctica – Levenstein

- Tres operaciones posibles, destrucción ($des(x)$), inserción ($ins(x)$) y sustitución ($subs(x)$):
 - $d(s1, s2) = 1$ (solo es necesario efectuar $des(s)$ en $s2$).
 - $d(s1, s3) = 4$ (es necesario realizar operaciones sobre la hilera más corta ($s1$) y aprovechando la o: $subs(r)$ por s , $subs(r)$ por c , $ins(a)$ y $ins(d)$).

Práctica – Bigrama

- $s1 = pe\ er\ rr\ ro$. Bigramas únicos: $pe\ er\ rr\ ro$.
- $s2 = pe\ er\ rr\ ro\ os$. Bigramas únicos: $pe\ er\ rr\ ro\ os$.
- $s1$ tiene 4 bigramas, 4 únicos.
- $s2$ tiene 5 bigramas, todos únicos.
- Comparten 4 bigramas: $pe\ er\ rr\ ro$,
- Usando el coeficiente de Dice tenemos:
 - $d(s1, s2) = (2*4)/(4+5) = 8/9 = 0,88\dots$

Práctica – Bigrama (cont.)

- $s1 = pe\ er\ rr\ ro$. Bigramas únicos: $pe\ er\ rr\ ro$.
- $s3 = pe\ es\ sc\ ca\ ad\ do$. Bigramas únicos: $pe\ es\ sc\ ca\ ad\ do$.
- $s1$ tiene 4 bigramas, todos únicos.
- $s3$ tiene 6 bigramas, todos únicos.
- Comparten solo 1 bigrama: pe .
- Usando el coeficiente de Dice tenemos:
 - $d(s1, s3) = (2*1)/(4+6) = 1/5 = 0,2$.

Práctica – Euclideo

- La distancia es la raíz de la sumatoria de las diferencia entre los valores ASCII de los campos de las hileras. Esto para no considerar los negativos.
- Sean los valores ASCII:
 - $a = 97, e = 101, o = 111, c = 99, d = 100, p = 112, r = 114, s = 115$ y espacio en blanco = 32.
- $d(s1, s2) = 83.$
$$\sqrt{|112-112|^2 + |101-101|^2 + |114-114|^2 + |114-114|^2 + |111-111|^2 + |32-115|^2}$$
- $d(s1, s3) = 106.24$
$$\sqrt{|112-112|^2 + |101-101|^2 + |114-115|^2 + |114-99|^2 + |111-97|^2 + |32-100|^2 + |32-111|^2}$$



Práctica – Ultramétrico

- La primera posición en donde las cadenas son distintas (iniciando en la posición 1):
 - $d(s1, s2) = 1/6 = 0,166\dots$
 - $d(s1, s3) = 1/3 = 0,33\dots$

Práctica – Secuencias positivas

- Se requiere de una secuencia de reales $(a_i)_{i \in \mathbb{N}}$ con $i =$ medida de la cadena mayor. Es aquí en donde puede jugarse con los pesos de cada posición.
- $d(s1, s2) = 1*1 + 1*2 + 1*3 + 1*4 + 1*5 + 0*6 = 15$
para este caso sea $a = [1,2,3,4,5,6]$
- $d(s1, s3) = 1*1 + 1*2 + 0*3 + 0*4 + 0*5 + 0*6 + 0*7 = 3$
para este caso sea $a = [1,2,3,4,5,6,7]$

Tabla Comparativa de Resultados

	HD	LD	BiD	ED	UD	SPD
$d(s1, s2)$	1	1	$8/9 = 0,8\dots$	83	$1/6 = 0,16\dots$	15
$d(s1, s3)$	5	4	$1/5 = 0,2$	117,25	$1/3 = 0,3\dots$	3

Cada función se interpreta distinto, a veces entre más alto sea el resultado, más alta será la distancia, en otras es todo lo contrario.



Referencias Bibliográficas

- La información fue tomada de:
 - Libro de texto del curso.