

A Data Validation Infrastructure for R



Daniel Franke

Introducing A Data Validation Infrastructure
For R: The {validate} Package

Data Validation

	SEX	AGE	LANG_INTERVIEW		POB	PARTY	LEFT_RIGHT_0_10	CHILDREN
1	Dona	41	Castellà		Catalunya	PSC	Extrema esquerra	2
2	Home	59	Castellà	Altres comunitats	autònomes	Podemos	5	2
3	Dona	18	Català		Catalunya	Podemos	2	Cap
4	Dona	23	Castellà		Catalunya	Cap	5	Cap
5	Dona	74	Català		Catalunya	Cap	5	2
6	Dona	89	Castellà	Altres comunitats	autònomes	PSC	2	8

Data Validation

	SEX	AGE	LANG_INTERVIEW		POB	PARTY	LEFT_RIGHT_0_10	CHILDREN
1	Dona	41	Castellà		Catalunya	PSC	Extrema esquerra	2
2	Home	59	Castellà	Altres comunitats autònomes		Podemos	5	2
3	Dona	18	Català		Catalunya	Podemos	2	Cap
4	Dona	23	Castellà		Catalunya	Cap	5	Cap
5	Dona	74	Català		Catalunya	Cap	5	2
6	Dona	89	Castellà	Altres comunitats autònomes		PSC	2	8

- Technical checks: **Age vs. Children**
- Checks on subject: **Party vs Ideology**
- Metadata: **Interview Language**

Data Validation

SEX	AGE	LA	SEX	AGE	LANG_INTERVIEW	POB	PARTY	LEFT_RIGHT_0_10	CHILDREN	ILDREN
			1	Dona	41	Castellà Catalunya	PSC	Extrema esquerra	2	
			2	Home	59	Castellà Altres comunitats autònomes	Podemos		5	2
1	Dona	41	3	Dona	18	Català Catalunya	Podemos		2	Cap 2
			4	Dona	23	Castellà Catalunya	Cap		5	Cap 2
2	Home	59	5	Dona	74	Català Catalunya	Cap		5	2
			6	Dona	89	Castellà Altres comunitats autònomes	PSC		2	8
3	Dona	18	7	Dona	30	Castellà Catalunya	Cap		2	Cap 8
			8	Dona	53	Castellà Resta del món	Cap		4	3
4	Dona	23	9	Home	25	Castellà Catalunya	Cap		5	Cap 2
			10	Home	67	Català Catalunya	Junts per Catalunya		3	2
5	Dona	74	11	Home	51	Català Catalunya	ERC		2	3
			12	Home	30	Castellà Catalunya	PSC	No ho sap		Cap 8
6	Dona	89	13	Dona	38	Castellà Resta del món	Cap		6	4
			14	Dona	35	Castellà Catalunya	Cap		7	1
			15	Dona	26	Català Catalunya	Barcelona en Comú		4	Cap
			16	Dona	68	Català Catalunya	Junts per Catalunya		5	1
			17	Dona	28	Castellà Resta del món	PSC		5	1
			18	Dona	40	Català Catalunya	ERC		3	1
			19	Home	39	Castellà Catalunya	C's		6	2
			20	Dona	69	Castellà Altres comunitats autònomes	PSC		5	4
			21	Dona	40	Català Catalunya	ERC		3	2
			22	Home	82	Castellà Altres comunitats autònomes	Cap		5	4
			23	Home	40	Castellà Resta del món	PSC		8	Cap
			24	Home	44	Castellà Catalunya	ERC		2	2
			25	Dona	20	Castellà Catalunya	Cap	No ho sap		Cap
			26	Dona	62	Castellà Altres comunitats autònomes	Podemos		4	2
			27	Dona	71	Castellà Altres comunitats autònomes	PSC		5	2
			28	Home	27	Castellà Catalunya	Cap		5	1
			29	Dona	52	Castellà Catalunya	PPC		5	Cap
			30	Dona	55	Castellà Resta del món	Cap		5	2
			31	Dona	74	Castellà Altres comunitats autònomes	PSC	Extrema esquerra		3
			32	Home	73	Català Catalunya	PSC		5	1
			33	Home	29	Català Altres comunitats autònomes	Podemos		2	Cap
			34	Home	26	Català Catalunya	CUP		5	Cap
			35	Home	73	Català Catalunya	Cap		4	3
			36	Home	38	Català Catalunya	ERC		2	3
			37	Home	64	Català Catalunya en Comú Podem			3	2

Definition

- Data Validation:
 - „Checking if a combination of values is member of a set of acceptable value combinations“

European Statistical System

Definition

- Data Validation:
 - „Checking if a combination of values is member of a set of acceptable value combinations“


European Statistical System



`%in%`



`%in%`



???




Definition

- Data Validation:
 - „Checking if a combination of values is member of a set of acceptable value combinations“

European Statistical System

- Data validation function returns a boolean vector




TRUE

FALSE

The {validate} Package

- Domain Specific Language



`validator()`

- free text
- yaml
- data frame
- ...

`confront()`

`summary()`

`values()`

`plot results`

Centre d'Estudis d'Opinió (CEO)
Baròmetre d'Opinió Política. 2a onada 2020
Survey Duration: 25-30 minutes
n=2000
Total population 18+ years resident in Catalonia

LET'S CODE

Links

- Centre d'Estudis d'Opinió (CEO). *Baròmetre d'Opinió Política: 2a onada 2020*.

<http://ceo.gencat.cat/ca/barometre/detall/index.html?id=7688>

- van der Loo, Mark & de Jonge, Edwin (2019). Data Validation Infrastructure for R. *Journal of Statistical Software*.

<https://CRAN.R-project.org/package=validate>

-  Daniel Franke

<https://www.linkedin.com/in/daniel-f-12a750164/>