

Como Escribir un Corrector Ortografico en 20 Lineas

Habla: Roberto Alsina <ralsina@netmanagers.com.ar>

Codigo: Norvig & Bacon

El Codigo

```
import re, collections

def words(text): return re.findall('[a-z]+', text.lower())

def train(features):
    model = collections.defaultdict(lambda: 1)
    for f in features:
        model[f] += 1
    return model

NWORDS = train(words(file('big.txt').read()))

alphabet = 'abcdefghijklmnopqrstuvwxyz'

def edits1(word):
    s = [(word[:i], word[i:]) for i in range(len(word) + 1)]
    deletes      = [a + b[1:] for a, b in s if b]
    transposes  = [a + b[1] + b[0] + b[2:] for a, b in s if len(b)>1]
    replaces    = [a + c + b[1:] for a, b in s for c in alphabet if b]
    inserts     = [a + c + b      for a, b in s for c in alphabet]
```

El Código

```
return set(deletes + transposes + replaces + inserts)

def known_edits2(word):
    return set(e2 for e1 in edits1(word) for e2 in edits1(e1) if e2 in NWORDS)

def known(words): return set(w for w in words if w in NWORDS)

def correct(word):
    candidates = known([word]) or known(edits1(word)) or known_edits2(word) or [word]
    return max(candidates, key=NWORDS.get)
```

Como funciona (La teoria)

Todo esto es culpa del teorema de Bayes (ignorenme!).

Queremos saber en que palabra estaba pensando el usuario. Entonces:

- Cual es la probabilidad de que sea exactamente lo que escribio? $P(w)$
- Dado un reemplazo c , cual es la probabilidad que sea esa? $P(c)$
- Cual es la probabilidad de que haya puesto w queriendo poner c ? $P(w|c)$
- En realidad, queremos maximizar $P(w|c) * P(c)$

O sea: queremos la palabra c mas probable que se parezca mas a w .

- Si es muy distinta de w , c no nos sirve ($w=berde$, $c=hola$)
- Si es muy rara, no nos sirve ($w=verdo$, $c=bardo$)
- Si es comun y parecida, c es genial!

Codigo!!!!

Codigo!!!!

POR FAVOR!

Calculando P(c)

- Agarra un montoooooon de texto y conta las palabras.
- Indexalo por palabra
- Listo

```
def words(text): return re.findall('[a-z]+', text.lower())

def train(features):
    model = collections.defaultdict(lambda: 1)
    for f in features:
        model[f] += 1
    return model

NWORDS = train(words(file('big.txt').read()))
```

Calculando $P(w|c)$

Que quiere decir parecida?

- Distancia de edicion

Cuantas veces tengo que editar una palabra para convertirla en otra.

- hola -> bola = 1 (alteracion)
- hola -> ola = 1 (eliminacion)
- hola -> holas = 1 (insercion)
- hola -> ohla = 1 (transposicion)

CODIGO!!!!

Aca viene...

Esto te da el conjunto de todas las palabras a distancia 1 de otra:

```
def edits1(word):
    n = len(word)
    return set([word[0:i]+word[i+1:] for i in range(n)] +
               [word[0:i]+word[i+1]+word[i]+word[i+2:] for i in range(n-1)] + # transposition
               [word[0:i]+c+word[i+1:] for i in range(n) for c in alphabet] + # alteration
               [word[0:i]+c+word[i:] for i in range(n+1) for c in alphabet]) # insertion
```

El 80% de los errores son a distancia 1. Si queres distancia 2 (95% de los errores), es usar edits1 dos veces ;-)

```
def edits2(word):
    return set(e2 for e1 in edits1(word) for e2 in edits1(e1))
```

SON DEMASIADAS!

En realidad, edits2 da MUCHO. Entonces descartamos todo lo que no puede ser una correccion porque nunca lo vimos escrito en un texto (tiene $P(c)=0$)

```
def known_edits2(word):
    return set(e2 for e1 in edits1(word) for e2 in edits1(e1) if e2 in NWORDS)

len(known_edits2('something'))

3

len(edits2('something'))

114324
```

ESTIMANDO P(w|c)

```
def known(words): return set(w for w in words if w in NWORDES)

def correct(word):
    candidates = known([word]) or known(edits1(word)) or known_edits2(word) or [word]
    return max(candidates, key=lambda w: NWORDES[w])
```

- known descarta las palabras que nunca vimos en uso.
- correct dice:
 - si word es conocida, la corrección es word. Si no...
 - si hay palabras conocidas a distancia 1, es la mas probable de esas. Si no...
 - si hay palabras conocidas a distancia 2, es la mas probable de esas. Si no....
 - me rindo

Y funciona????

Y funciona????

Si:

```
>>> correct('speling')
'spelling'
>>>correct('korrechter')
'corrector'
```