Laboratorio Nacional de Políticas Públicas

CIDE CENTRO DE INVESTIGACIÓN Y DOCENCIA ECONÓMICAS A.C.

Introducción a regex con rebus

Periodismo de datos
Febrero, 2021

M.C. JORGE JUVENAL CAMPOS FERREIRA.
Investigador Asociado.
Laboratorio Nacional de Políticas Públicas
CIDE

Introducción

Requerimientos para la sesión:

Instalar los paquetes {rebus}, {stringr} y {htmltools}.

Introducción

Como vimos la clase pasada con Sebastián, las funciones de la librería stringr funcionan con algo llamado "patrones".

```
str_view(string, pattern, match = NA)

str_view_all(string, pattern, match = NA)
```

Sin embargo... ¿qué son y cómo podemos generar esos patrones?

Para eso, en programación contamos con una herramienta muy poderosa conocida como *regex* o *expresiones regulares*.

Expresiones regulares

Las expresiones regulares son **secuencias de caracteres** para definir un patrón de búsqueda.

Las expresiones regulares sirven **tanto para quedarnos** con palabras/frases importantes, así **como para deshacernos de ellas.**

Inversión de tiempo que todo buen analista de datos tiene que hacer.
Son **la navaja suiza para trabajar con datos de texto.**

¿Cómo funcionan las expresiones regulares?

Regex

¿Cómo se ven las expresiones regulares?

Las regex son cadenas de texto que, a través de símbolos predefinidos, nos sirven para detectar un patrón en un texto.

Regex

¿Cómo se ven las expresiones regulares?

Las regex son cadenas de texto que, a través de símbolos predefinidos, nos sirven para detectar un patrón en un texto.

Ejemplo:

```
(?<![\\w\\d])Retweet(?![\\w\\d])(\\s[\\d\\.(K|M)?]+)?
```

(Regex para capturar el numero de retweets de una base de datos en TW)

Regex

¿Cómo se ven las expresiones regulares?

Las regex son cadenas de texto que, a través de símbolos predefinidos, nos sirven para detectar un patrón en un texto.

Ejemplo:

```
(?<![\\w\\d])Retweet(?![\\w\\d])(\\s[\\d\\.(K|M)?]+)?
```

(Regex para capturar el numero de retweets de una base de datos en TW)

Regex

Las regex son conceptos complicados (incluso para los programadores), así que tómenlo con calma.

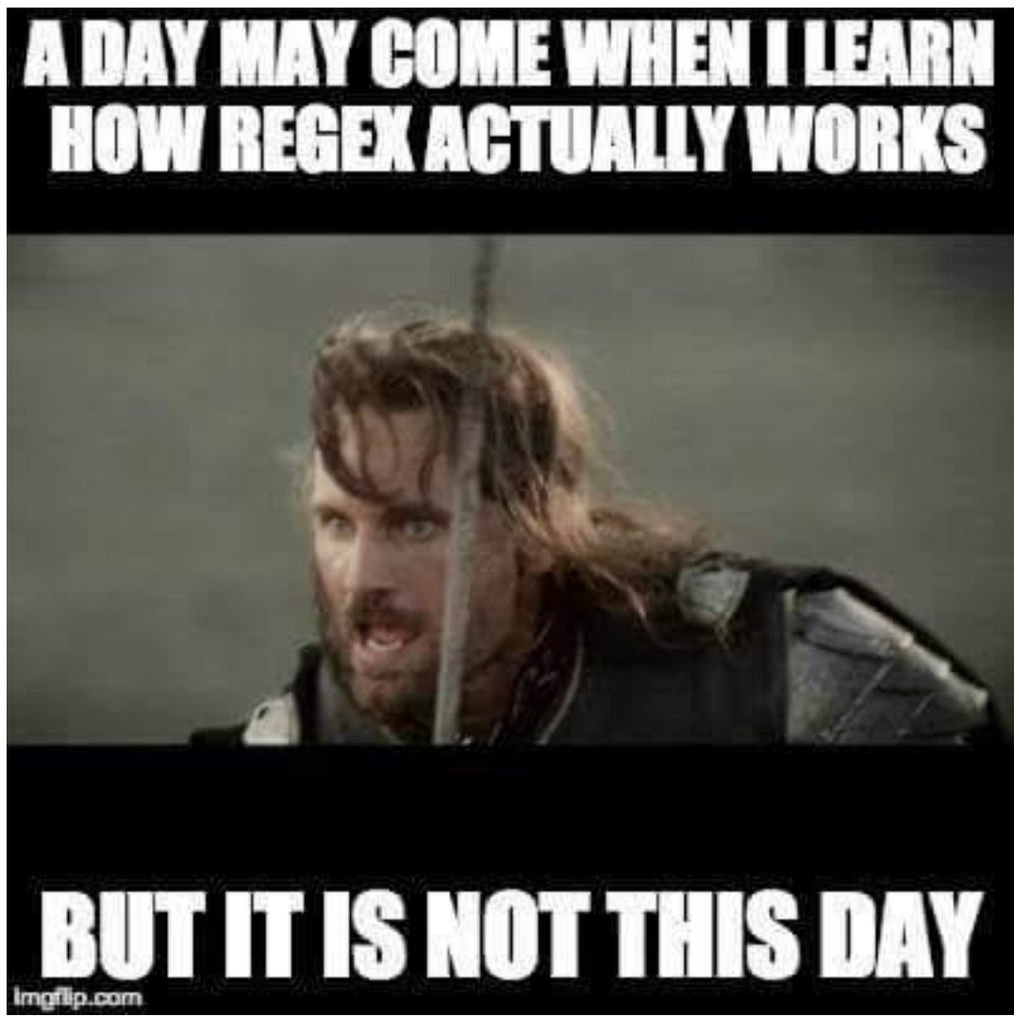

{rebus}

En R, existe una forma menos dolorosa para poder aprender (y utilizar) estos conceptos sin tanto sufrimiento.

La librería {rebus} nos da la facilidad de construir expresiones regulares **de manera más intuitiva,** mientras vamos aprendiendo a trabajar con las *regex* tradicionales.

rebus: Build Regular Expressions in a Human Readable Way

Build regular expressions piece by piece using human readable code. This package is designed for interactive use.

Documentación:

https://www.rdocumentation.org/packages/rebus/versions/0.1-3

Objetos pre-programados {rebus}

Patrón	Expresión Regular	Objeto rebus
Inicio de un string o cadena de texto	^	START
Final de un string	$	END
Cualquier carácter sencillo	.	ANY_CHAR
Punto literal, gorrito o signo de pesos	\. \^ \$	DOT, CARAT, DOLLAR

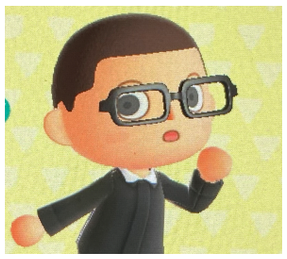

Ojo! 👀 Todo esto va a tener más sentido una vez que nos pongamos a programar! Por lo que, por esto mismo, traten de volver a esta presentación en el futuro.

Objetos pre-programados {rebus}

Objeto Rebus	Regex Tradicional	Interpretación
UPPER	**[:upper:]**	**Letras en Mayúsculas**
PUNCT	**[:punct:]**	**Signo de puntuación**
DOT	**\\.**	**Punto**

Patrón	Expresión Regular	Función rebus
Valor exacto	^$	exactly()
Captura	()	capture()
Este patrón o este patrón (varios en uno)	(?:a|b)	or1(c(pat_1, pat_2))

Funciones de repetición {rebus}

Patrón	Expresión Regular	Función rebus
Opcional	?	optional()
Zero o más	*	zero_or_more()
Uno o más	+	one_or_more()
Entre *n* y *m* veces	{n}{m}	repeated()

Escapando caracteres especiales

Cuando estamos generando expresiones regulares en R, tenemos que tener cuidado al utilizar los símbolos siguientes:

- **Paréntesis:** “(“ y “)”
- **Corchetes:** “[“ y “]”
- **Gorritos:** “^”
- **Símbolos de Moneda** “$”
- **Guiones:** “-“ o “ ”
- **Símbolo de Más:** “+”
- **Símbolo de interrogación:** “?”

Si queremos diseñar patrones utilizando estos símbolos especiales, tenemos que “escaparlos” primero, utilizando “\\”, por ejemplo:

```
pat <- "\\[" %R% capture(one_or_more(DGT)) %R% "\\])"
```

Función char_class()

Esta función sirve para definir un conjunto de caracteres que van a formar parte del patrón. Por ejemplo:

```
library(rebus)
c <- char_class("aeiouAEIOUñ@")
str_view_all("Estos niñ@s son mis Alumnos", pattern = c)
```

En este caso, creamos un objeto en el cual el patrón a detectar va a ser todas las vocales, minúsculas y mayúsculas, la letra ñ y el arroba. Abajo, podemos ver lo que captura este patrón:

Función %R% (pipa rebus, concatenar)

Esta función sirve para concatenar objetos rebus, para poder armar patrones compuestos.

Ejemplo de uso:

```
pat <- START %R% WRD %R% DGT %R% capture(one_or_more(SPC)) %R% END
```

Patrón compuesto.

Este patrón va a capturar:

“Al inicio del renglón”: “una letra” + “un dígito” + “uno o varios espacios” + “final del string”

Algo así como: A10000231

Hay que entenderlo como el “**pegamento**” que va a unir múltiples objetos rebus para armar un patrón compuesto.

Funciones:

stringr::str_view(*string, pattern, match*)
stringr::str_view_all(*string, pattern, match*)

Esta función nos permite probar nuestros intentos de expresiones regulares. “Para atrapar lo que queremos atrapar.”

Solo se visualizan donde hay coincidencias con el patrón

Atrapa a todos los números de manera individual

```
str_view_all(contact, pattern = DGT , match = TRUE)
```

Objeto rebus de patrón de dígito o números

```
Call me at 555-555-0191
123 Main St
(555) 555 0191
Phone: 555.555.0191 Mobile: 555.555.0192
```

Funciones *_all* de stringr

Función	Efecto
str_view()	Permite revisar si el patrón que definimos atrapa lo que queremos atrapar. **Solo remarca la primera vez que detecta el patrón.**
str_extract()	Extrae el pedazo del string en donde se detecta el patrón indicado. **Solo lo hace con la primera ocurrencia.**
str_remove()	Remueve el pedazo del string en donde se detecta el patrón indicado. **Solo lo hace con la primera ocurrencia.**
str_replace()	Reemplaza el pedazo del string en donde **se detecta por primera vez el patrón** indicado, con un reemplazo proveído por el usuario.

Función "_all"	Efecto
str_view_all()	Permite revisar si el patrón que definimos atrapa lo que queremos atrapar. **Atrapa todas las ocurrencias del patrón.**
str_extract_all()	Extrae el pedazo del string en donde se detecta el patrón indicado para TODAS las ocurrencias. **Si hay más de una genera una lista por cada string analizado.**
str_remove_all()	Remueve el pedazo del string en donde se detecta el patrón indicado **en todas las ocurrencias.**
str_replace_all()	**Reemplaza el pedazo de string en todas las ocurrencias del patrón a lo largo del texto.** Igualmente, acepta la opción de introducir un vector nombrado para asignar múltiples reemplazos.

Nota para los que ya conocen las expresiones regulares.

El paquete {rebus} es una herramienta para utilizar expresiones regulares sin aprender la sintaxis tradicional. Si, en tu caso, te sientes más cómodo utilizando esta sintaxis, te recomiendo que la sigas utilizando.

Ojo! Solo que, a diferencia de las expresiones regulares normales que utilizaríamos en cualquier otro lado, en R tenemos que escaparlas con doble backlash (\\) por ejemplo:

Texto: “Timmy y Tommy son los sobrinos del viejo Nook”

Objetivo	Con rebus	Con regex normal	Con regex para R	Resultado
Atrapar todos los nombres propios	UPPER %R% one_or_more(WRD)	[:upper:][\w]+	[:upper:][\\w]+	`Timmy` y `Tommy` son los sobrinos del viejo `Nook`
Atrapar todas las palabras después de Timmy y Tommy	one_or_more(WRD) %R% SPC %R% "Nook"	[\w]+\sNook	[\\w]+\\sNook	Timmy y Tommy son los sobrinos del `viejo Nook`

Manos a la obra

A continuación vamos a llevar a cabo un ejemplo

Manos a la obra

1. Leemos las librerías

```
library(rebus)
library(stringr)
```

2. Generamos texto

```
# Some strings to practice with
x <- c("cat", "coat", "scotland", "tic toc")
```

3. Primer patrón!
Generamos un patrón de las palabras que empiezan con la letra “c”

```
# Run me
str_view(x, pattern = START %R% "c")
```

Ejemplos

4. Resultado

Se marca en obscuro la letra c inicial.

```
# Run me
str_view(x, pattern = START %R% "c")
```

```
cat

coat

scotland

tic toc
```

Ejemplos

5. Ahora, las que terminen en “-at”

```
# Match the strings that end with "at"
str_view(x, pattern = "at" %R% END)
```

cat

coat

scotland

tic toc

Ejemplos

6. Palabras que llevan un caracter, y luego llevan una “t”

```
x <- c("cat", "coat", "scotland", "tic toc")

# Match any character followed by a "t"
str_view(x, pattern =  ANY_CHAR %R% "t")
```

cat

coat

scotland

tic toc

Ejemplos

7. Palabras de exactamente 3 caracteres.

```
# Match a string with exactly three characters
str_view(x, pattern = START %R% ANY_CHAR %R% ANY_CHAR %R% ANY_CHAR
%R% END)
```

```
cat

coat

scotland

tic toc
```

Ejercicio.

Abramos RStudio y corramos el ejemplo que les envié a su correo.