ver.3.14.

Métodos de geografía lingüística con estadística multivariante

Análisis de asociación

Hiroto Ueda, Universidad de Tokio

14 de marzo, Universidad de Barcelona

Análisis de asociación

"Comprados juntos habitualmente:"

Libro A => Libro B

Libro A, B => Libro C

1. Análisis descriptivo:

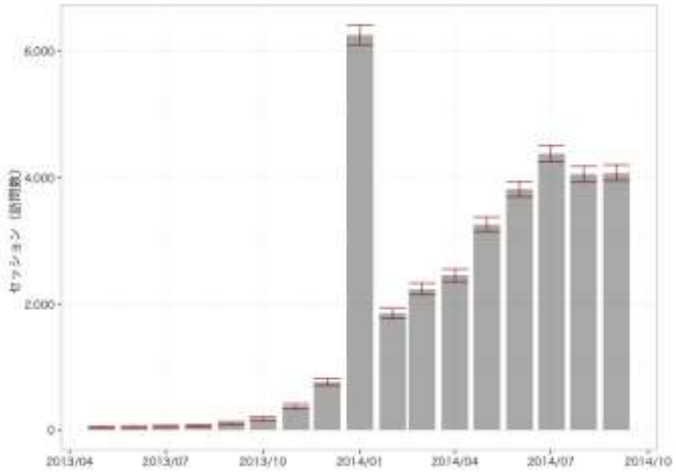

2. Causa y efecto:

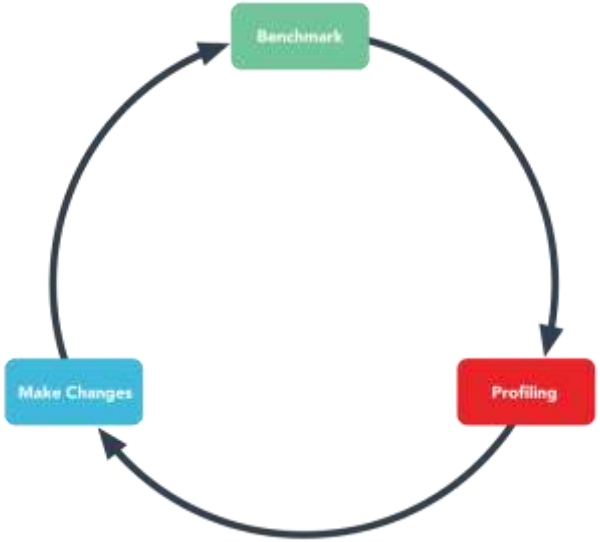

Tres cifras propuestas:

1. «Support» (Soporte)

Dat	A	B	C	D
d1	1	1	0	0
d2	0	0	1	0
d3	0	1	0	0
d4	0	0	1	1
d5	1	1	1	0

Soporte(A, B) = 2 / 5 = .400

«Soporte»(A, B) = «Soporte»(B, A)

Rango: [0, 1]

2. «Confidence» (Confianza)

probabilidad condicionada de A => B.

Dat	A	B	C	D
d1	1	1	0	0
d2	0	0	1	0
d3	0	1	0	0
d4	0	0	1	1
d5	1	1	1	0

Confianza(A, B) = 2 / 2 = 1.000

Confianza(B, A) = 2 / 3 = 0.667

Rango: [0, 1]

3. «Lift» (Elevación).

«Confianza»(A, B) con respecto a la probabilidad de B:

Dat	A	B	C	D
d1	1	1	0	0
d2	0	0	1	0
d3	0	1	0	0
d4	0	0	1	1
d5	1	1	1	0

Elevación(A, B)

= Confianza(A, B) / Probabilida(B)

= (2 / 2) / (3 / 5) = 1 / 0.6 = 1.667

«Elevación»(A, B) ≠ «Elevación»(B, A)

Rango: [0, ~]

Nuestra propuesta:

Síntesis = (Soporte * Confianza * Elevación)^(1/3)

Máximo: c/N * 1 * 1/(c/N) = 1 (!)

Rango = [0, 1]

(donde c: coocurrencias, N: número de datos)

(1) Análisis de asociación simple

Dat	A	B	C	D
d1	1	1	0	0
d2	0	0	1	0
d3	0	1	0	0
d4	0	0	1	1
d5	1	1	1	0

#	L	R	LHS	=>	RHS	L.f.	R.f.	L.p.	R.p.	Cooc.	Sup.	Cnf.	Lift	Synt.
1	1	2	A	=>	B	2	3	.400	.600	2	.400	1.000	1.667	.667
2	2	1	B	=>	A	3	2	.600	.400	2	.400	.667	1.667	.444
3	4	3	D	=>	C	1	3	.200	.600	1	.200	1.000	1.667	.333

4	3	4	C	=>	D	3	1	.600	.200	1	.200	.333	1.667	.111
5	1	3	A	=>	C	2	3	.400	.600	1	.200	.500	.833	.083
6	3	1	C	=>	A	3	2	.600	.400	1	.200	.333	.833	.056
7	2	3	B	=>	C	3	3	.600	.600	1	.200	.333	.556	.037
8	3	2	C	=>	B	3	3	.600	.600	1	.200	.333	.556	.037
9	1	4	A	=>	D	2	1	.400	.200	0	.000	.000	.000	.000
10	2	4	B	=>	D	3	1	.600	.200	0	.000	.000	.000	.000
11	4	1	D	=>	A	1	2	.200	.400	0	.000	.000	.000	.000
12	4	2	D	=>	B	1	3	.200	.600	0	.000	.000	.000	.000

(2) Análisis de asociación doble

Dat	A	B	C	D
d1	1	1	0	0
d2	0	0	1	0
d3	0	1	0	0
d4	0	0	1	1
d5	1	1	1	0

#	L.	R.	LHS	=>	RHS	L.f.	R.f.	L.p.	R.p.	Cooc.	Sup.	Cnf.	Lift	Synt.
1	2:3	1	B:C	=>	A	1	2	.200	.400	1	.200	1.000	2.500	.794

2	1:3	2	A:C	=>	B	1	3	.200	.600	1	.200	1.000	1.667	.693
3	1:2	3	A:B	=>	C	2	3	.400	.600	1	.200	.500	.833	.437
4	1:4	3	A:D	=>	C	0	3	.000	.600	0	.000	.000	.000	.000
5	1:2	4	A:B	=>	D	2	1	.400	.200	0	.000	.000	.000	.000

(3) Análisis de asociación triple

…

(4) Análisis de asociación cuaduple

…

... (?)

Addenda: Análisis de componentes principales

- Álgebra linear
- Matrices
- Producto
- Matriz inversa
- Valores eigen (valores propios),

etc.

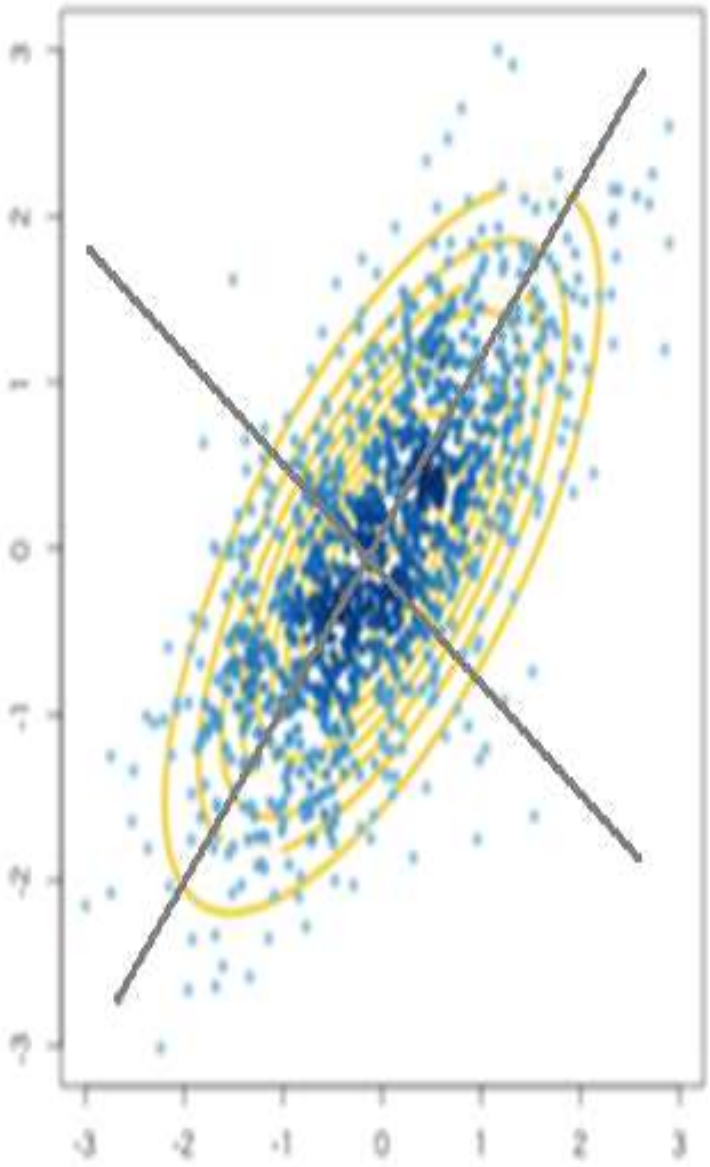
3
2
1
0
-1
-2
-3
-3
-2
-1
0
1
2
3

[1] $Z_n = X_{np}\, W_p$

Varianza (V) del vector compuesto:

[2] $V = (Z_n^T\, Z_n) / N$

$= (X_{np}\, W_p)^T\, (X_{np}\, W_p) / N$ ←[1]

$= W_p^T\, X_{np}^T\, X_{np}\, W_p / N$ ←$(A\, B)^T = B^T\, A$

$= W_p^T\, (X_{np}^T\, X_{np} / N)\, W_p$ ←N es escalar, movible

$= W_p^T\, R_{pp}\, W_p$ ← $R_{pp} = X_{np}^T\, X_{np} / N$

(…)

E.mat.	#1	#2	#3	#4
A	.449	.707	.317	-.445
B	.599	-.000	.230	.767
C	-.449	.707	-.317	.445
D	-.489	.000	.864	.122

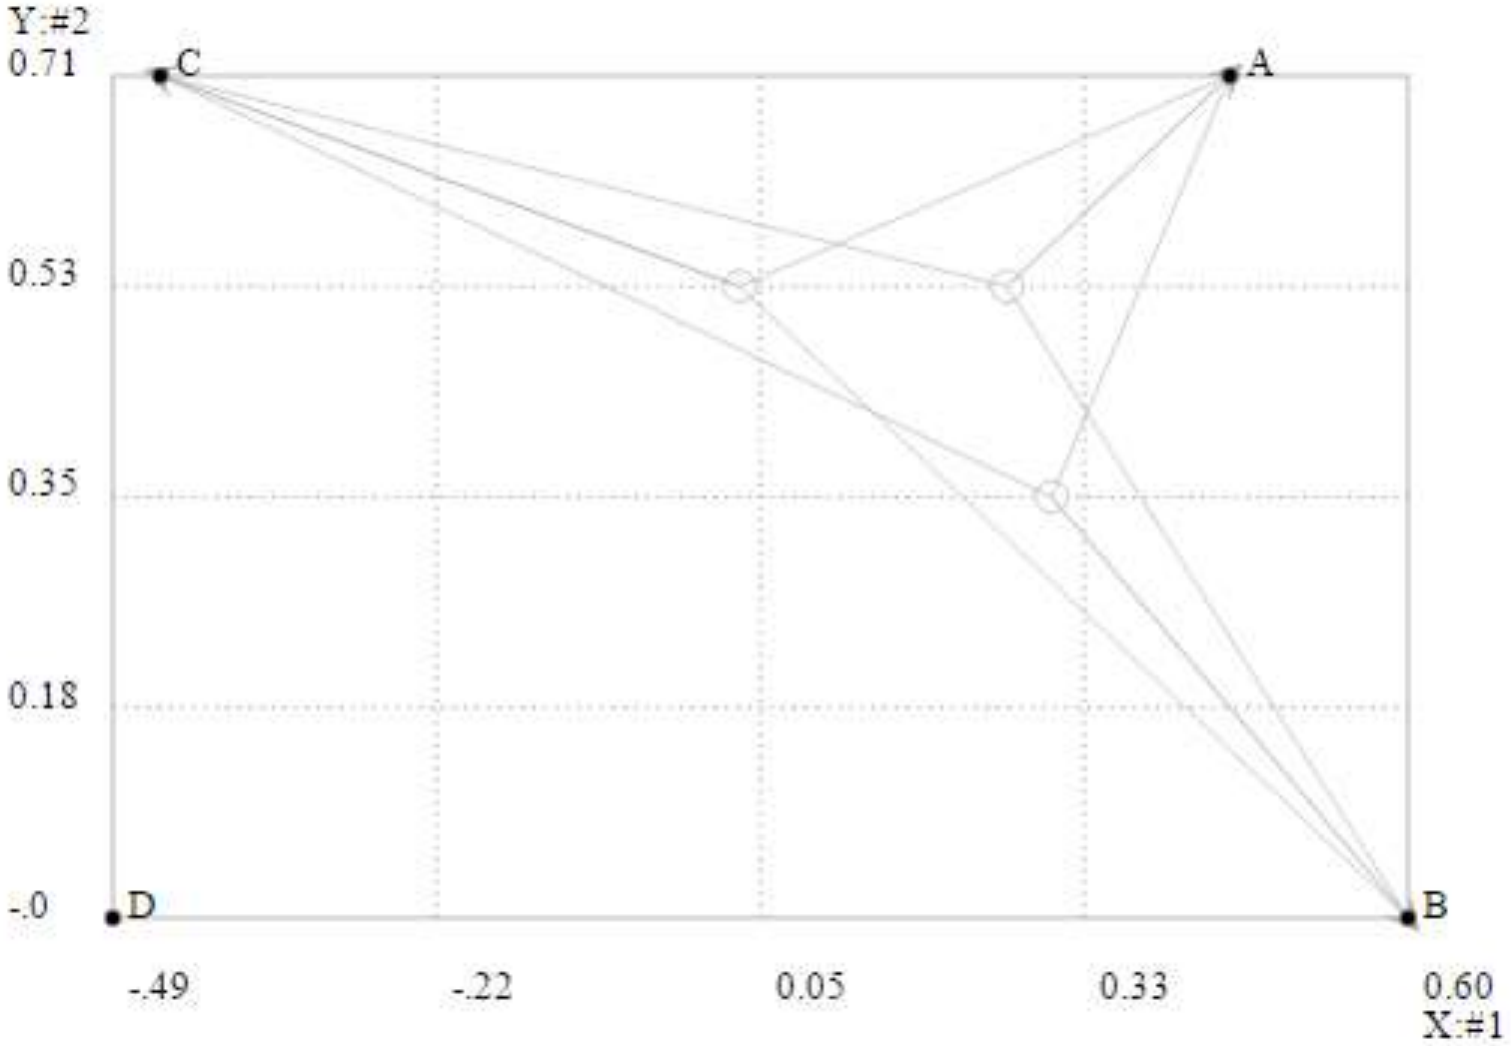
Y:#2
0.71
0.53
0.35
0.18
-.0
C
A
D
B
-.49
-.22
0.05
0.33
0.60
X:#1

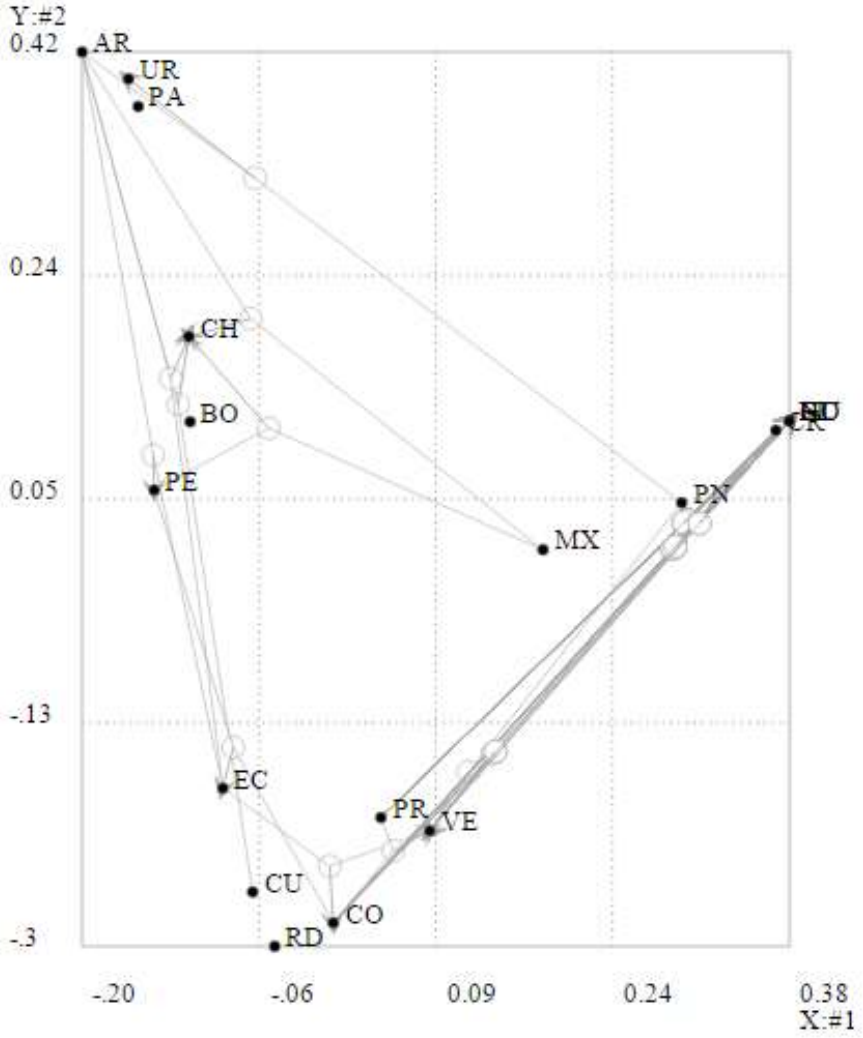
Y:#2
0.42
0.24
0.05
-.13
-.3
AR
UR
PA
CH
BO
PE
EC
CU
RD
CO
PR
VE
MX
PN
-.20
-.06
0.09
0.24
0.38
X:#1

(a) Input:

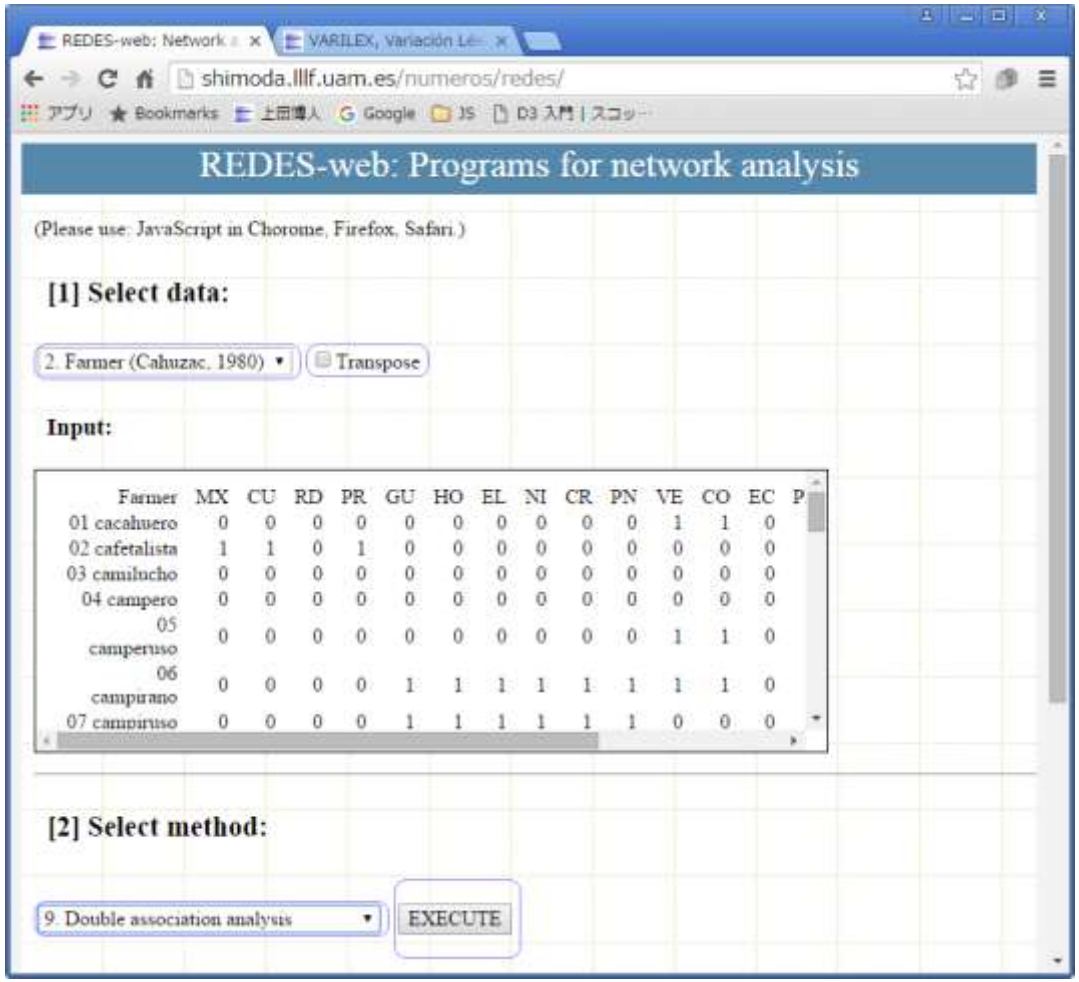
REDES-web: Network
VARILEX, Variación Le
shimoda.lllf.uam.es/numeros/redes/
REDES-web: Programs for network analysis
(Please use: JavaScript in Chorome, Firefox, Safari.)
[1] Select data:
2. Farmer (Cahuzac, 1980)
Transpose
Input:
Farmer MX CU RD PR GU HO EL NI CR PN VE CO EC P
01 cacahuero 0 0 0 0 0 0 0 0 0 0 1 1 0
02 cafetalista 1 1 0 1 0 0 0 0 0 0 0 0 0
03 camilucho 0 0 0 0 0 0 0 0 0 0 0 0 0
04 campero 0 0 0 0 0 0 0 0 0 0 0 0 0
05 camperuso 0 0 0 0 0 0 0 0 0 0 1 1 0
06 campurano 0 0 0 0 1 1 1 1 1 1 1 1 0
07 campuruso 0 0 0 0 1 1 1 1 1 1 0 0 0
[2] Select method:
9. Double association analysis
EXECUTE

(b) Seleccionar el método

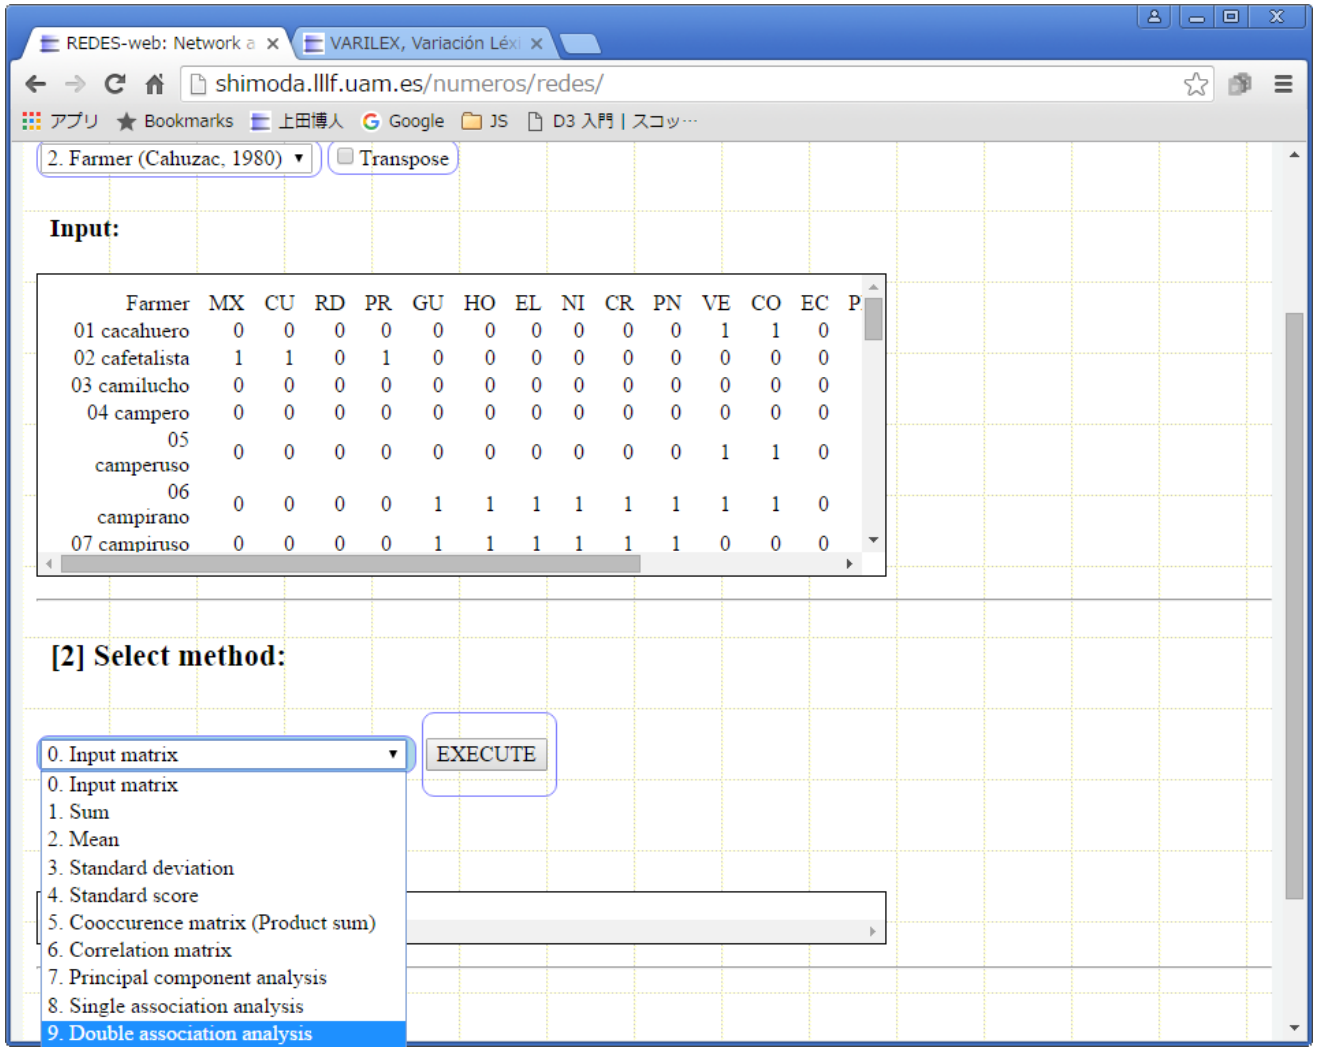

(c.1.) Output 1. Análisis de asociación

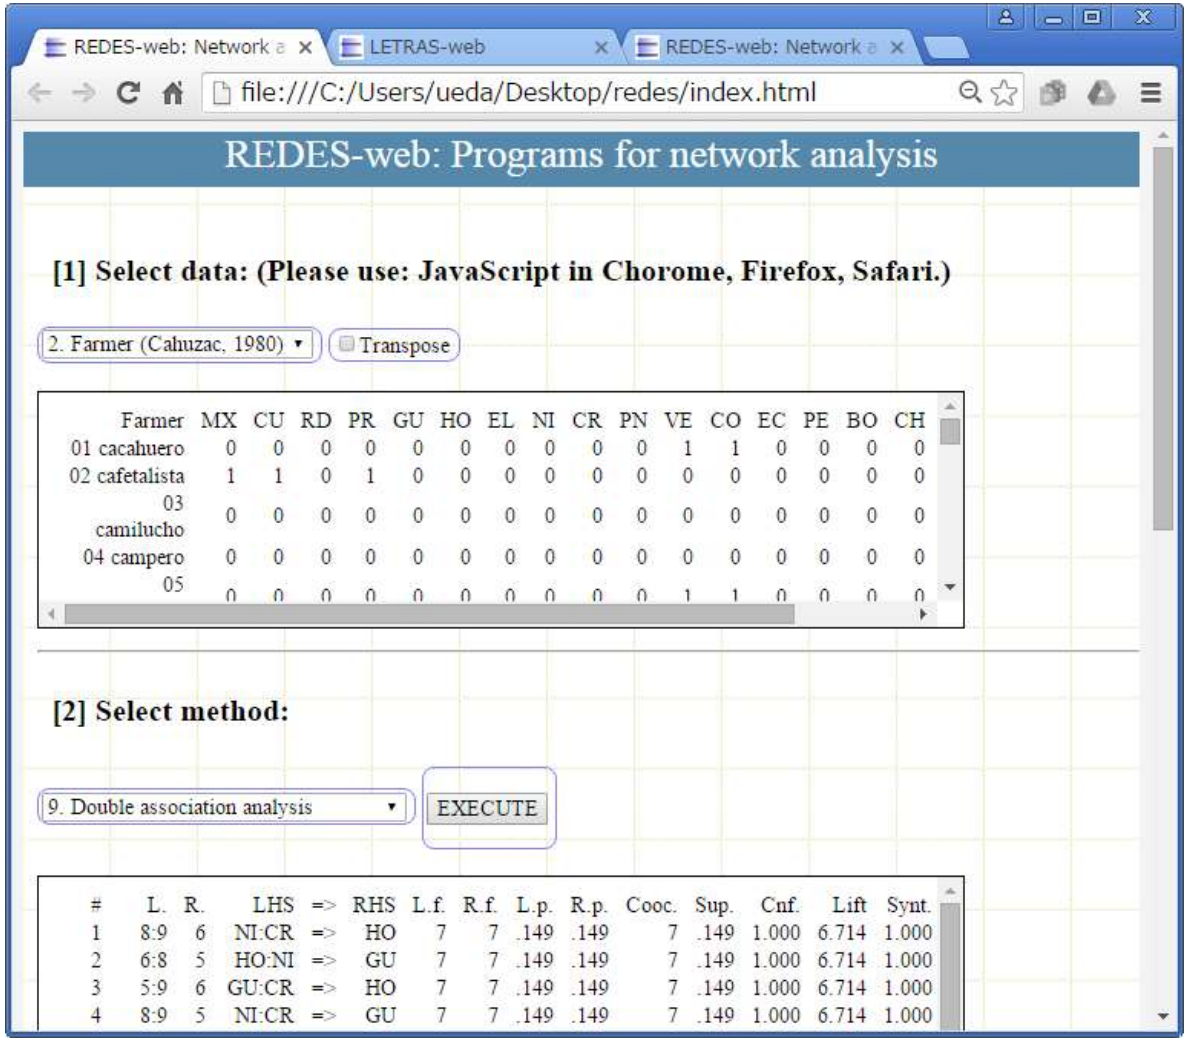

(c.2.) Output 2. Vectores eigen

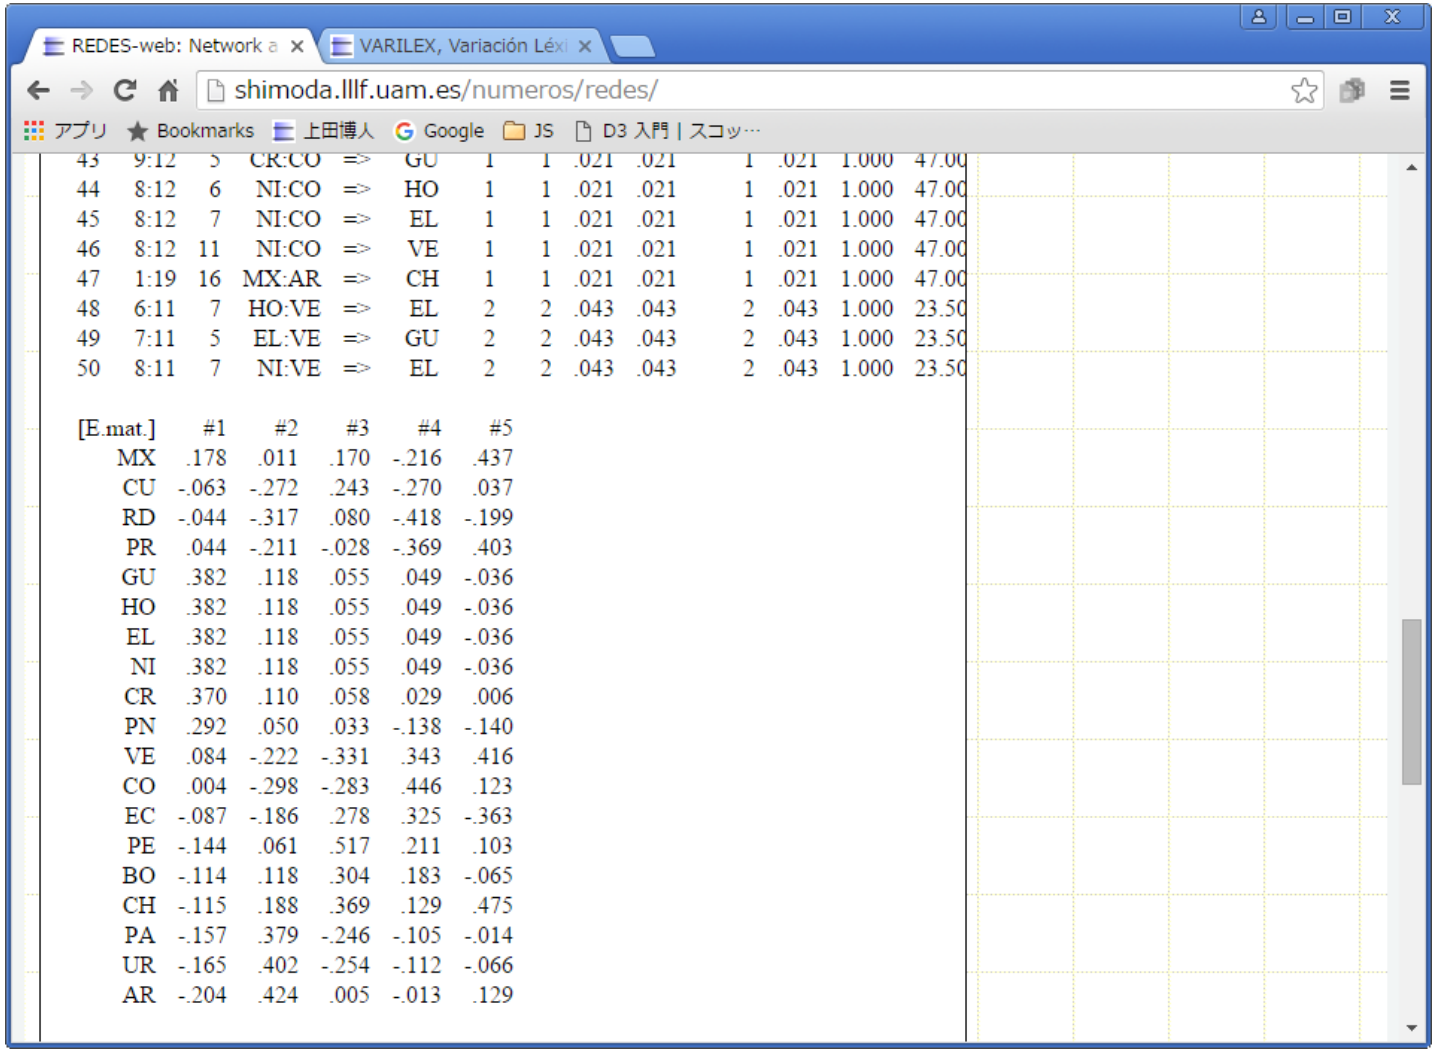

43	9:12	5	CR:CO	=>	GU	1	1	.021	.021	1	.021	1.000	47.00
44	8:12	6	NI:CO	=>	HO	1	1	.021	.021	1	.021	1.000	47.00
45	8:12	7	NI:CO	=>	EL	1	1	.021	.021	1	.021	1.000	47.00
46	8:12	11	NI:CO	=>	VE	1	1	.021	.021	1	.021	1.000	47.00
47	1:19	16	MX:AR	=>	CH	1	1	.021	.021	1	.021	1.000	47.00
48	6:11	7	HO:VE	=>	EL	2	2	.043	.043	2	.043	1.000	23.50
49	7:11	5	EL:VE	=>	GU	2	2	.043	.043	2	.043	1.000	23.50
50	8:11	7	NI:VE	=>	EL	2	2	.043	.043	2	.043	1.000	23.50

[E.mat.]	#1	#2	#3	#4	#5
MX	.178	.011	.170	-.216	.437
CU	-.063	-.272	.243	-.270	.037
RD	-.044	-.317	.080	-.418	-.199
PR	.044	-.211	-.028	-.369	.403
GU	.382	.118	.055	.049	-.036
HO	.382	.118	.055	.049	-.036
EL	.382	.118	.055	.049	-.036
NI	.382	.118	.055	.049	-.036
CR	.370	.110	.058	.029	.006
PN	.292	.050	.033	-.138	-.140
VE	.084	-.222	-.331	.343	.416
CO	.004	-.298	-.283	.446	.123
EC	-.087	-.186	.278	.325	-.363
PE	-.144	.061	.517	.211	.103
BO	-.114	.118	.304	.183	-.065
CH	-.115	.188	.369	.129	.475
PA	-.157	.379	-.246	-.105	-.014
UR	-.165	.402	-.254	-.112	-.066
AR	-.204	.424	.005	-.013	.129

(c.3.) Output 3. Redes

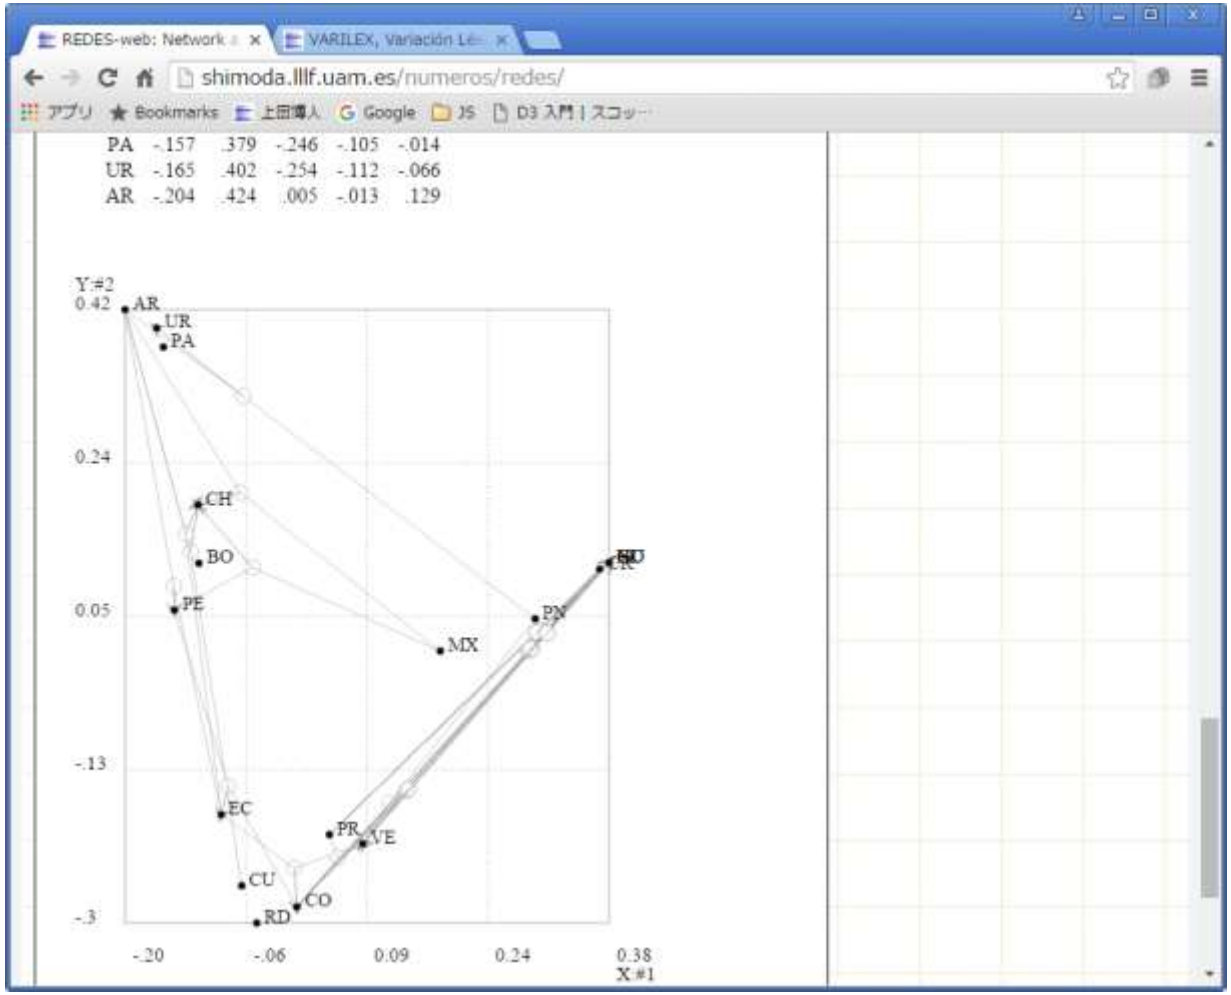

Bibliografía

Cahuzac, Philippe. (1980) "La División del español de América en zonas dialectales: Solución etnolingüística o semántico-dialectal." *Lingüística Española Actual,* 10, pp. 385-461.

Michael Hahsler, Bettina Grun, Kurt Hornik, Christian Buchta. "Introduction to arules – A computational environment for mining association rules and frequent item sets" https://lyle.smu.edúIDA/arules/ (24/2/2016)

Ueda, Hiroto. *Análisis de datos cuantitativos para estudios lingüísticos.*

http://shimoda.lllf.uam.es/numeros/redes/numeros-es.pdf

5.3.2. Análisis de componentes principales

5.4. Análisis de asociación

¡FIN!

¡¡MUCHAS GRACIAS¡

Google: Hiroto Ueda