

Package ‘datamedios’

May 20, 2025

Type Package
Title Scraping Chilean Media
Version 1.2.1
Maintainer Exequiel Trujillo <exequiel.trujillo@ug.uchile.cl>
Description A system for extracting news from Chilean media,
specifically through Web Scapping from Chilean media. The package al-
lows for news searches using search phrases and date filters,
and returns the results in a structured format, ready for analysis.
Additionally, it includes functions to clean the extracted data, visualize it, and
store it in databases. All of this can be done automatically, facilitating the collection and analy-
sis of relevant
information from Chilean media.
License MIT + file LICENSE
Encoding UTF-8
Language es-ES
Depends R (>= 4.1)
Suggests rcmdcheck
Imports dplyr, httr, magrittr, jsonlite, utils, rlang, wordcloud2,
tidytext, lubridate, rvest, stringr, xml2, purrr, DT, ggplot2
RoxygenNote 7.3.2
NeedsCompilation no
Author Exequiel Trujillo [aut, cre, cph, fnd],
Ismael Aguayo [aut, fnd],
Klaus Lehmann [aut, fnd]
Repository CRAN
Date/Publication 2025-05-19 22:10:01 UTC

Contents

agregar_datos_unicos	2
extraccion_parrafos	3

extraer_noticias_fecha	3
extraer_noticias_fecha_bbcl	4
extraer_noticias_fecha_emol	5
extraer_noticias_max_res	6
extraer_noticias_max_res_bbcl	7
extraer_noticias_max_res_emol	7
grafico_notas_por_mes	8
init_req_bbcl	9
init_req_emol	9
iteracion_emol	10
limpieza_notas	11
parserFuentes	11
tabla_frecuencia_palabras	12
word_cloud	13
Index	14

agregar_datos_unicos *Agregar datos unicos a una tabla MySQL*

Description

Esta funcion agrega datos a una tabla MySQL utilizando endpoints que esperan datos en formato JSON.

Usage

```
agregar_datos_unicos(data)
```

Arguments

`data` Un data frame con los datos a insertar.

Value

No retorna ningun valor.

Examples

```
## Not run:
# Agregar datos unicos
noticias <- extraer_noticias_max_res("tesla", max_results=10, fuentes="bbcl", subir_a_bd = FALSE)
agregar_datos_unicos(noticias)

## End(Not run)
```

extraccion_parrafos	<i>Extraer parrafos de una columna de texto</i>
---------------------	---

Description

Esta funcion procesa una columna de texto en un dataframe y extrae los parrafos que coinciden con los sinonimos proporcionados.

Usage

```
extraccion_parrafos(datos, sinonimos = c())
```

Arguments

datos	Data frame que contiene los datos de entrada con la columna "contenido".
sinonimos	Vector de sinonimos que se incluyan en la busqueda.

Value

Data frame con una columna adicional 'parrafos_filtrados' que contiene los parrafos extraidos como listas.

Examples

```
datos <- extraer_noticias_max_res("inteligencia artificial", max_results = 140, subir_a_bd = FALSE)
datos <- extraccion_parrafos(datos, sinonimos = c("IA", "AI"))
```

extraer_noticias_fecha

Extraccion de noticias de medios chilenos por rango de fechas

Description

Esta funcion permite realizar una extraccion automatizada de noticias de BioBio o Los medios de Emol, utilizando un rango de fechas.

Usage

```
extraer_noticias_fecha(  
  search_query,  
  fecha_inicio,  
  fecha_fin,  
  subir_a_bd = TRUE,  
  fuentes = "todas"  
)
```

Arguments

search_query	Una frase de busqueda (obligatoria).
fecha_inicio	Fecha de inicio del rango de busqueda en formato "YYYY-MM-DD" (obligatoria).
fecha_fin	Fecha de fin del rango de busqueda en formato "YYYY-MM-DD" (obligatoria).
subir_a_bd	por defecto TRUE, FALSE para test y cosas por el estilo (opcional).
fuentes	es un string con las fuentes a extraer. Puede ser bbcl o las de emol.

Value

Un dataframe con las noticias extraidas.

Examples

```
## Not run:  
noticias <- extraer_noticias_fecha("delincuencia", "2025-04-25",  
  "2025-04-28", subir_a_bd = FALSE, fuentes="bbcl")  
  
## End(Not run)
```

extraer_noticias_fecha_bbcl

Extraccion de noticias de BioBio.cl por rango de fechas

Description

Esta funcion permite realizar una extraccion automatizada de noticias de BioBio.cl utilizando un rango de fechas.

Usage

```
extraer_noticias_fecha_bbcl(search_query, fecha_inicio, fecha_fin)
```

Arguments

search_query	Una frase de busqueda (obligatoria).
fecha_inicio	Fecha de inicio del rango de busqueda en formato "YYYY-MM-DD" (obligatoria).
fecha_fin	Fecha de fin del rango de busqueda en formato "YYYY-MM-DD" (obligatoria).

Value

Un dataframe con las noticias extraidas.

Examples

```
## Not run:
noticias <- extraer_noticias_fecha_bbcl("inteligencia artificial", "2025-01-01",
"2025-02-24")

## End(Not run)
```

extraer_noticias_fecha_emol

Extraccion de noticias de emol.com por rango de fechas

Description

Esta funcion permite realizar una extraccion automatizada de noticias de emol.com utilizando un rango de fechas.

Usage

```
extraer_noticias_fecha_emol(search_query, fecha_inicio, fecha_fin, fuente)
```

Arguments

search_query	Una frase de busqueda (obligatoria).
fecha_inicio	Fecha de inicio del rango de busqueda en formato "YYYY-MM-DD" (obligatoria).
fecha_fin	Fecha de fin del rango de busqueda en formato "YYYY-MM-DD" (obligatoria).
fuelle	Fuente de emol para iterar (obligatoria).

Value

Un dataframe con las noticias extraidas.

Examples

```
## Not run:
noticias <- extraer_noticias_fecha_emol("inteligencia artificial", "2025-01-01",
"2025-02-24", fuente="emol")

## End(Not run)
```

`extraer_noticias_max_res`*Extraccion de noticias de medios chilenos por cantidad maxima de resultados*

Description

Esta funcion permite realizar una extraccion automatizada de noticias de BioBio y fuentes de El Mercurio.

Usage

```
extraer_noticias_max_res(  
  search_query,  
  max_results = NULL,  
  subir_a_bd = TRUE,  
  fuentes = "todas"  
)
```

Arguments

<code>search_query</code>	Una frase de busqueda (obligatoria).
<code>max_results</code>	Numero maximo de resultados a extraer (opcional, por defecto todos).
<code>subir_a_bd</code>	por defecto TRUE, FALSE para test y cosas por el estilo (opcional).
<code>fuentes</code>	por defecto marca todas las fuentes, pero se puede elegir una o varias de las disponibles en el README. (opcional)

Details

Es importante mencionar que si tiene mas de una fuente seleccionada, la cantidad maxima de resultados se aplicara para cada una de las fuentes, es decir, si pones `max_results = 10` y tienes `fuentes = "emol,guiteca,bbcl"` tendras como maximo 30 resultados.

Value

Un dataframe con las noticias extraidas.

Examples

```
## Not run:  
noticias <- extraer_noticias_max_res("inteligencia artificial",  
  max_results = 20, fuentes="bbcl, emol", subir_a_bd = FALSE)  
  
## End(Not run)
```

`extraer_noticias_max_res_bbcl`*Extraccion de noticias de BioBio.cl por cantidad maxima de resultados*

Description

Esta funcion permite realizar una extraccion automatizada de noticias de BioBio.cl entregando como parametro una cantidad maxima de resultados.

Usage

```
extraer_noticias_max_res_bbcl(search_query, max_results = NULL)
```

Arguments

`search_query` Una frase de busqueda (obligatoria).
`max_results` Cantidad maxima de resultados (opcional).

Value

Un dataframe con las noticias extraidas.

Examples

```
## Not run:  
noticias <- extraer_noticias_fecha_bbcl("inteligencia artificial", "2025-01-01",  
"2025-02-24")  
  
## End(Not run)
```

`extraer_noticias_max_res_emol`*Extraccion de noticias de Emol.com*

Description

Esta funcion permite extraer noticias de las fuentes de Emol, tanto de las noticias no pagas de emol, como de guioteca y los medios regionales de El Mercurio

Usage

```
extraer_noticias_max_res_emol(search_query, max_results = NULL, fuente)
```

Arguments

search_query	Una frase de busqueda (obligatoria).
max_results	Numero maximo de resultados a extraer (opcional, por defecto todos).
fuelle	Fuente de emol para iterar (obligatoria).

Value

Un dataframe con las noticias extraidas.

Examples

```
## Not run:
noticias <- extraer_noticias_max_res_emol("inteligencia artificial", "2025-01-01",
"2025-02-24", fuente="mediosregionales")

## End(Not run)
```

grafico_notas_por_mes *Grafico de notas por mes*

Description

Esta funcion genera un grafico de linea que muestra la cantidad de publicaciones agrupadas por mes.

Usage

```
grafico_notas_por_mes(datos, titulo, fecha_inicio = NULL, fecha_fin = NULL)
```

Arguments

datos	Data frame con los datos procesados, que debe incluir la columna 'fecha' en formato YYYY-MM-DD.
titulo	Texto que aparecera en el titulo del grafico.
fecha_inicio	Fecha de inicio para la construccion del grafico en formato YYYY-MM-DD (opcional).
fecha_fin	Fecha de finalizacion para la construccion del grafico en formato YYYY-MM-DD (opcional).

Value

Un grafico ggplot2 que muestra la cantidad de publicaciones por mes.

Examples

```
## Not run:
datos <- extraer_noticias_fecha("cambio climatico", "2024-01-01", "2025-01-01", subir_a_bd = FALSE)
grafico_notas_por_mes(datos, titulo = "Cambio Climatico",
fecha_inicio = "2024-01-01", fecha_fin = "2024-06-06")

## End(Not run)
```

init_req_bbcl	<i>Inicializa una solicitud a BioBio.cl y retorna el primer caso de busqueda</i>
---------------	--

Description

Esta funcion permite realizar una consulta inicial a BioBio.cl utilizando una frase de busqueda.

Usage

```
init_req_bbcl(search_query)
```

Arguments

search_query Una frase de busqueda (obligatoria).

Value

Un dataframe con el primer caso de la busqueda.

Examples

```
## Not run:
primer_caso <- init_req_bbcl("inteligencia artificial")

## End(Not run)
```

init_req_emol	<i>Inicializa una solicitud a emol.com y retorna el primer caso de busqueda</i>
---------------	---

Description

Esta funcion permite realizar una consulta inicial a emol.com utilizando una frase de busqueda.

Usage

```
init_req_emol(search_query, fuentes = "emol-todas")
```

Arguments

search_query Una frase de búsqueda (obligatoria).
 fuentes Un string donde se ponen las fuentes de emol a consultar

Value

Un dataframe con el primer caso de la búsqueda.

Examples

```
## Not run:
primer_caso <- init_req_emol("Boric", fuentes="emol")

## End(Not run)
```

iteracion_emol	<i>Inicializa una solicitud a emol.com y retorna maximo 10 noticias</i>
----------------	---

Description

Esta funcion auxiliar llama a emol.com utilizando una frase de búsqueda. Entrega como maximo 10 resultados. Se debe llamar desde otras funciones solo con una fuente a la vez, es decir, sin llamar a emol-todas.

Usage

```
iteracion_emol(search_query, page = 0, fuentes = "emol-todas")
```

Arguments

search_query Una frase de búsqueda (obligatoria).
 page La pagina de búsqueda para iterar, es un int
 fuentes Es un string que deberia tener solo fuentes de emol posibles separadas por comas.

Value

Un dataframe con el caso de la búsqueda, incluyendo solo columnas especificas.

Examples

```
## Not run:
primer_caso <- iteracion_emol("Boric", fuentes="emol-todas")

## End(Not run)
```

limpieza_notas	<i>Funcion para limpiar notas de contenido HTML</i>
----------------	---

Description

Esta funcion permite limpiar por completo las notas eliminando codigos y secciones irrelevantes. Verifica que el input sea un data frame con una columna llamada 'contenido'.

Usage

```
limpieza_notas(datos, sinonimos = c())
```

Arguments

datos	Data frame donde estan almacenadas las notas
sinonimos	Un vector de character

Value

Un dataframe con el contenido limpio en la columna contenido_limpio

Examples

```
datos <- extraer_noticias_max_res("inteligencia artificial", max_results= 150, subir_a_bd = FALSE)
datos_proc <- limpieza_notas(datos, sinonimos = c("IA", "AI"))
```

parserFuentes	<i>Parser de Fuentes</i>
---------------	--------------------------

Description

Esta funcion toma un string que contiene nombres de fuentes separados por comas y devuelve una lista con cada fuente como un elemento separado, sin espacios en blanco adicionales.

Usage

```
parserFuentes(cadena)
```

Arguments

cadena	Un string que contiene nombres de fuentes separados por comas.
--------	--

Value

Una lista de strings, cada uno representando una fuente sin espacios en blanco adicionales.

Examples

```
parserFuentes("bbcl, emol, mediosregionales, ")
parserFuentes(" emol-todas, bbcl")
```

tabla_frecuencia_palabras

Generar una tabla estilizada con las palabras mas frecuentes

Description

Esta funcion procesa la columna 'contenido_limpio' de un dataframe, tokeniza el texto, cuenta la frecuencia de cada palabra y genera una tabla con las palabras mas frecuentes.

Usage

```
tabla_frecuencia_palabras(datos, max_words, stop_words = NULL)
```

Arguments

datos	Data frame que contiene la columna 'contenido_limpio'.
max_words	Numero maximo de palabras que se mostraran en la tabla.
stop_words	Vector opcional de palabras que se deben excluir del conteo.

Value

Una tabla con las palabras mas frecuentes.

Examples

```
datos <- data.frame(
  contenido_limpio = c(
    "La ministra de Defensa Maya Fernandez enfrenta cuestionamientos
    el presidente Gabriel Boric solicita transparencia en los procesos.
    Renovacion Nacional pide la renuncia de Maya Fernandez debido a la polemica.
    La transparencia es fundamental en la politica y la gestion publica"
  ),
  stringsAsFactors = FALSE
)

# Probar la funcion con el dataframe de ejemplo
tabla_frecuencia_palabras(datos, max_words = 5, stop_words = c())
```

word_cloud	<i>Funcion de nube de palabras</i>
------------	------------------------------------

Description

Esta funcion permite realizar una nube de palabras con las palabras más frecuentes del corpus de noticias.

Usage

```
word_cloud(datos, max_words, stop_words = NULL)
```

Arguments

datos	data frame que incluye la columna contenido_limpio.
max_words	Cantidad maxima de palabras que apareceran en la nube.
stop_words	Definir las palabras que seran ignoradas en la visualizacion. Debe ser un vector de caracteres.

Value

Una nube de palabras con las palabras mas frecuentes.

Examples

```
## Not run:
datos <- extraer_noticias_fecha("Boric",
"2025-03-01",
"2025-04-01",
fuentes="bbc1",
subir_a_bd = FALSE)
datos_proc <- limpieza_notas(datos)
word_cloud(datos_proc, max_words = 50, stop_words = c("es", "la"))

## End(Not run)
```

Index

agregar_datos_unicos, [2](#)

extraccion_parrafos, [3](#)

extraer_noticias_fecha, [3](#)

extraer_noticias_fecha_bbcl, [4](#)

extraer_noticias_fecha_emol, [5](#)

extraer_noticias_max_res, [6](#)

extraer_noticias_max_res_bbcl, [7](#)

extraer_noticias_max_res_emol, [7](#)

grafico_notas_por_mes, [8](#)

init_req_bbcl, [9](#)

init_req_emol, [9](#)

iteracion_emol, [10](#)

limpieza_notas, [11](#)

parserFuentes, [11](#)

tabla_frecuencia_palabras, [12](#)

word_cloud, [13](#)