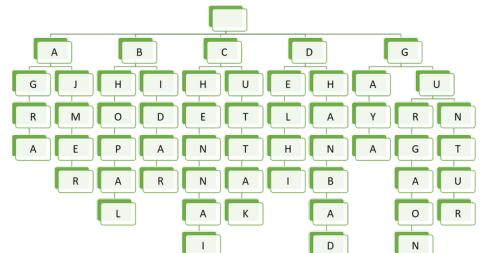


Tries (árvores digitais)

AULA 15



Fonte: [Building an autocomplete system using Trie](#)

Referências: Tries (árvores digitais) (PF); Tries (S&W); slides (S&W); Vídeo (S&W); TAOCP, vol 3, cap. 6.3

R-way tries

Uma **trie** (=R-way trie) é um tipo de árvore usado para implementar STs de **strings** sobre um alfabeto com R símbolos.

Tries também são conhecidas como **árvores digitais** e como **árvores de prefixos**.

Com **Tries** em vez de o **método de busca** ser baseado em comparações entre chaves, é **utilizada** a representação das chaves como **caracteres de um alfabeto**.

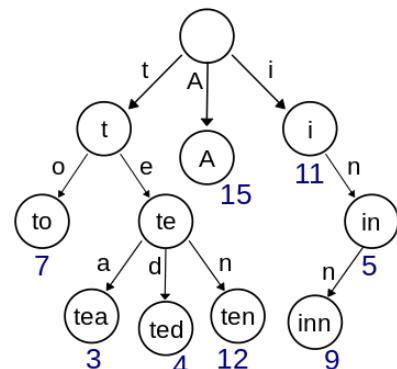
Considere, por exemplo, a **busca de uma palavra no dicionário**: a **primeira letra** indica as páginas que devemos olhar; a **segunda letra** restringe o espaço de busca;

Métodos específicos

A **API** de uma **trie** inclui, além do métodos usuais como **put()**, **get()**, **delete()**,..., 3 métodos **específicos**:

- **keysWithPrefix(String s)**: todas as chaves que têm prefixo s
- **keysThatMatch(String s)**: todas as chaves que **casam** com s quando '.' é usado como **curinga**
- **longestPrefixOf(String s)** a chave mais longa que é prefixo de s

Ilustração



Fonte: [Wikipedia](#)

Métodos específicos

Exemplos para o conjunto de chaves

she sells sea shells by the sea shore:

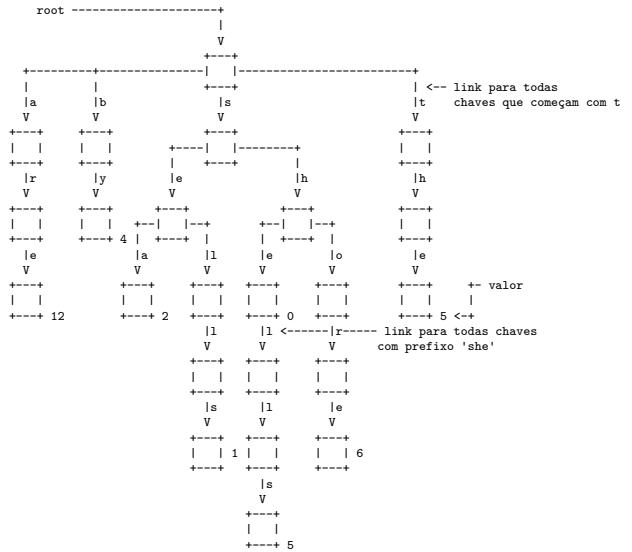
keysWithPrefix("she") devolve "she" e "shells"
keysWithPrefix("se") devolve "sells" e "sea"
keysThatMatch(".he") devolve "she" e "the"
keysThatMatch("s..") devolve "she" e "sea"
longestPrefixOf("shell") devolve "she"
longestPrefixOf("shellsort") devolve "shells"

Outra ilustração

Para os pares **key-val**

key	val
are	12
by	4
sea	2
sells	1
she	0
shells	3
the	5
shore	6

temos a **trie** a seguir



Estrutura do nó de uma trie

Os **links** correspondem a **caracteres** e não a chaves.
Tries são compostas por nós do tipo **Node**.

```
private static class Node {  
    private Value val;  
    private Node[] next = new Node[R];  
}
```

| a | b | c | d | e | f | g | h | i | j | k | l | m | n | o | p | q | r | s | t | u | v | w | x | y | z |

Fonte: JavaByPatel

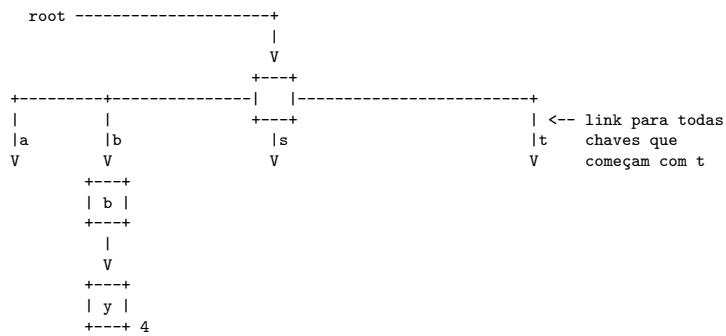
Muitos dos R ponteiros podem ser null.



Fonte: JavaByPatel

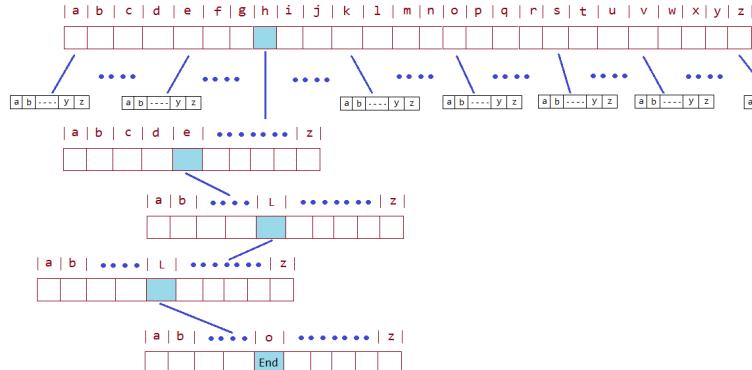
Ilustração

Se a **trie** é para o **alfabeto** 'a', 'b', ..., 'z' temos



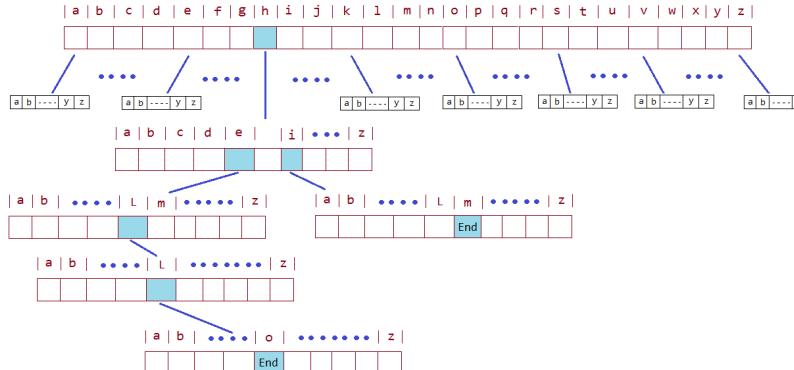
as **posições vazias** representam null

Trie para "hello"



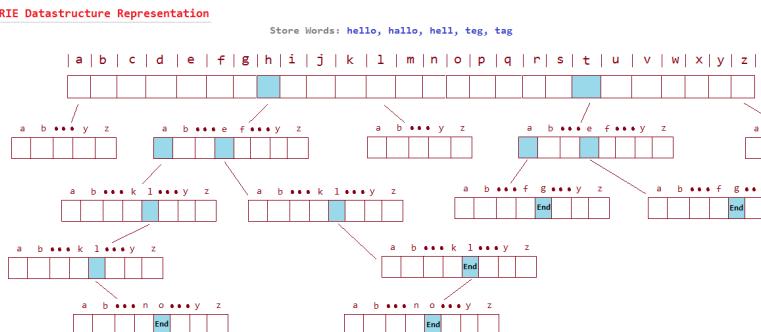
Fonte: [JavaByPatel](#)

Trie para "hello" e "him"



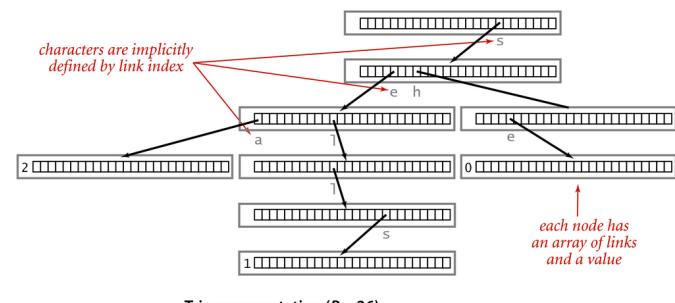
Fonte: [JavaByPatel](#)

Trie para ...



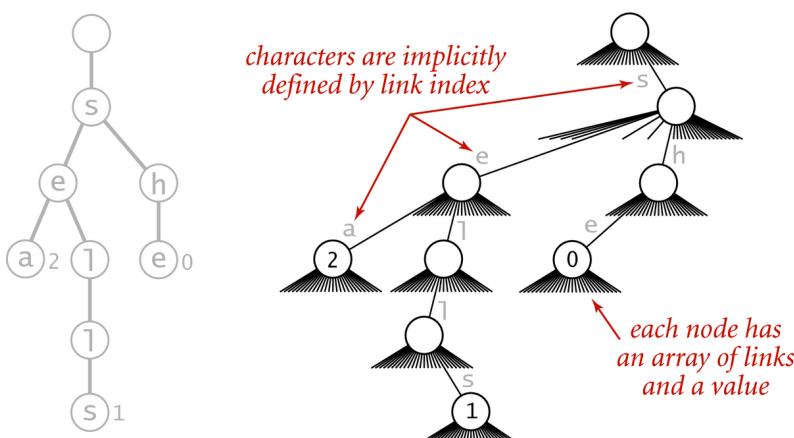
Fonte: [JavaByPatel](#)

Trie para "sea", "sells" e "he"



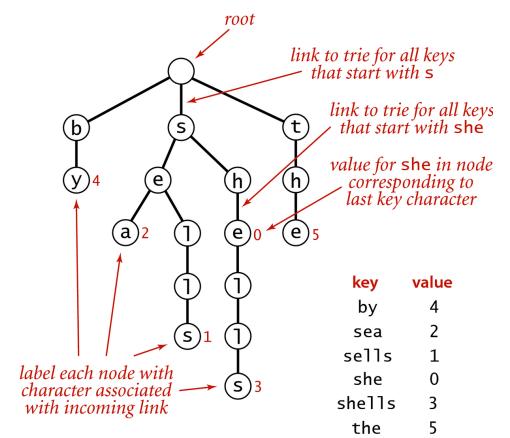
Fonte: [algs4](#)

Outra representação da mesma trie



Trie representation

Anatomia de uma Trie



Anatomy of a trie

Fonte: [algs4](#)

Observações

Duas observações importantes sobre tries:

- **chaves** ficam codificadas nos caminhos que começam na raiz;
- **prefixos de chaves**, que nem sempre são chaves, estão representados na trie.

Ao descer da raiz até um nó **x**, **soletramos** uma string, digamos **s**. Dizemos que **s** leva ao nó **x**.

Dizemos também que o nó **x** é localizado pela string **s**.

A string que leva a um nó **x** é uma chave se e somente se **x.val != null**.

Alfabeto

A implementação utiliza a classe **Alphabet**

Um **alfabeto** é um conjunto de **caracteres** ou **símbolos**.

Em Java, cada **caractere** é um número entre **0** e **65535**.

A classe **Alphabet** permite definir um alfabeto personalizado com **R** caracteres numerados de **0** a **R-1**.

R é a **base** do alfabeto.

Veja a página **Alfabetos e a classe Alphabet (PF)**

Alphabet API

public class Alphabet	
	Alphabet(String s)
int	toIndex(char c)
char	toChar(int i)
boolean	contains(char c)
int	R()
int	lgR()
	cria uma alfabeto com caracteres em s
	converte c em um índice em 0..R-1
	converte i para o caractere correspondente
	c está no alfabeto?
	base do alfabeto
	número de bits de um índice

Alfabeto do DNA

Alphabet("ACTG")

c	A	C	T	G
toIndex(c)	0	1	2	3

i	0	1	2	3
toChar(i)	A	C	T	G

Alfabeto ASCII

Para o **alfabeto ASCII** temos simplesmente

- **toIndex(c) == c** para todo **c**
- **toChar(i) == i** para todo **i**.

ASCII Code Chart																
0	NUL	SOH	STX	ETX	EOT	ENQ	ACK	BEL	BS	HT	LF	VT	FF	CR	SO	SI
1	DLE	DC1	DC2	DC3	DC4	NAK	SYN	ETB	CAN	EM	SUB	ESC	FS	GS	RS	US
2	!	"	#	\$	%	&	'	()	*	+	,	-	.	/	
3	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5	P	Q	R	S	T	U	V	W	X	Y	Z	[\	^	_	
6	~	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7	p	q	r	s	t	u	v	w	x	y	z	{	}	~	DEL	

Fonte: [Wikipedia](#)

Implementação (ASCII extendido)

```
public class TrieST<Value> {  
    // tamanho do alfabeto  
    private static int R = 256;  
    // número de pares chave-valor  
    private int n;  
    private Node r; // raiz da trie  
    private static class Node{...}  
    public Value get(String key) {...}  
    private Node get(Node x, String key, int d)  
    {...}  
    public void put(String key, Value val) {...}  
    private Node put(Node x, String key,  
                    Value val, int d) {...}  
    public void delete(String k) {...}  
    public Iterable<String> keys() {...}  
}
```

get(key): método clássico

Seguimos os ponteiros soletrando a string key.

```
public Value get(String key) {  
    Node x = get(r, key, 0);  
    if (x == null) return null;  
    return x.val;  
}
```

put(key, val): método clássico

É feita uma busca.

Se a key é encontrada o valor val é substituído.
Caso contrário chegamos a um null e devemos
continuar a inserção ou chegamos no último
caractere de key.

```
public void put(String key, Value val) {  
    r = put(r, key, val, 0);  
}
```

delete(key): método clássico

delete(key) remove a chave key do conjunto de chaves da trie.

Em princípio, a implementação de delete() é fácil:
basta encontrar o nó x localizado por key e fazer

```
x.val = null;
```

Infelizmente, a trie resultante dessa operação pode
não ser limpa.

Para manter a trie limpa, é preciso fazer algo mais complexo.

get(key): método clássico

Seguimos os ponteiros soletrando a string key.

```
private Node get(Node x, String key,  
                 int d) {  
    if (x == null) return;  
    if (d == key.length()) return x;  
    char c = key.charAt(d);  
    return get(x.next[c], key, d+1);  
}
```

put(key, val): método clássico

```
private Node put(Node x, String key,  
                 Value val, int d) {  
    if (x == null) x = new Node();  
    if (d == key.length()) {  
        if (x.val == null) n++;  
        x.val = val;  
        return x;  
    }  
    char c = key.charAt(d);  
    x.next[c] = put(x.next[c], key, val, d+1);  
    return x;  
}
```

delete(key): método clássico

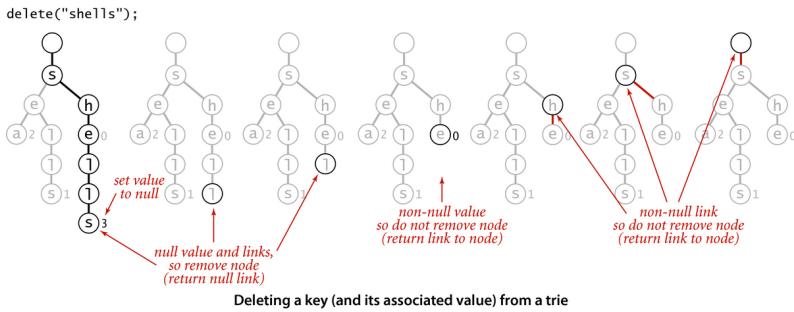
```
public void delete(String key) {  
    r = delete(r, key, 0);  
}
```

```

delete(key): método clássico
private Node delete(Node x, String key,
                    int d) {
    if (x == null) return null;
    if (d == key.length()) x.val = null;
    else {
        char c = key.charAt(d);
        x.next[c] = delete(x.next[c], key, d+1);
    }
    if (x.val != null) return x;
    for (char c = 0; c < R; c++)
        if (x.next[c] != null) return x;
    return null;
}

```

delete(key): ilustração



Fonte: algs4

keysWithPrefix(pre): método especial

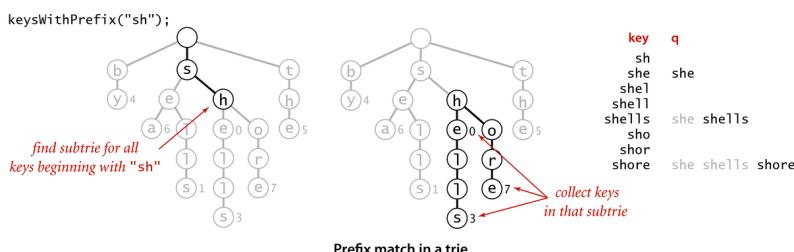
Devolve todas as chaves na ST que têm prefixo pre.

```

public Iterable<String>
    keysWithPrefix(String pre) {
    Queue<String> q = new Queue<String>();
    Node x = get(r, pre, 0);
    collect(x, pre, q);
    return q;
}

```

keysWithPrefix(pre): ilustração



Fonte: algs4

collect(): método auxiliar

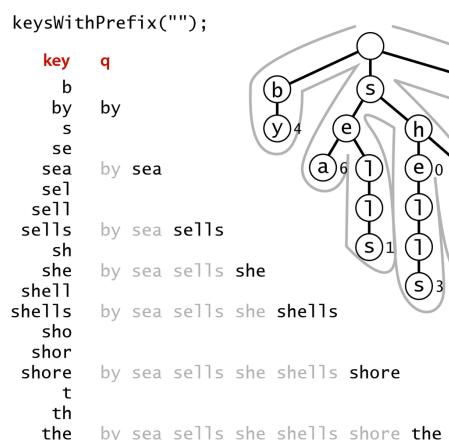
O método coloca na fila q todas as chaves da subtrie cuja raiz é x depois de acrescentar o prefixo pre a todas essas chaves.

```

private void collect(Node x, String pre,
                    Queue<String> q) {
    if (x == null) return;
    if (x.val != null) q.enqueue(pre);
    for (char c = 0; c < R; c++)
        collect(x.next[c], pre+c, q);
}

```

collect(): ilustração



Fonte: algs4

keys(): método clássico

```
public Iterable<String> keys() {  
    return keysWithPrefix("");  
}
```

keysThatMatch(): método especial

Devolve todas as chaves que casam com o padrão pat.

Todos os caracteres '.' em pat são curingas.

```
public Iterable<String>  
keysThatMatch(String pat) {  
    Queue<String> q = new Queue<String>();  
    collect(r, "", pat, q);  
    return q;  
}
```

Consumo de espaço e tempo

A estrutura de uma **trie** não depende da ordem em que as chaves são inseridas ou removidas.

O consumo de tempo das operações sobre uma **trie** não depende do número n de itens.

O número de nós visitados por `get(key)` é no máximo $1 + w$, onde $w = \text{key.length}()$.

O número de links em uma **trie** é entre Rn e Rnw onde w é o comprimento médio de uma chave.

longestPrefixOf(s): método especial

Devolve a maior chave que é prefixo de s.

```
public String longestPrefixOf(String s) {  
    int max = -1;  
    Node x = r;  
    for (int d = 0; x != null; d++) {  
        if (x.val != null) max = d;  
        if (d == s.length()) break;  
        x = x.next[s.charAt(d)];  
    }  
    if (max == -1) return null  
    return s.substring(0, max);  
}
```

Mais um collect()

Coloca em q todas as chaves da trie que têm prefixo pre e casam com o padrão pat.

```
private void collect(Node x, String pre,  
                     String pat, Queue<String> q) {  
    if (x == null) return;  
    if (pre.length() == pat.length()  
        && x.val != null)  
        q.enqueue(pre);  
    if (pre.length() == pat.length()) return;  
    char c_next = pat.charAt(pre.length());  
    for (int c = 0; c < R; c++)  
        if (c_next == '.' || c_next == c)  
            collect(x.next[c], pre+c, pat, q);  
}
```

Consumo de espaço e tempo

O número esperado de nós visitados durante uma busca malsucedida em uma **trie** com n chaves aleatórias sobre um alfabeto de tamanho R é aproximadamente $\log_R n$.

Tries ternárias

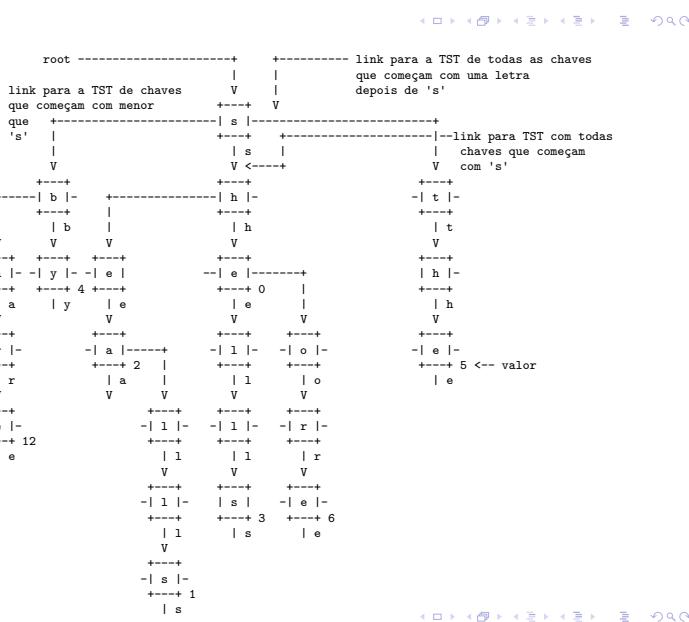


Fonte: The Little Prince, Antoine de Saint-Exupéry

Referências: Tries (árvores digitais) (PF); Tries (S&W); slides (S&W); Vídeo (S&W); TAOCP, vol 3, cap. 6.3

Alphabet

nombre	R()	lg(R)	conjunto de caracteres
BINARY	2	1	'01'
DNA	4	2	'ACTG'
OCTAL	8	3	'01234567'
DECIMAL	10	4	'0123456789'
HEXADECIMAL	16	4	'0123456789ABCDEF'
PROTEIN	20	5	'ACDEFGHIJKLMNOPQRSTUVWXYZ'
LOWERCASE	26	5	'abcd...wxyz'
UPPERCASE	26	5	'ABCD...WXYZ'
ASCII	128	7	alfabeto ASCII
EXTENDED_ASCII	256	8	alfabeto ASCII estendido
UNICODE16	65536	16	alfabeto Unicode



Tries ternárias

O maior problema das tries é possivelmente o espaço, já que cada nó contém R referências.

Assim, cada nó utiliza pelo menos $8 \times R$ bytes.

Veja alguns valores de R para de alguns alfabeto na classe [Alphabet](#)' na página [Alfabetos e a classe Alphabet \(PF\)](#).

Para evitar o custo excessivo de espaço associamos de uma **R-trie**, consideramos uma representação como uma **ternary search trie (TST)**.

Outra ilustração

Para os pares key-val

key	val
are	12
by	4
sea	2
sells	1
she	0
shells	3
the	5
shore	6

temos a **TST** a seguir

TSTS

De maneira semelhante ao que ocorre com tries, nas tries ternárias:

- ▶ **chaves** ficam codificadas nos caminhos que começam na raiz;
 - ▶ **prefixos** de chaves, que nem sempre são chaves, estão representados na **TST**.

Estrutura de uma trie ternária

Os **links** da estrutura correspondem a caracteres.
Nas figuras, o **caractere** escrito dentro de um nó é o **caractere do link** que sai pelo meio do nó.
TSTs são compostas por nós do tipo **Node**.

```
private static class Node {
    private char c; // caractere
    private Value val;
    private Node left; // < c
    private Node mid; // == c
    private Node right; // > c
}
```

Ilustração

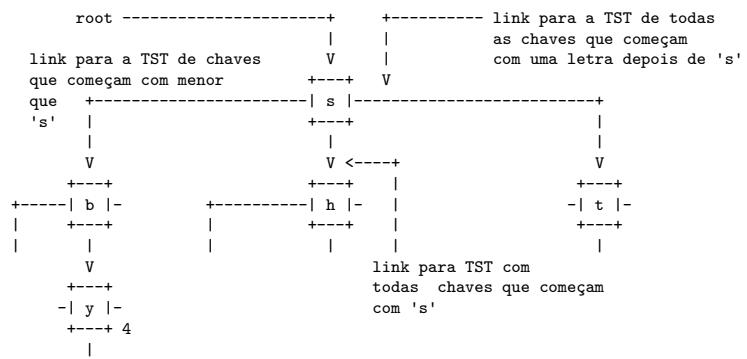
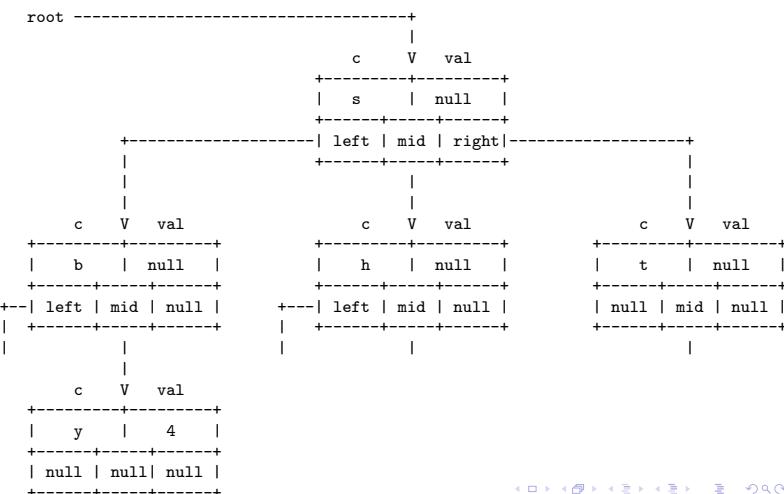
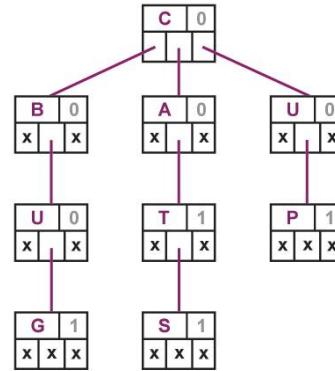


Ilustração com zoom



Outra ilustração



Ternary Search Tree for CAT, BUG, CATS, UP

Fonte: [Ternary search trees for autocomplete and spell checking](#)

get(key): método clássico

```
public class TST<Value> {
    private int n;
    private Node r; // raiz da tst
    private static class Node{...}
    public Value get(String key) {...}
    private Node get(Node x, String key, int d)
    {...}
    public void put(String key, Value val) {...}
    private Node put(Node x, String key,
                    Value val, int d) {...}
    public Iterable<String> keys() {...}
}
```

A string que leva a um nó **x** é uma chave se e somente se **x.c** é o último caractere da chave e **x.val != null**.

```
// TrieST e TST
public Value get(String key) {
    Node x = get(r, key, 0);
    if (x == null) return null;
    return x.val;
}
```

`get(key)`: método clássico

```
private Node get(Node x, String key,
                 int d) {
    char c = key.charAt(d);
    if (x == null) return null;
    if (c < x.c)
        return get(x.left, key, d);
    if (c > x.c)
        return get(x.right, key, d);
    if (d < key.length()-1)
        return get(x.mid, key, d+1);
    return x;
}
```

`put(key, val)`: método clássico

```
private Node put(Node x, String key,
                 Value val, int d) {
    char c = s.charAt(d);
    if (x == null)
        { x = new Node(); x.c = c; }
    if (c < x.c)
        x.left = put(x.left, s, val, d);
    else if (c > x.c)
        x.right = put(x.right, s, val, d);
    else if (d < s.length()-1)
        x.mid = put(x.mid, s, val, d+1);
    else x.val = val;
    return x;
}
```

`keys()`: método clássico

```
public Iterable<String> keys() {
    Queue<String> q = new Queue<String>();
    collect(r, "", q);
    return q;
}
```

`put(key, val)`: método clássico

É feita uma **busca**.

Se a `key` é encontrada o valor `val` é **substituído**. Caso contrário chegamos a um `null` e devemos **continuar a inserção** ou chegamos no último caractere de `key`.

```
// TrieST e TST
public void put(String key, Value val) {
    r = put(r, key, val, 0);
}
```

`collect()`: método auxiliar

O método coloca na fila `q` todas as chaves da **subtrie** cuja raiz é `x` depois de acrescentar o prefixo `pre` a todas essas chaves.

```
private void collect(Node x, String pre,
                     Queue<String> q) {
    if (x == null) return;
    collect(x.left, pre, q);
    // ordem lexicográfica
    if (x.val != null) q.enqueue(pre+x.c);
    collect(x.mid, pre+x.c, q);
    collect(x.right, pre, q);
}
```

`keysWithPrefix()`: método especial

Devolve todas as chaves na **ST** que têm prefixo `pre`.

```
public Iterable<String>
    keysWithPrefix(String pre) {
    Queue<String> q = new Queue<String>();
    Node x = get(r, pre, 0);
    if (x == null) return q;
    if (x.val != null) q.enqueue(pre);
    collect(x.mid, pre, q);
    return q;
}
```

longestPrefixOf(): método especial

Devolve a maior chave que é prefixo de s.

```
public String longestPrefixOf(String s) {
    if (s == null || s.length() == 0)
        return null;
    int max = 0;
    Node x = r;
    int i = 0;
```

longestPrefixOf(): método especial

```
while (x != null && i < s.length()) {
    char c = s.charAt(i);
    if (c < x.c) x = x.left;
    else if (c > x.c) x = x.right;
    else {
        i++;
        if (x.val != null) max = i;
        x = x.mid;
    }
}
return s.substring(0, max);
```

keysThatMatch(): método especial

Devolve todas as chaves que casam com o padrão pat. Todos os caracteres '.' em pat são curingas.

```
public Iterable<String>
keysThatMatch(String pat) {
    Queue<String> q = new Queue<String>();
    collect(r, "", 0, pat, q);
    return q;
}
```

Mais um collect()

Coloca em q todas as chaves da trie que têm prefixo pre e casam com o padrão pat.

```
private void collect(Node x, String pre,
                     int i, String pat, Queue<String> q){
    if (x == null) return;
    char c = pat.charAt(i);
    if (c == '.' || c < x.c)
        collect(x.left, pre, i, pat, q);
    else if (c == x.c)
        collect(x.mid, pre+x.c, i+1, pat, q);
    else if (c > x.c)
        collect(x.right, pre, i, pat, q);
```

Mais um collect()

```
if (c == '.' || c == x.c) {
    if (i == pat.length() - 1
        && x.val != null)
        q.enqueue(pre+x.c);
    else if (i < pat.length() - 1)
        collect(x.mid, pre+x.c, i+1, pat, q);
}
if (c == '.' || c > x.c)
    collect(x.right, pre, i, pat, q);
```

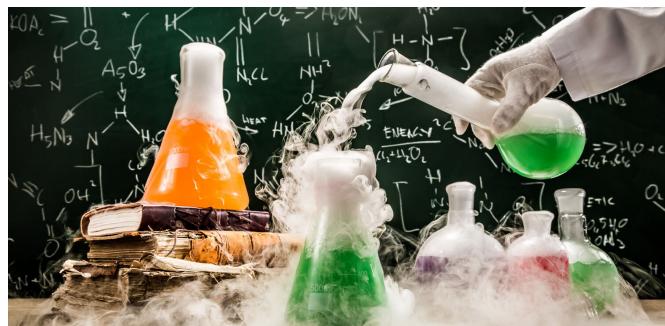
Consumo de espaço e tempo

Espaço. A propriedade mais importante de uma TST é que ela tem apenas três links por nó.

Proposição J: O número de links em uma TST com n chaves de comprimento médio w é entre 3n e 3nw.

Proposição K: O número esperado de nós visitados durante uma busca malsucedida em uma TST com n chaves aleatórias é aproximadamente $\lg n$.

Alguns experimentos



Fonte: <https://singularityhub.com/>

Experimentos: les_miserables.txt

ST com 26764 itens

% wc les-miserables.txt

68116 568531 3322649 les-miserables.txt

ST	criada (s)
BST	0.626
Red-Black	0.577
Separate chain	0.495 (4096, 18, $\alpha = 6$)
Linear probing	0.411 (65536, 67, $\alpha = 0.40$)
Tries	0.574
TST	0.497

Experimentos: actors.list

ST com 1482495 itens

% wc actors.list

16612200 124796815 932688622 actors.list

ST	criada (s)
BST	141.968
Red-Black	168.723
Separate Chain	110.035 (262144, 19, $\alpha = 5$)
Linear Probing	73.123 (4194304, 4787 $\alpha = 0.35$)
Tries	OutOfMemoryError
TST	107.223