Estructuras de Datos
Clase 18 – Procesamiento de Texto (Tries)

Dr. Sergio A. Gómez
http://cs.uns.edu.ar/~sag

Departamento de Ciencias e Ingeniería de la Computación
Universidad Nacional del Sur
Bahía Blanca, Argentina

Tries

- Un trie es una estructura de datos que se usa para implementar conjuntos de strings, y mapeos y diccionarios de string en un tipo E-
- Un trie es un árbol que factoriza prefijos comunes entre las cadenas almacenadas en el mismo.
- Los caminos de la raíz a las hojas representan las palabras del conjunto o las claves del mapeo.

Definición

- Sea S un conjunto de s strings sobre un alfabeto Σ.
- Un trie para S es un árbol ordenado T tal que:
  - Cada nodo de T, excepto la raíz, está etiquetado con un carácter de Σ.
  - El orden los hijos de un nodo interno de T está determinado por el orden canónico de Σ.
  - T tiene s nodos externos, cada uno asociado con un string de S, tal que la concatenación de los rótulos de los nodos del camino de la raíz a una hoja v produce el string de S asociado a v.

Ejemplo (notación de GT)

Sea S = { “ab”, “casa”, “casita”, “cosa”, “coso” }

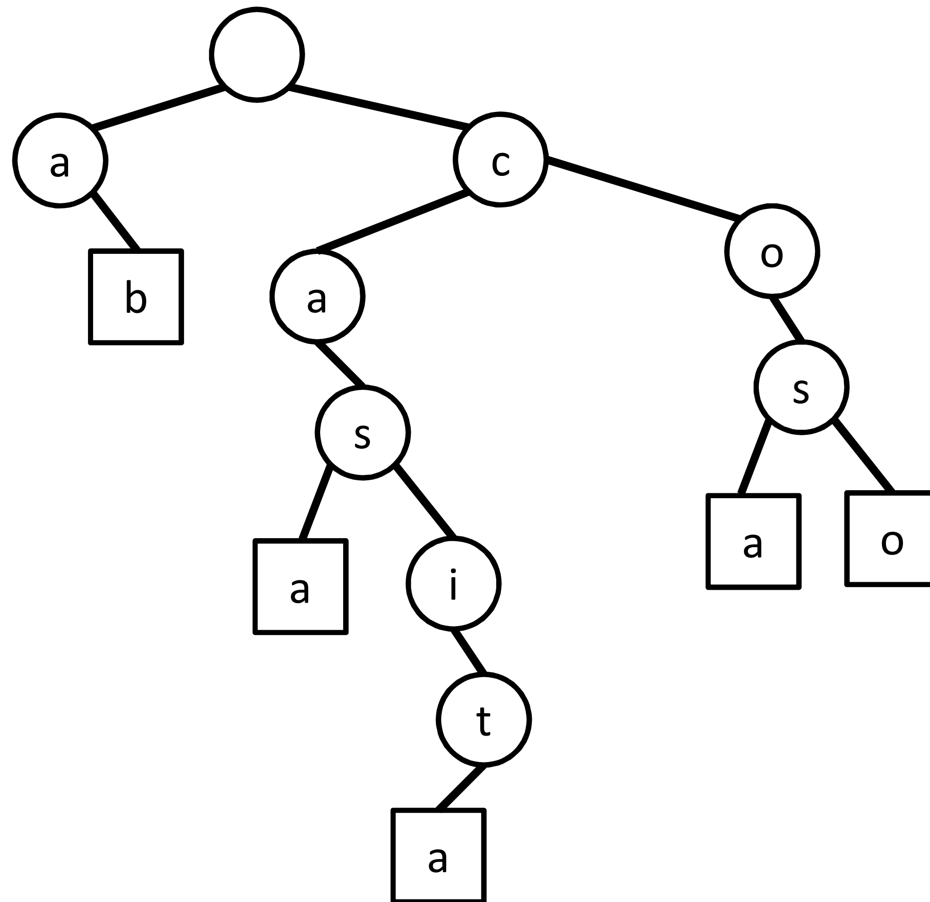

Aclaración

- Nota: Para definir trie, El libro GT, sección 12.3.1, no permite que una palabra del trie sea prefijo de otra palabra del trie.
- Esto se soluciona agregando un carácter especial terminador (párrafo 3 de sec. 12.3.1), que es la política que tomaremos en esta clase.

Ejemplo

Sea S = { "a", "ab", "casa", "casita", "cosa", "coso" }

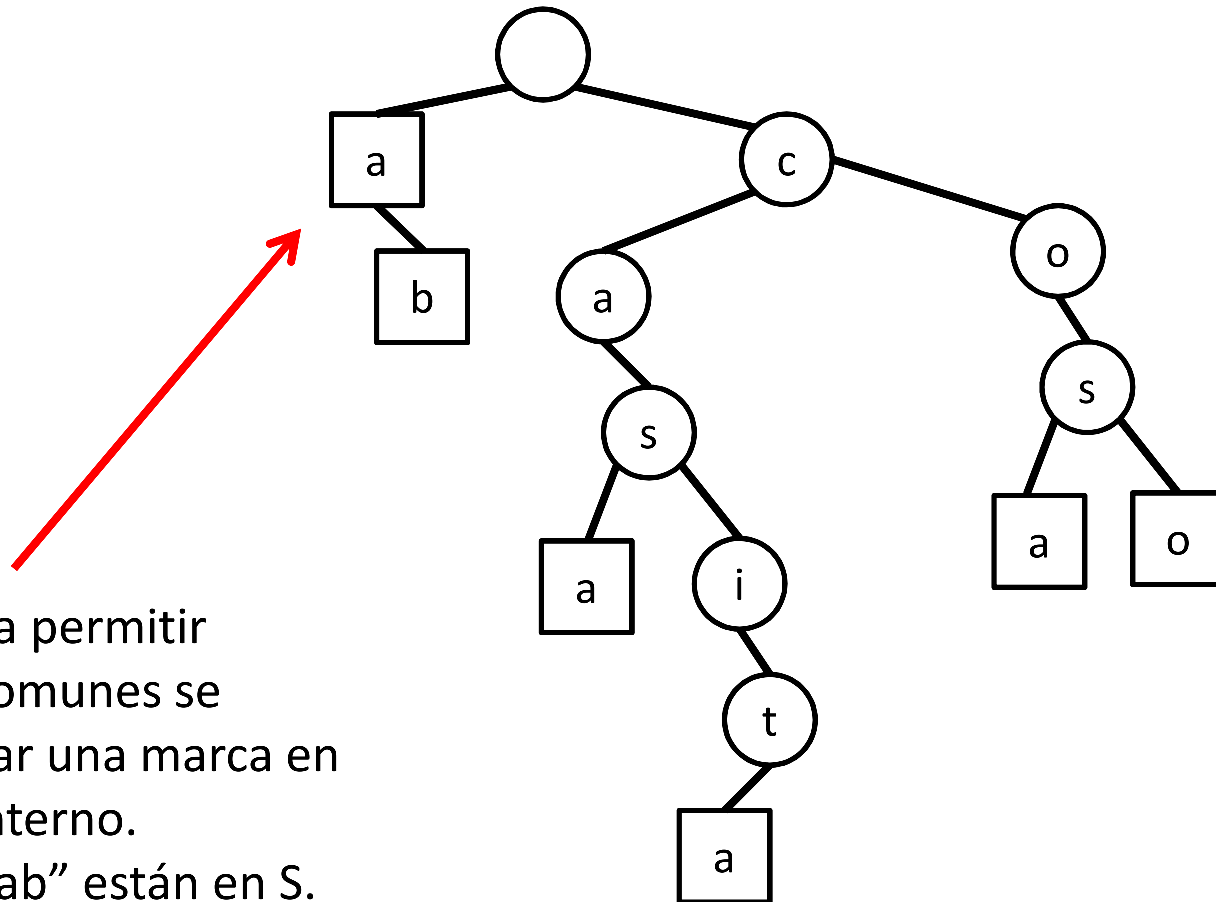

Nota: Para permitir prefijos comunes se puede usar una marca en el nodo interno.
Ej: "a" y "ab" están en S.

Ejemplo

Sea S = { “”, “a”, “ab”, “casa”, “casita”, “cosa”, “coso” }

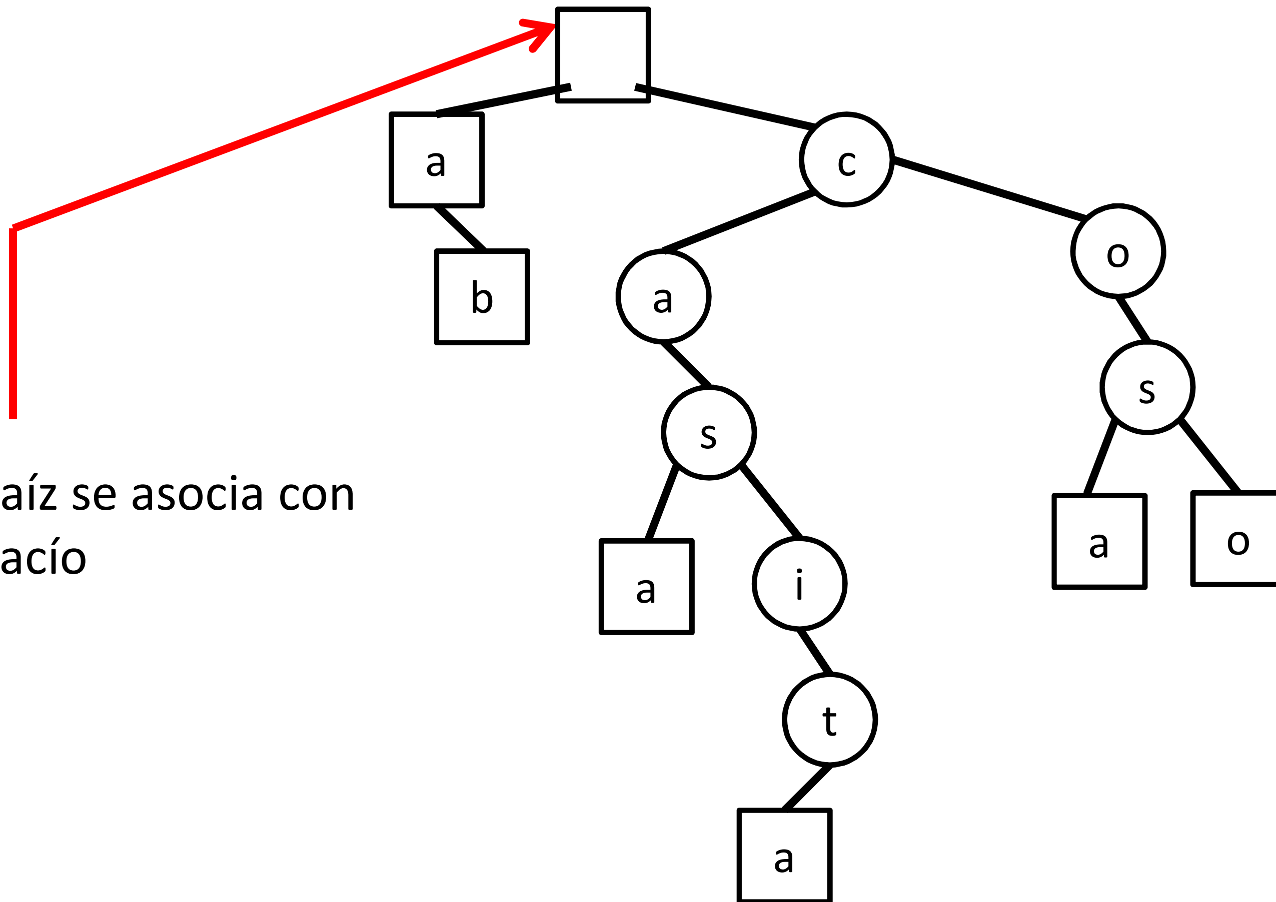

Nota: La raíz se asocia con el string vacío

Ejemplo de Trie en Wikipedia

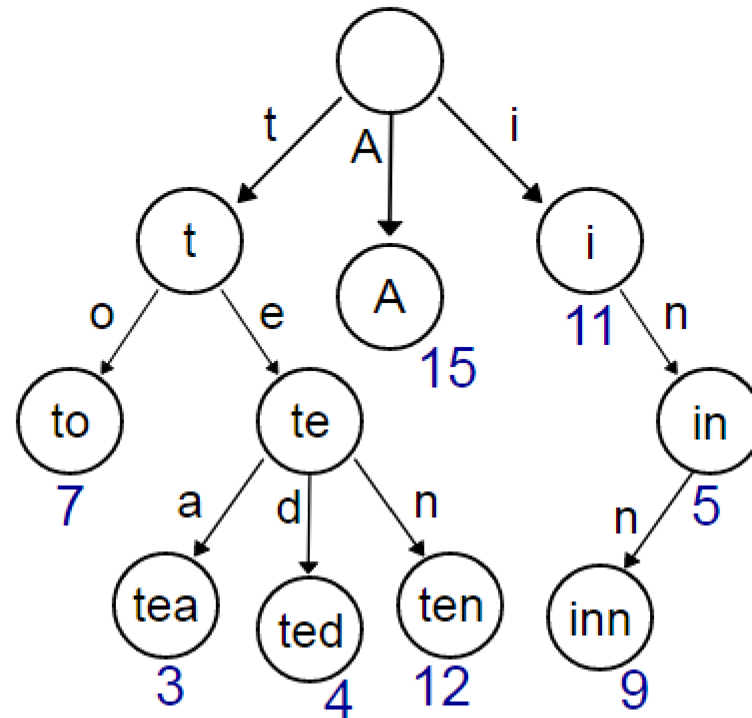

Denota un Map<String,Integer> m donde m.get(“to”) retorna 7, m.get(“tea”) retorna 3, m.get(“ted”) retorna 4, m.get(“ten”) retorna 12, m.get(“A”) retorna 15, m.get(“i”) da 11, m.get(“in”) da 5 y m.get(“inn”) da 9.

Note como los rótulos de caracteres van en los arcos y en los nodos hay un string (implícito ya que no está en la estructura de datos) que denota el string que se contruye con el camino desde la raíz a tal nodo.

Propiedades

Un trie almacenando una colección S de s strings de longitud total n sobre un alfabeto de tamaño d cumple:

- Cada nodo interno de T tiene a lo sumo d hijos
- T tiene s nodos externos
- La altura de T es igual a la longitud del string más largo de S
- El número de nodos de T es O(n).

Implementación: Mapeo de String en E

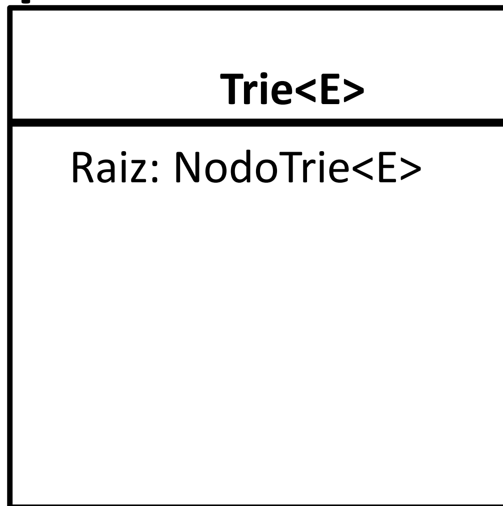

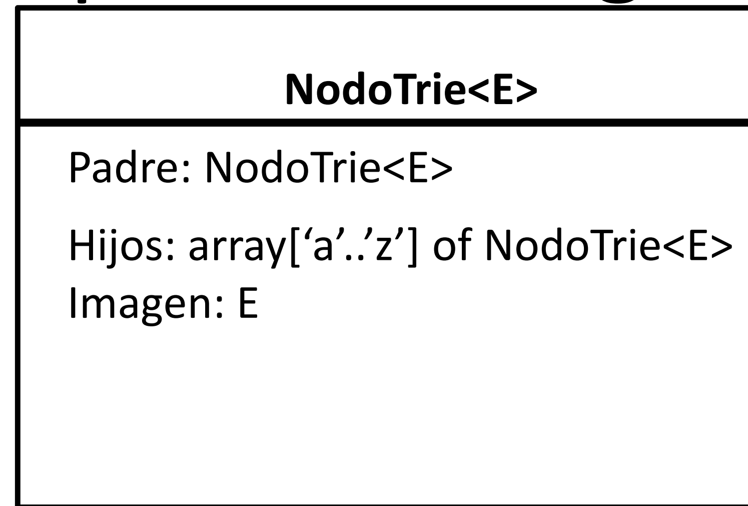

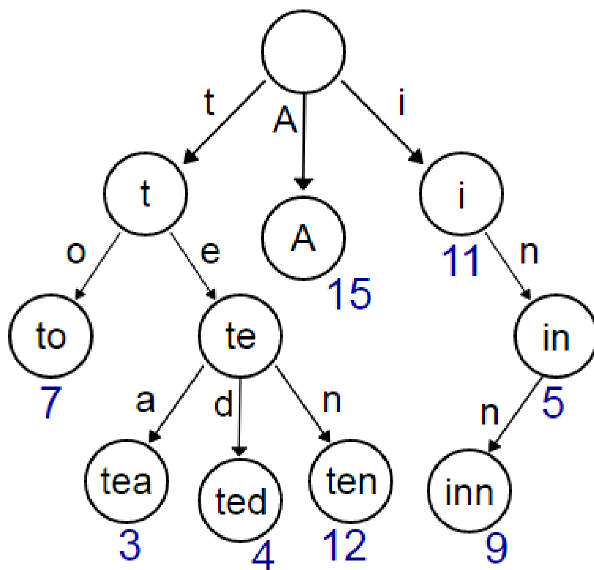

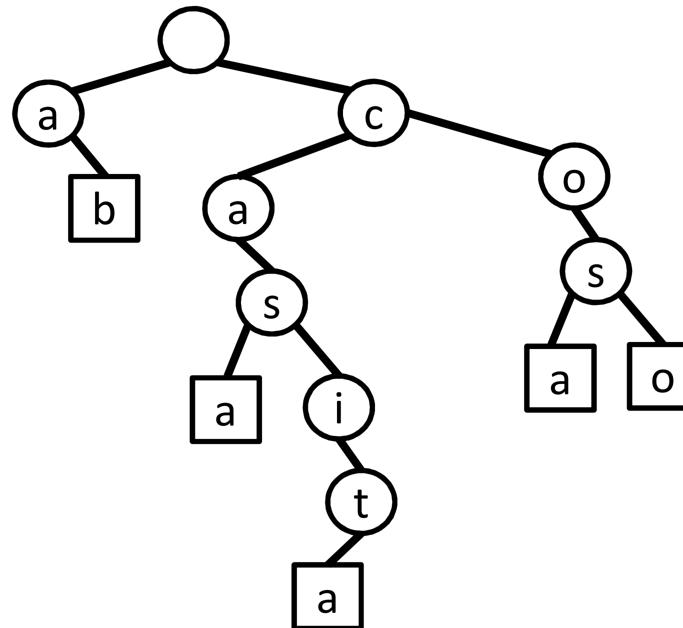

Los cuadraditos de GT correnponden a Imagen != null. En el trie de wikipedia, los números se almacenan en el campo *Imagen* y los arcos corresponden a los índices del arreglo *Hijos*. Note que nosotros no representamos las mayúsculas.

```
public class Trie<E>
{
	protected NodoTrie<E> raiz;

	// Clase anidada estática:
	// Permite usar la clase Trie como paquete:
	public  static class ClaveInexistenteException extends Exception
	{
		public ClaveInexistenteException( String msg )
		{
			super( msg );
		}
	}
```

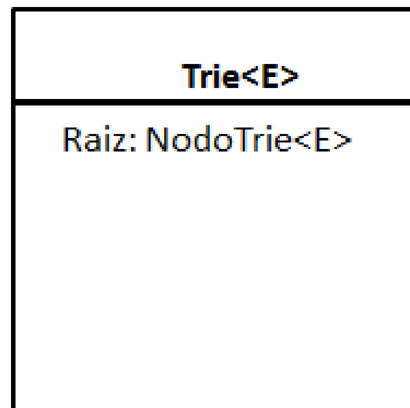

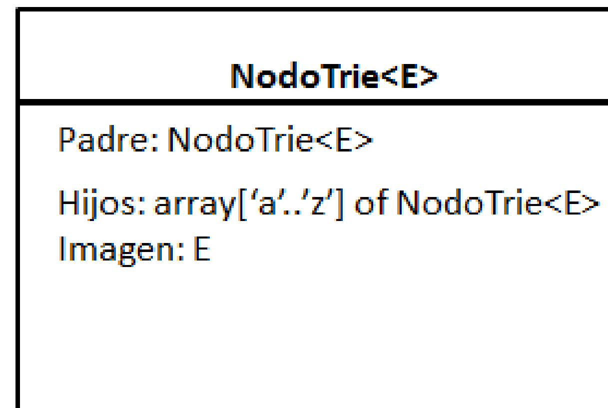

```java
// NodoTrie es parte de la implementación:
private class NodoTrie<E>  {
   protected E imagen;
   protected NodoTrie<E> [] hijos;
   protected NodoTrie<E> padre;

   public NodoTrie(NodoTrie<E> p) {
                  hijos = new NodoTrie[26];
                  imagen = null; padre = p;  }
   public void setImagen(E imagen) { this.imagen = imagen; }
   public E getImagen() { return imagen; }
   public void setHijo(int i, NodoTrie<E> hijo ) { hijos[i] = hijo; }
   public NodoTrie<E> getHijo(int i) { return hijos[i]; }
   public void setPadre( NodoTrie<E> padre ) { this.padre = padre; }
   public NodoTrie<E> getPadre() { return padre; }
}
// Constructor
public Trie() { raiz = new NodoTrie<E>(null); }
```

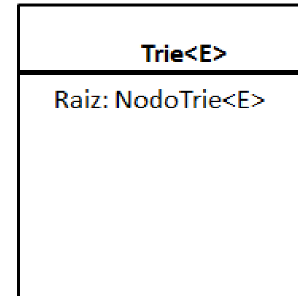

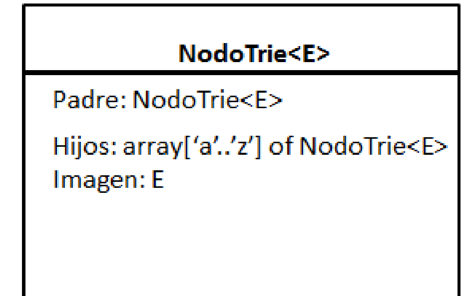

```
public E put( String clave, E valor ) {
        return putaux( clave, valor, 0, clave.length(), raiz, null );
}

private E putaux( String clave, E valor, int i, int n,
        NodoTrie<E> raiz, NodoTrie<E> padre ) {
    if( i < n ) {
        int indice = ((int) clave.charAt(i)) - ((int) 'a');
        if( raiz.getHijo(indice) == null )
                raiz.setHijo( indice, new NodoTrie<E>(raiz) );
        return putaux( clave, valor, i+1, n, raiz.getHijo(indice), raiz );
    } else {        // i == n
        E imavieja =
           raiz.getImagen();
        raiz.setImagen( valor );
        return imavieja;
    }
}
```

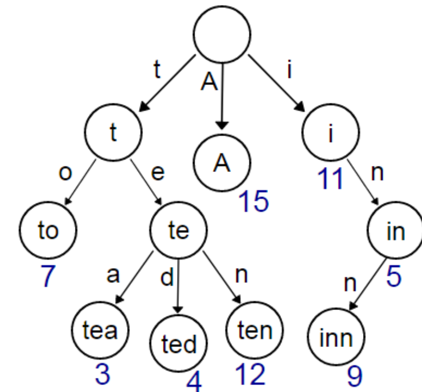

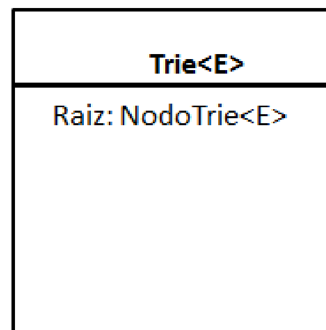

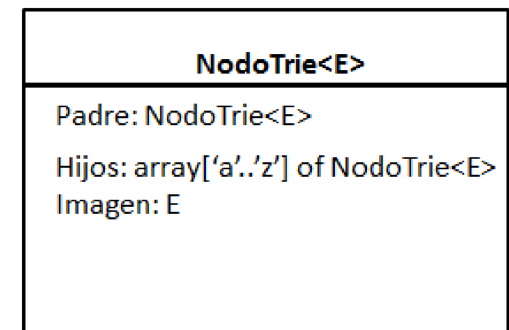

```
public E get( String clave )
{
     return getaux( clave, 0, clave.length(), raiz );
}
```

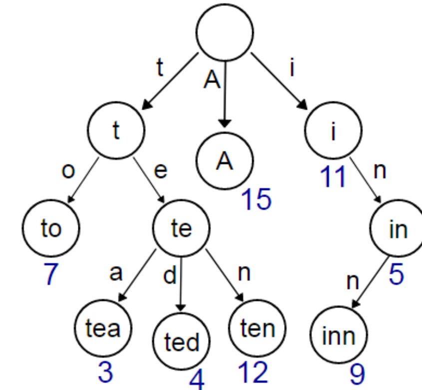


```
private E getaux( String clave, int i, int n, NodoTrie<E> raiz )
{
if( i == n )
    return raiz.getImagen();
else {
    int indice = (int) clave.charAt(i) - (int) 'a';
    if( raiz.getHijo(indice) == null ) return null; // La clave no existe en el
árbol trie.
    return getaux( clave, i+1, n, raiz.getHijo(indice) );
 }
}
```

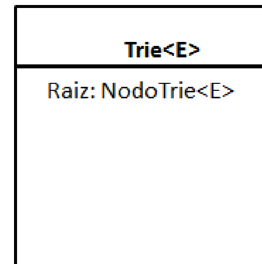

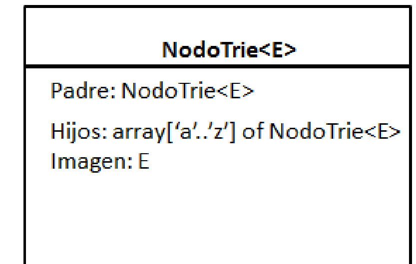

```
public E remove( String clave ) throws ClaveInexistenteException {
    return removeaux( clave, 0, clave.length(), raiz, 0 );   }

private E removeaux( String clave, int i, int n, NodoTrie<E> raiz,  int indiceRaiz
                                        throws ClaveInexistenteException {
     E toRet = null;
     if( i == n ) {
            if( raiz.getImagen() == null )
                        throw new ClaveInexistenteException( "Clave inexistente ");
            E imagen = raiz.getImagen();
            raiz.setImagen( null );
            toRet = imagen;
   } else {
            int indice = (int) clave.charAt(i) - (int) 'a';
            if( raiz.getHijo(indice) == null )
                        throw new ClaveInexistenteExcept

            toRet = removeaux( clave, i+1, n, raiz.getHijc
   }
// Chequear si el nodo quedó todo nulo: no tiene valor ni hijos.
if( todoNulo( raiz ) ) {  // Desconectar este nodo salvo que sea la raiz
            if( raiz != this.raiz ) { raiz.getPadre().setHijo( indiceRaiz, null );
                        raiz.setPadre( null );  }
} return toRet;  }
```

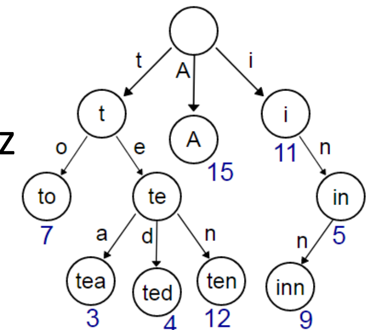

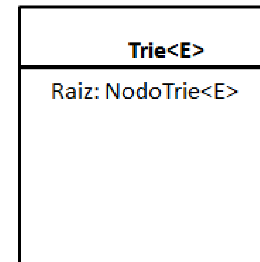

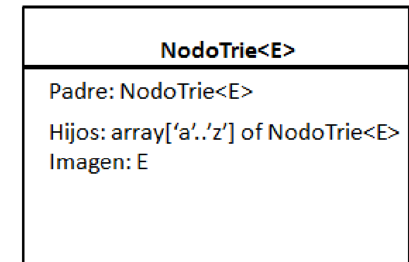

Complejidad temporal

- Sea un conjunto S implementado con un trie T sobre un alfabeto Σ.
- Sea s=cardinal de S, d=cardinal de Σ, m=largo de un string a procesar
- T_{put} (s,d,m) = O(m)
- T_{get}(s,d,m) = O(m)
- T_{remove}(s,d,m) = O(dm)

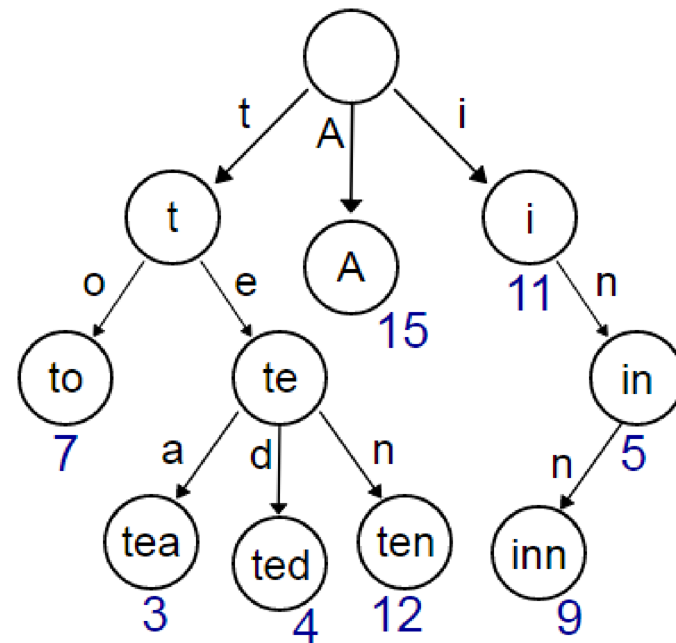

Aplicaciones: Word matching

- <u>Problema:</u> Dado un documento determinar todas las apariciones de una palabra determinada.
- <u>Ejemplo:</u> Opción Ctrl-F en Google Chrome.
- <u>Solución:</u> Construir un trie donde por cada palabra se almacena la lista de posiciones (una lista de enteros) de las apariciones de la palabra.
- <u>Referencia:</u> Ver Figura 12.7 de GT.

Bibliografía

- Capítulo 12, Sección 3 de M. Goodrich & R. Tamassia, Data Structures and Algorithms in Java. Fourth Edition, John Wiley & Sons, 2006.