

IXth Congress of the International Society for Dialectology and Geolinguistics
23-27 July 2018, Vilnius, Lithuania

Measures of frequency and dispersion in individual texts

**Applied to the morphology of future of Spanish verbs
observed in space and time**

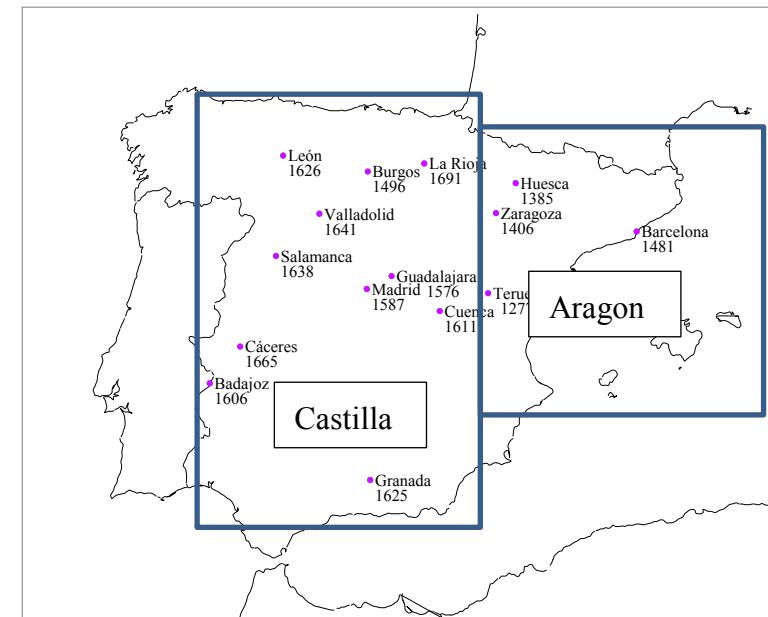
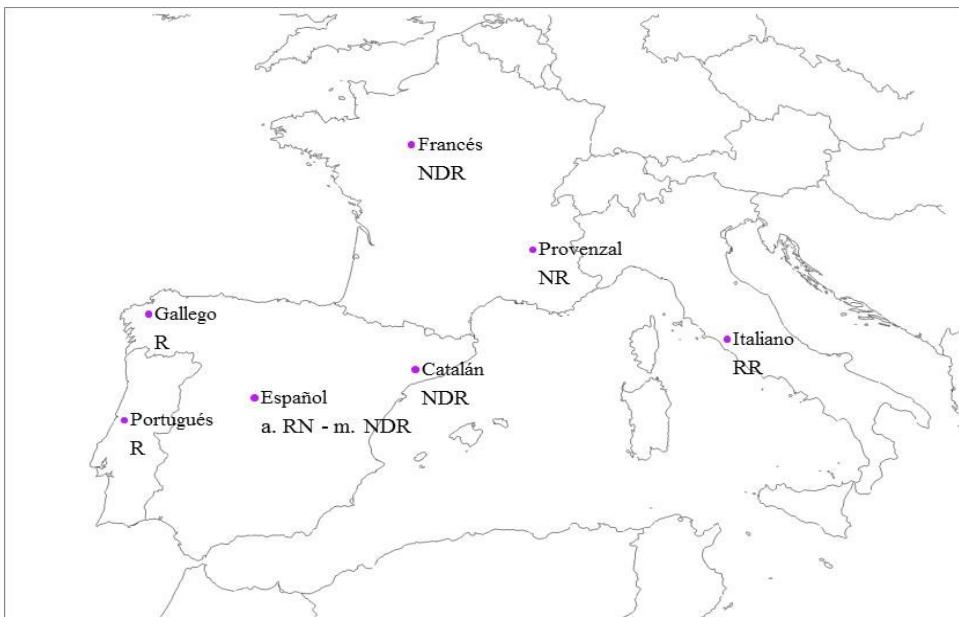
Hiroto Ueda, University of Tokyo

1. Introduction

Frequency and dispersion of linguistic forms in one text

Spanish texts of the Middle and Modern Ages

Castile and Aragon with extension to Navarra



Irregular forms of future of verbs: *poner* 'to put', *tener* 'to have' and *venir* 'to come'

Corpus: CODEA «*Corpus de documentos Españoles Anteriores a 1800*»

('Corpus of Spanish documents before 1800')

[GITHE] CODEA+ 2015 *Corpus de documentos Españoles Anteriores a 1800*

Inicio Acceso al corpus Grupo GITHE Red CHARTA

Bienvenidos a Codea+ 2015

El corpus CODEA (Corpus de Documentos Españoles Anteriores a 1800) es una herramienta imprescindible para los estudiosos de la historia de la lengua, la dialectología diacrónica y la geografía lingüística, para paleógrafos, interesados por la historia general, de la vida privada y las mentalidades, y para todos aquellos que busquen información de carácter local o de cualquier otro tipo sobre el pasado antiguo y reciente. CODEA ofrece en su estado actual 2500 documentos en español de toda la geografía peninsular del español y de diferentes registros (desde la Cancillería a las notas de manos inhábilles). Los textos se presentan en edición triple (facsimil, paleográfica y crítica). CODEA es un corpus de libre acceso, fiable y citable, con transcripciones rigurosas directamente realizadas por el equipo elaborador. Las lecturas ofrecidas se pueden comprobar en los facsímiles. CODEA permite búsquedas simples y complejas, filtradas por varios parámetros (fechas, lugares, tipologías diversas, género, etc.). Los resultados de las búsquedas pueden exportarse a lista, gráfico y mapa. CODEA+ 2015 se convierte así en un verdadero Atlas Lingüístico Diacrónico y Dinámico del Español (ALDIDI).

Triple presentación de los documentos

Algunos de los archivos

Transcripción paleográfica

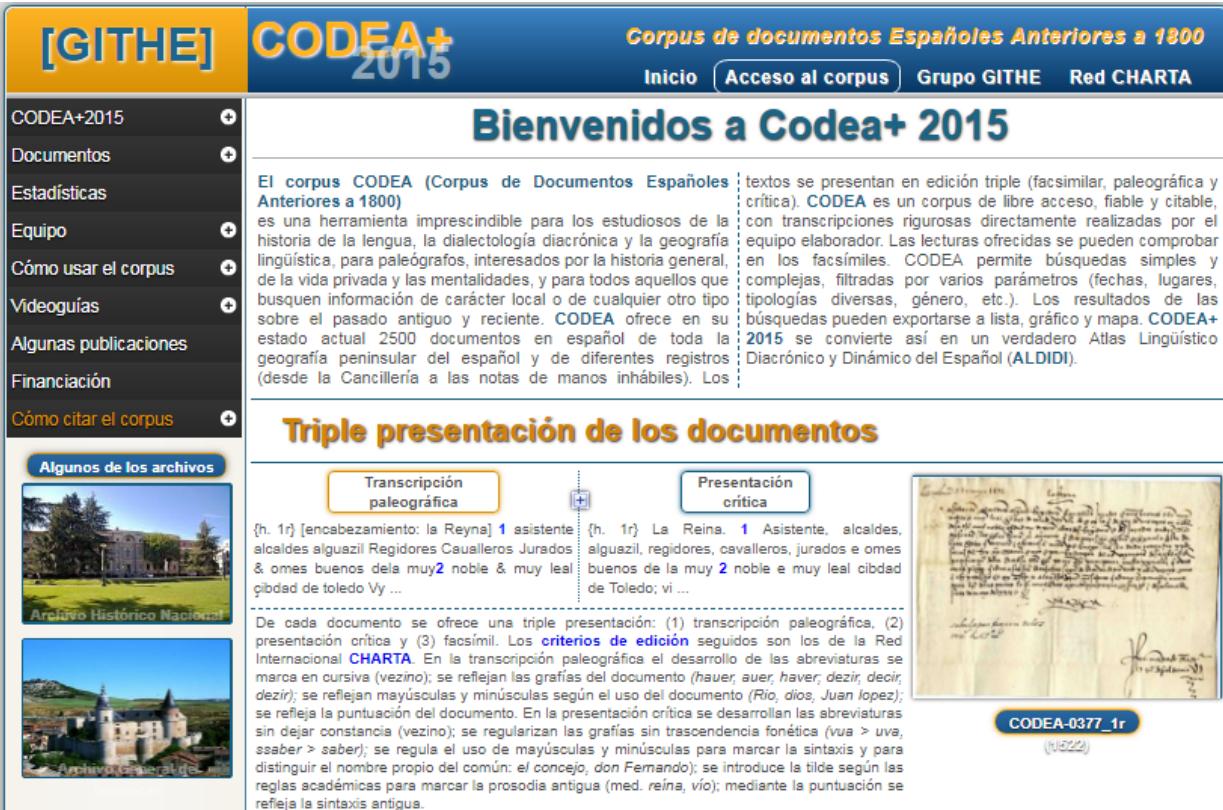
Presentación crítica

Facsimil

(h. 1r) [encabezamiento: la Reyna] 1 asistente, alcaldes, alcaldes alguazil Regidores Caballeros Jurados & omes buenos dela muy2 noble & muy leal ciudad de Toledo Vy ... (h. 1r) La Reina. 1 Asistente, alcaldes, alguazil, regidores, caballeros, jurados e omes buenos de la muy 2 noble e muy leal ciudad de Toledo; vi ...

De cada documento se ofrece una triple presentación: (1) transcripción paleográfica, (2) presentación crítica y (3) facsímil. Los criterios de edición seguidos son los de la Red Internacional CHARTA. En la transcripción paleográfica el desarrollo de las abreviaturas se marca en cursiva (vezino); se reflejan las grafías del documento (*hauer, auer, haver, dezir, decir, dezir*); se reflejan mayúsculas y minúsculas según el uso del documento (*Rio, dios, Juan lopez*); se refleja la puntuación del documento. En la presentación crítica se desarrollan las abreviaturas sin dejar constancia (vezino); se regularizan las grafías sin trascendencia fonética (*vua > uva, ssaber > saber*); se regula el uso de mayúsculas y minúsculas para marcar la sintaxis y para distinguir el nombre propio del común: *el concejo, don Fernando*; se introduce la tilde según las reglas académicas para marcar la prosodia antigua (med. *reina, vio*); mediante la puntuación se refleja la sintaxis antigua.

CODEA-0377_1r
(1522)



<http://corpuscodea.es/>

Analyzer: LYNEAL («*Letras y Números en Análisis Lingüísticos*»)

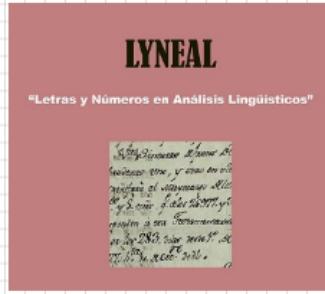
('Letters and Numbers in Linguistic Analysis').

CORPUS

- ➡ * [Biblia Medieval](#) *
- ➡ * [Bolivia](#) *
- ➡ * [CICA](#) *
- ➡ * [CODCAR-NORM](#) *
- ➡ * [CODEA](#) *
- ➡ * [CORHEN](#) *
- ➡ * [DCVB](#) *
- ➡ * [LEMI](#) *
- ➡ * [LLI-UAM](#) *
- ➡ * [PRESEEA](#) *
- ➡ * [PROGRAMES](#) *
- ➡ * [VARIGRAMA](#) *
- ➡ * [VARILEX](#) *
- ➡ * [VARILEX-R](#) *
- ➡ * [VARITEX](#) *
- ➡ * [Varios textos](#) *

- ➡ * [ILC](#) *

■ Language: Español ▾



LYNEAL
"Letras y Números en Análisis Lingüísticos"

(A small image of a medieval manuscript page is visible at the bottom left of the logo.)

EXPLICACIÓN



En el sistema LYNEAL se están reuniendo varios proyectos de corpus digitales.

Invitamos a todos los investigadores interesados para formar un grupo de corpus en esta plataforma general, sin hacer distinción de lenguas, de magnitud de materiales, de modo de estructura, etc.

Tenemos dos sitios en Madrid y Tokio para instalar los materiales reunidos y ofrecer la versión más nueva de la herramienta.

De esta manera, podemos presentar y citar nuestros datos con los que se han hecho nuestros estudios, lo que garantiza la fiabilidad y replicabilidad tanto de los datos como de los métodos.

* Hemos desarrollado y comprobado los programas de LYNEAL en el browser CHROME.

* Para reiniciar el sistema utilice el atajo [Ctrl] + [F5].

Nuestro contacto es:

Hiroto Ueda, Universidad de Tokio: uedahiroto@jicom.home.ne.jp

Antonio Moreno Sandoval, Universidad Autónoma de Madrid: antonio.msandoval@uam.es

ver. 2017-7-14

<http://shimoda.lllf.uam.es/ueda/lyneal/>

2. Frequency and dispersion

2. 1. Probabilistic frequency

Absolute Frequency (AF)

Relative Frequency (RF)

Normalized Frequency (NF)

Probabilistic Frequency (PF)

AF	1200	1300	1400	1500	1600	1700
de el	2	1	0	14	53	23
de la	89	38	89	242	420	117
del	800	732	1187	1752	1195	389
dela	402	412	680	1088	364	181
Total	1 293	1 183	1 956	3 096	2 032	710

RF (%)	1200	1300	1400	1500	1600	1700
de el	0.2	0.1	0	0.5	2.6	3.2
<i>de la</i>	6.9	3.2	4.6	7.8	20.7	16.5
<i>del</i>	61.9	61.9	60.7	56.6	58.8	54.8
<i>dela</i>	31.1	34.8	34.8	35.1	17.9	25.5

$$3 / 12 = 25 / 100 = 25 \% (?)$$

Year	1200	1300	1400	1500	1600	1700
Palabra	73 316	90 987	119 607	185 010	106 694	49 150

$$\text{NF} (\langle \text{de el} \rangle \text{ en } 1200) = 2 / 73316 * 100 000 = 2.72$$

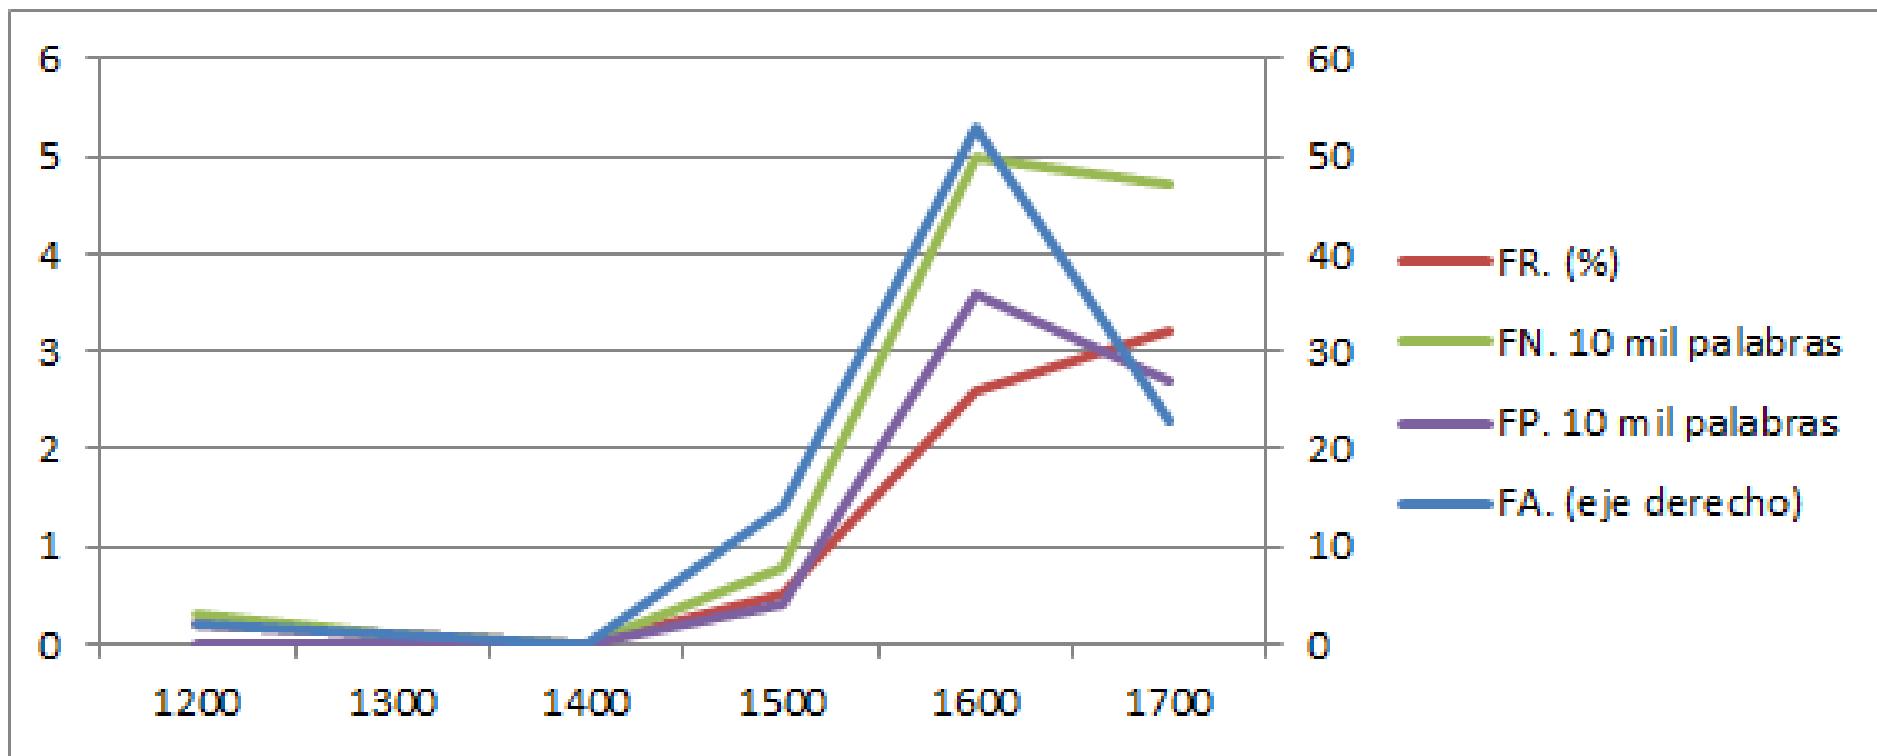
Probabilistic Frequency (PF):

Significance (s) of the x successes in n trials of an event endowed with the expectative binomial probability (e)

$$s = \text{BinS}(x, n, e) = \text{Excel.BINOMDIST}(x-1, n, e, 1)$$

$$e = \text{BinE}(x, n, s)$$

PF. 10 mil palabras	1200	1300	1400	1500	1600	1700
<i>de el</i>	0.2	0	0	3.7	35.5	27.1
<i>de la</i>	94	27.7	57.6	112.2	350.5	190.5
<i>del</i>	1004	737.3	927	895.5	1046.5	701.8
<i>dela</i>	487.1	402.8	519.2	547.6	301.1	308.2



PF (Probabilistic Frequency): Significance of 99%

RF and NF cause problems when the base of comparison, total of the column or total of words, presents great differences and above all, some members of the base are quite small figures, such as one or two digits.

2. 2. Block dispersion

Standard Deviation (SD):

$$SD = \{[(X_1 - M)^2 + (X_2 - M)^2 + \dots + (X_n - M)^2] / N\}^{1/2}$$

where M is mean, and N is the total number of data.

Coefficient of Variation (CV):

$$CV = SD / M$$

Normalized Standard Deviation (NSD):

$$NSD = SD / SD.max$$

How to find the SD.max:

$$SD = \{[(X_1 - M)^2 + (X_2 - M)^2 + \dots + (X_n - M)^2] / N\}^{1/2}$$

Eg. (10, 0, 0, 0, 0) → Maximum value of Standard Deviation (SD.max)

(K, 0, 0, ..., 0)

$$SD.\max. = \{[(K - M)^2 + (N - 1)M^2]\}^{1/2}$$

$$K = \text{Sum} = NM$$

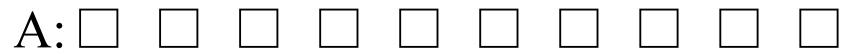
$$\begin{aligned} SD.\max. &= \{[(NM - M)^2 + M^2(N - 1)] / N\}^{1/2} \leftarrow K = NM \\ &= \{[(M(N - 1))^2 + M^2(N - 1)] / N\}^{1/2} \leftarrow M \text{ al exterior} \\ &= \{\underline{M^2(N - 1)^2} + \underline{M^2(N - 1)} / N\}^{1/2} \leftarrow M^2 \text{ es común} \\ &= \{M^2(N - 1) [(\underline{N - 1}) + 1] / N\}^{1/2} \leftarrow M^2(N - 1) \text{ es común} \end{aligned}$$

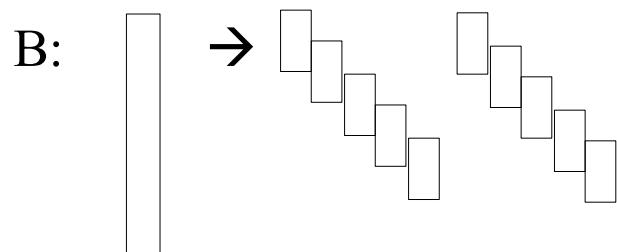
$$\begin{aligned}
 &= \{(M^2(N - 1) \frac{N}{N})^{1/2} \leftarrow (N - 1) + 1 = N \quad \leftarrow (N-1) + 1 = N \\
 &= [(M^2(N - 1))]^{1/2} \leftarrow N / N = 1 \\
 &= M(N - 1)^{1/2} \leftarrow (M^2)^{1/2} = M
 \end{aligned}$$

Normalized Standard Deviation (NSD):

$$NSD = SD / SD.max = SD / [M(N - 1)^{1/2}]$$

Block Dispersion:

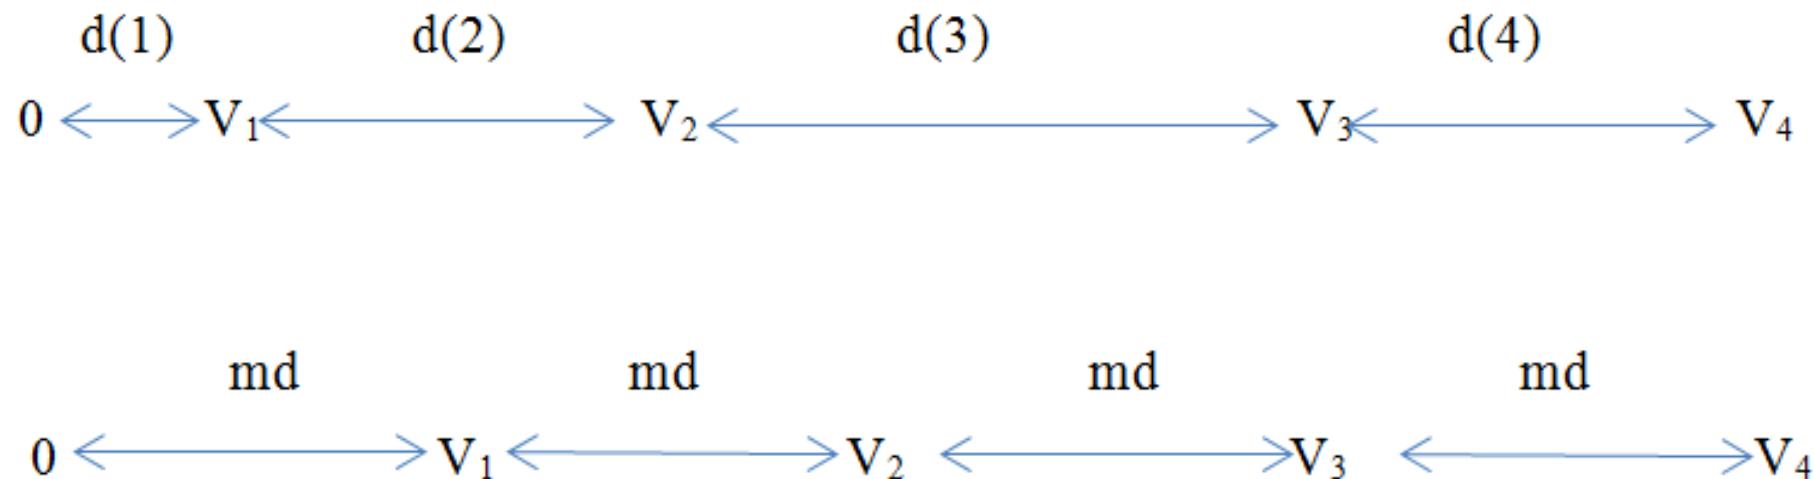
A: 

B: 

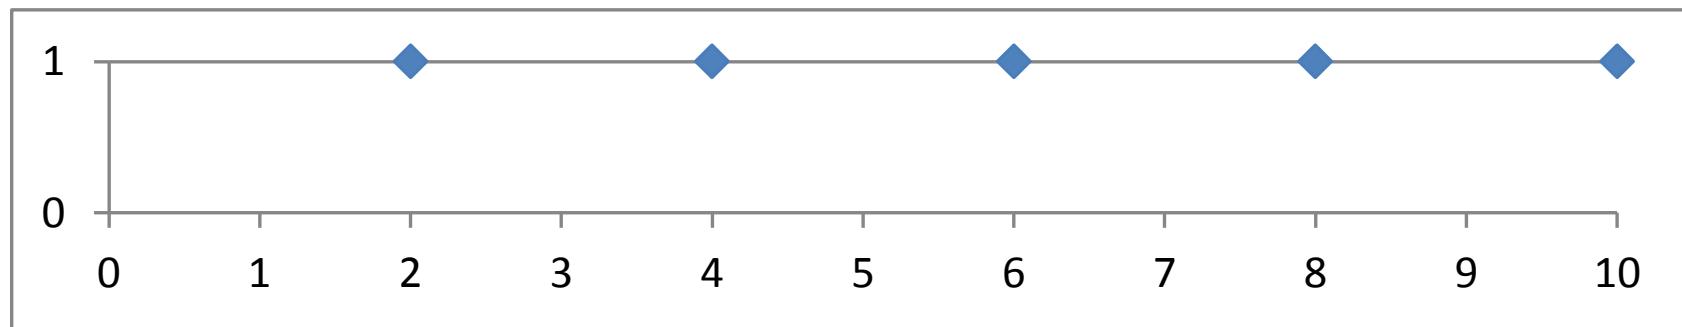
The complement of the «Standard Normalized Deviation in Blocks» (NSD.b) is Block Dispersion (Disp.b):

$$\text{Disp.b.} = 1 - \text{NSD.b}$$

2. 3. Uniformity

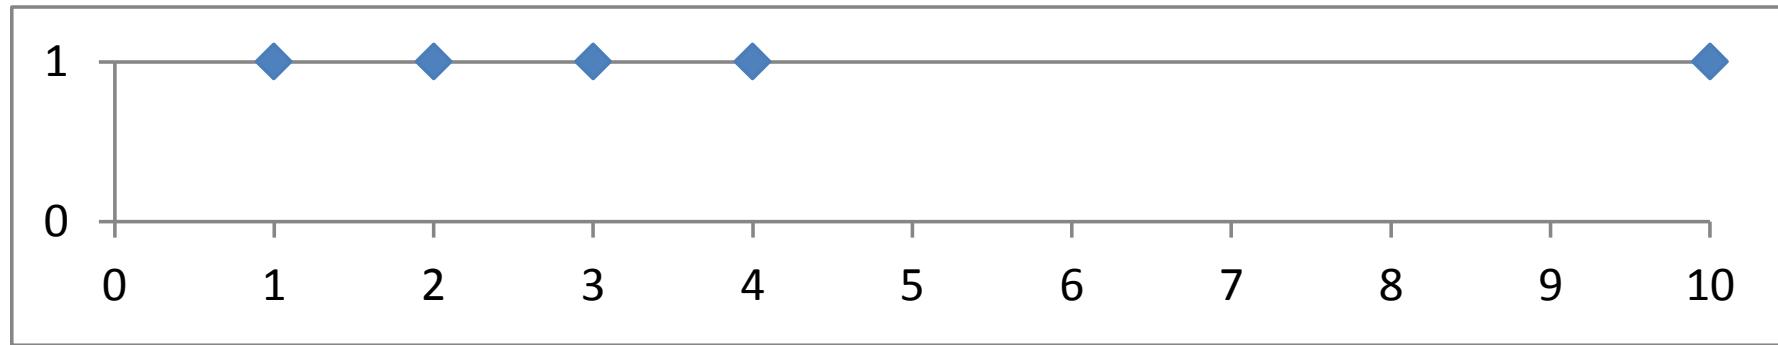


Element	Position	Distance	Mean distance	$ Dis. - M. Dis. $
x1	2	2	2	0
x2	4	2	2	0
x3	6	2	2	0
x4	8	2	2	0
x5: M	10	2	2	0

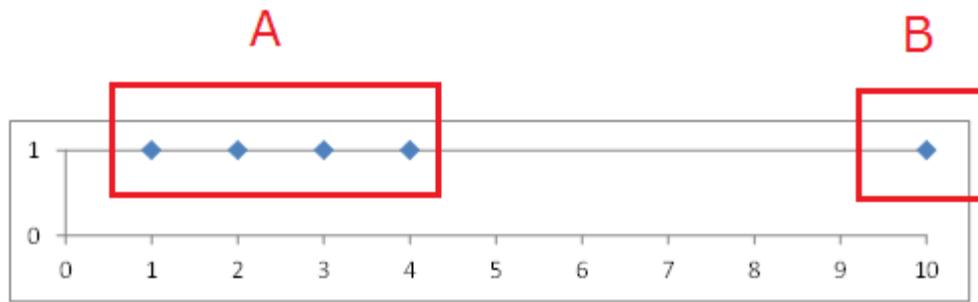


Position (2, 4, 6, 8, 10), Coagulation: 0.000, Uniformity: 1,000

Elemento	Posición	Distancia	Dist.media	Dis. - Dis.media
x1	1	1	2	1
x2	2	1	2	1
x3	3	1	2	1
x4	4	1	2	1
x5: M	10	6	2	4



Position (1, 2, 3, 4, 10), Coagulation: 1,000, Uniformity: 0.000



Maximum of the sum of the distances (S.Dist.max) in A :

$$S.Dist.max(A) = (5 - 1) * |1 - 10 / 5| = 4 * |1 - 2| = 4$$

$$\begin{aligned}
 S.Dist.max(A) &= (N - 1) * |1 - M / N| \\
 &= (N - 1) * |N - M| / N \\
 &= (N - 1) * (M - N) / N \quad \leftarrow M \geq N
 \end{aligned}$$

Maximum of the sum of the distances (S.Dist.max) in B :

$$S.Dist.max(B) = | 10 - (5 - 1) - 10/5 | = | (10 - 4) - 2 | = 4$$

$$\begin{aligned} S.Dist.max(B) &= |M - (N - 1) - M / N| \\ &= |N * (M - N + 1) - M| / N \\ &= |N * M - N * N + N - \underline{M}| / N \\ &= |N * M - \underline{M} - N * N + N| / N \\ &= |M * (N - 1) - N * (N - 1)| / N \\ &= |(N - 1) * (M - N)| / N \\ &= (N - 1) * (M - N) / N \quad \leftarrow N \geq 1, M \geq N \end{aligned}$$

Maximum of the total sum of the distances (S.Dist.max) is:

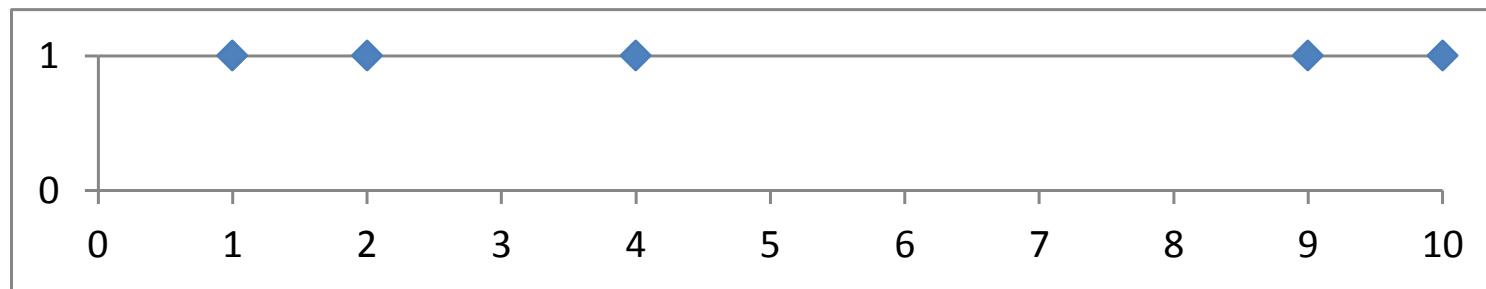
$$\begin{aligned} S.Dist.max &= S.Dist.max(A) + S.Dist.max(B) \\ &= 2 * (N - 1) * (M - N) / N = 4 * 2 = 8 \end{aligned}$$

$$\text{Coagulation} = S.Dist / S.Dist.max$$

$$\text{Uniformity} = 1 - \text{Coagulation} = 1 - S.Dist / S.Dist.max$$

Element	Position	Distance	Dist.mean	Dis. - Dis.mean
x1	1	1	2	1
x2	2	1	2	1
x3	4	2	2	0
x4	9	5	2	3
x5: M	10	1	2	1

Coagulation = $6 / 8 = .750$; Uniformity = $1 - .750 = .250$:



Position (1, 2, 4, 9, 10), Coagulation: .750, Uniformity: .250

2. 4. Stable use

Juillard and Chang Rodríguez (1964), Usage (U):

$$U = F * Disp, \quad F: \text{Frequency (F)}, \text{Disp: Dispersion}$$

$$Disp = 1 - SD / (2 * Mean)$$

$$Disp = 1 - NSD$$

Stable Usage (SU):

$$SU = F * (Disp.b * Unif)^{1/2}$$

3. Application

3. 1. Epenthetic forms

tener 'to have', *poner* 'to put', *venir* 'to come': *tenrá*, *terné*, *tendré*, *tendría*, *venr(r)án*, *vernié* etc.

Lloyd (1987: 496-7) / Penny (2006: 242):

"reinforcement" (*venr(r)án*) → NR

"metathesis" (*terné*, *vernie*) → RN

"epenthesis" (*tendrá*) → NDR

"assimilation" (*porrá*, *verrán*) → RR

Moreno Bernal (2004: 155) "Aragonese influence":

The Aragonese texts adopt the epenthetic solution for the futures of *poner*, *tener*, *venir* before the Castilians. The forms *pondré*, *tendré*, *vendré* 'I will put, I will have, I will come' that appear in Castilian texts prior to the fifteenth century are usually the product of the Aragonese influence (so *pondrán* 'they will put' and *avendremos* 'we will come' in Cid).

Marina Serrano (2018), CODEA

Aragon, Teruel (1277), Huesca (1285) and Zaragoza (1406).
Barcelona (1481)

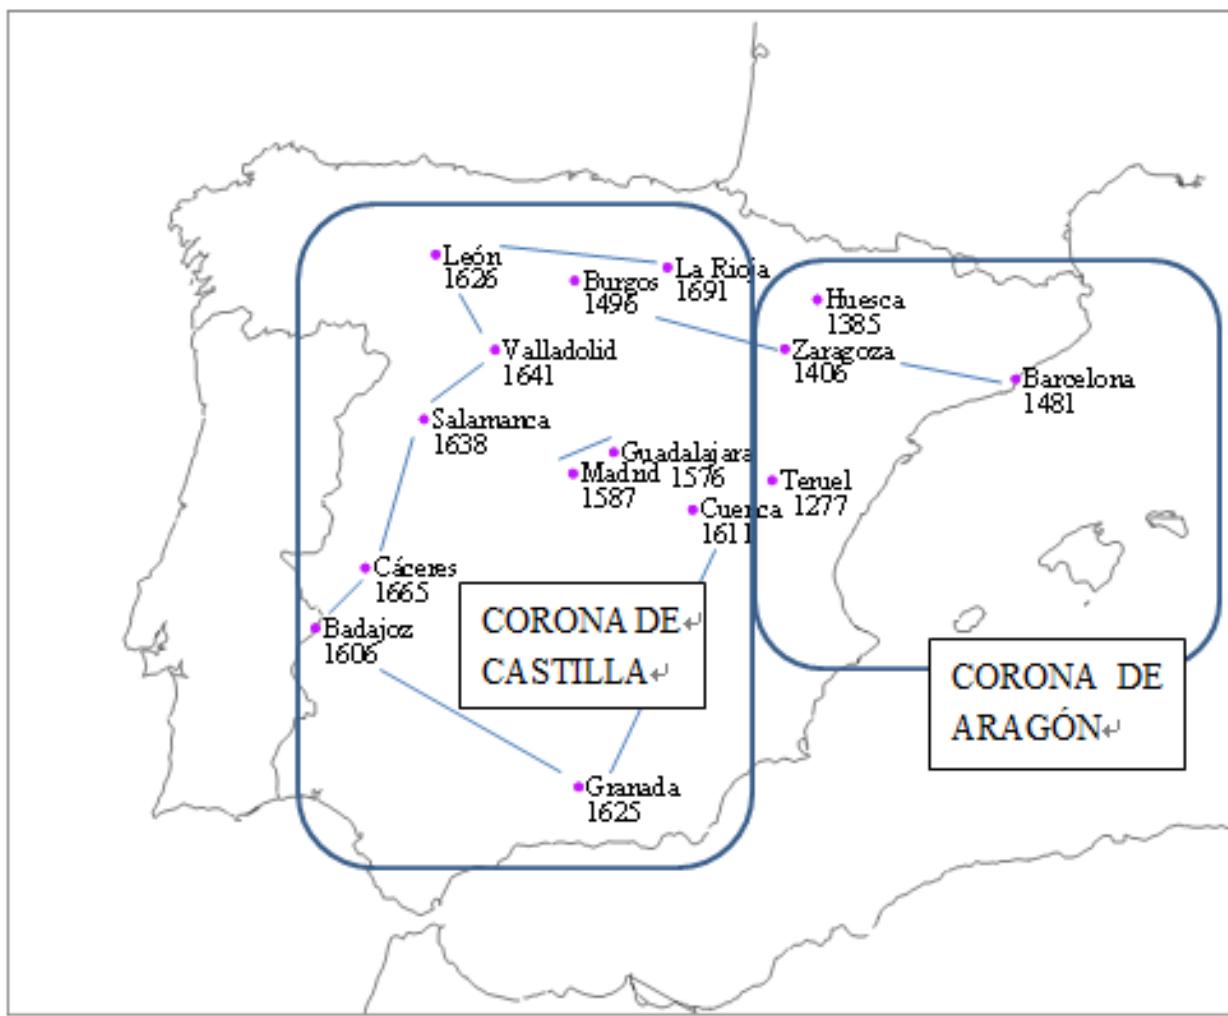


Fig. 3.1. First appearance of the NDR form

3. 2. Aragon and Navarra

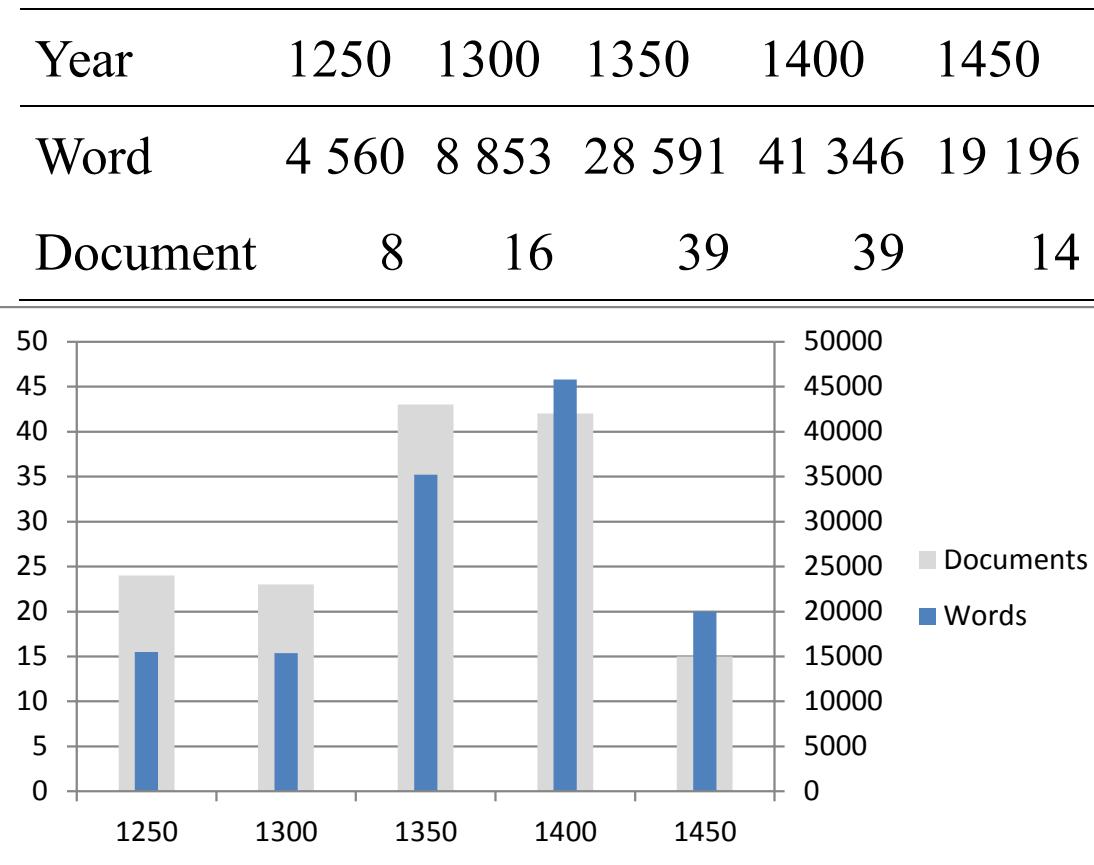


Fig. 4.2.a. Number of documents and words in Aragón and Navarra

Year	1250	1300	1350	1400	1450
NR	3	0	23	4	0
RN	0	3	7	32	17
NDR	1	0	6	19	17
RR	6	2	7	1	1

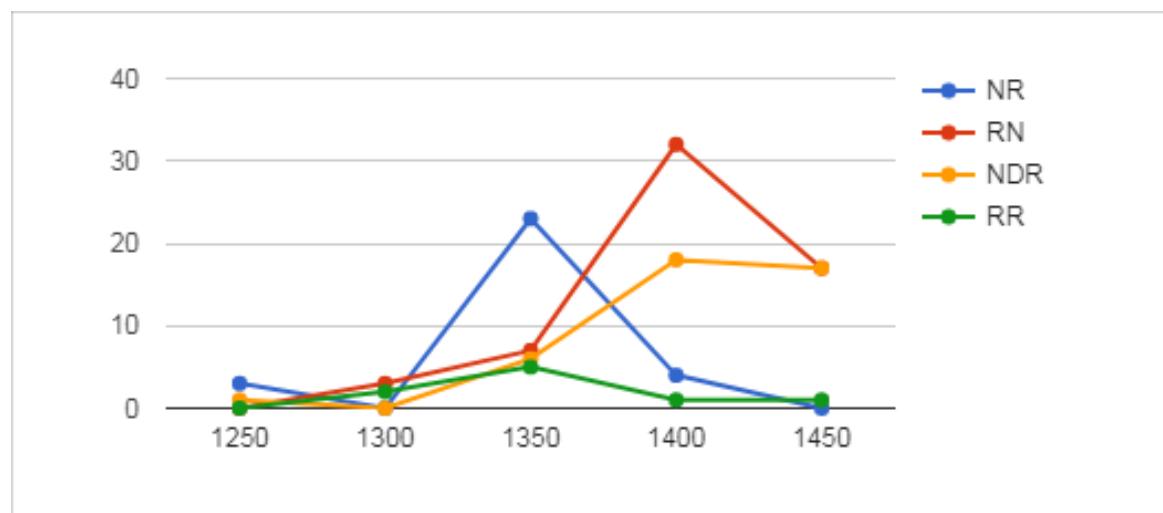


Fig. 4.2.c. Future forms in NR, RN, NDR, RR in Aragón. Absolute frequency

Year	1250	1300	1350	1400	1450
NR	2.81	.00	37.91	1.76	.00
RN	.00	2.81	6.63	44.39	44.58
NDR	.05	.00	5.10	22.55	44.58
RR	11.49	1.00	6.63	.05	.05

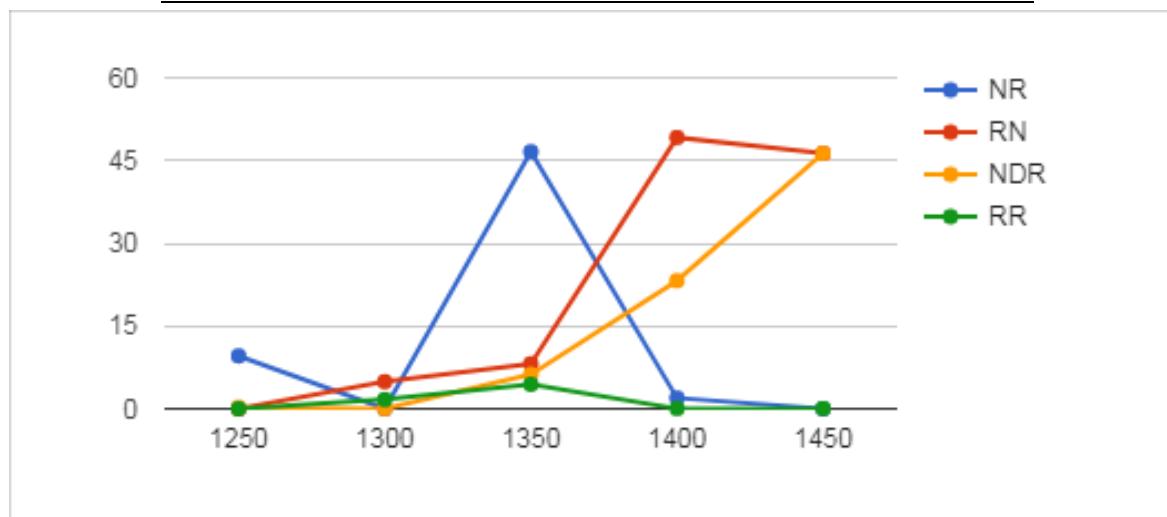


Fig. 4.2.d. Future forms in NR, RN, NDR, RR in Aragón
 Probabilistic frequency for 100 thousand words

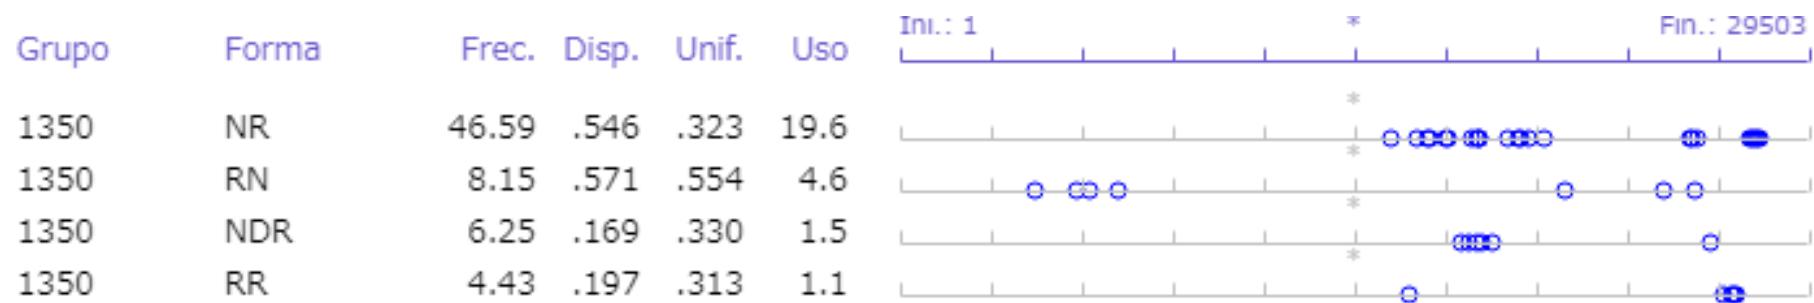
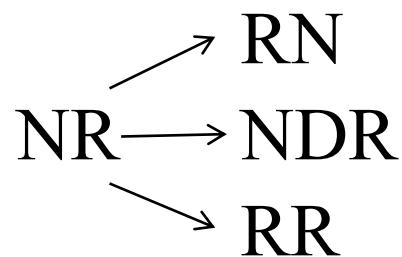


Fig. 4.2.e. Frequency and dispersion of RN, NDR, RR in Castilla of 1350

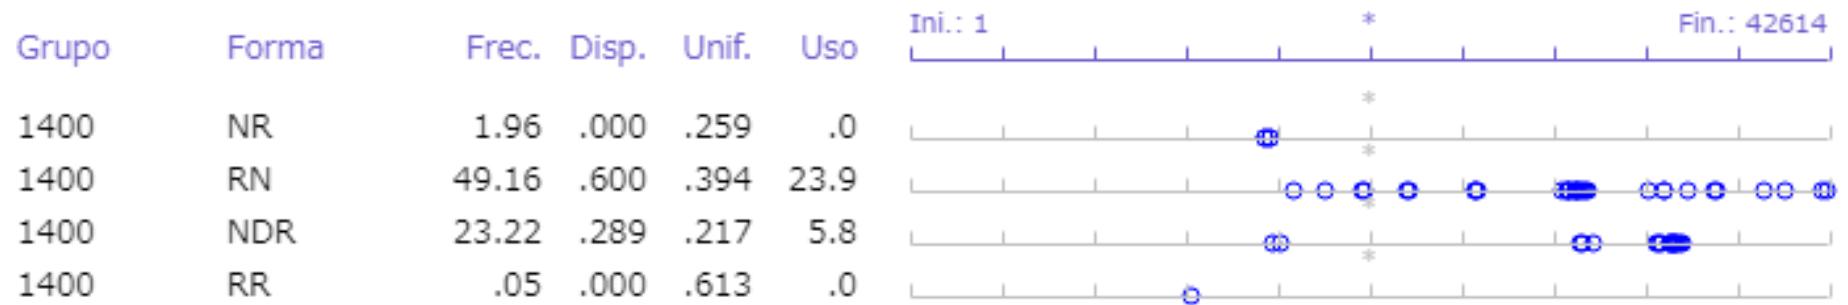


Fig. 4.2.f. Frequency and uniformity of RN, NDR, RR in Castilla of 1400

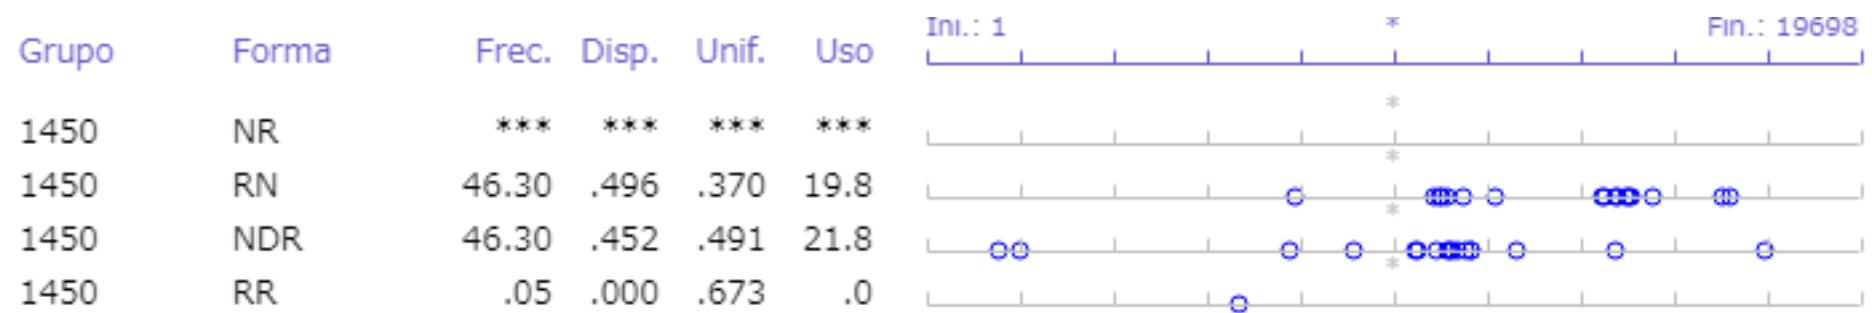


Fig. 4.2.g. Frequency and uniformity of RN, NDR, RR in Castilla of 1400

3. 3. Castile

Year	1200	1250	1350	1400	1450	1500	1550	1600	1650	1700	1750
Doc	43	176	81	81	101	158	348	184	131	122	193
Word	18976	98139	87449	97972	112015	128899	145371	78822	94090	53259	72603

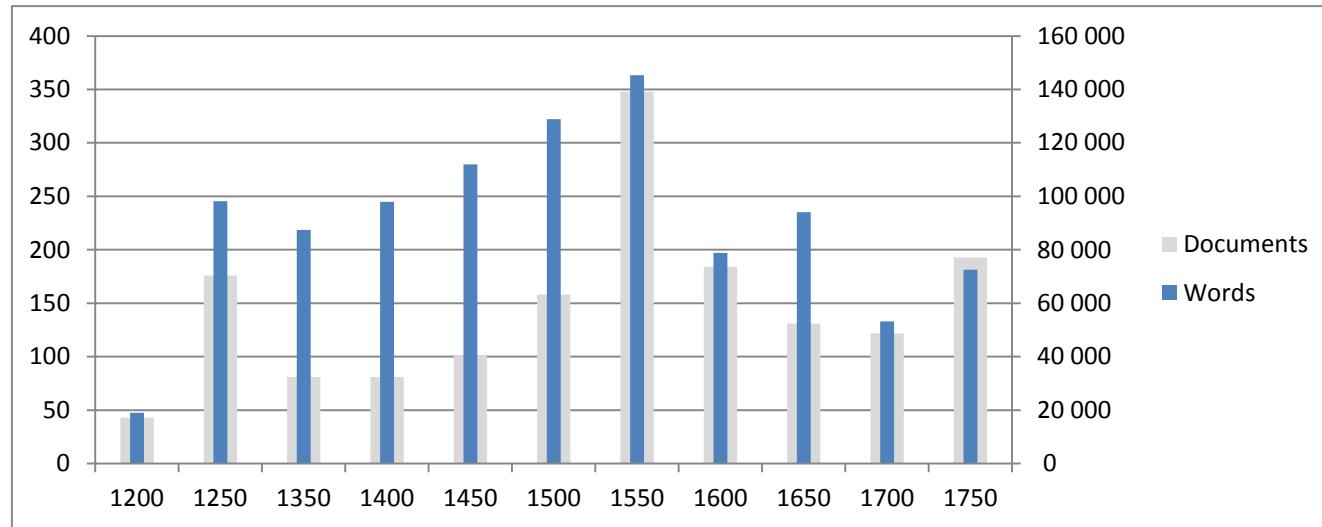


Fig. 4.3.a. Number of documents and words in Castile

Year	1200	1250	1350	1400	1450	1500	1550	1600	1650	1700	1750
RN	10	9	7	13	28	19	33	10	1	0	0
NDR	0	0	0	0	2	0	20	13	13	21	29
RR	0	1	0	0	0	0	0	0	0	0	0

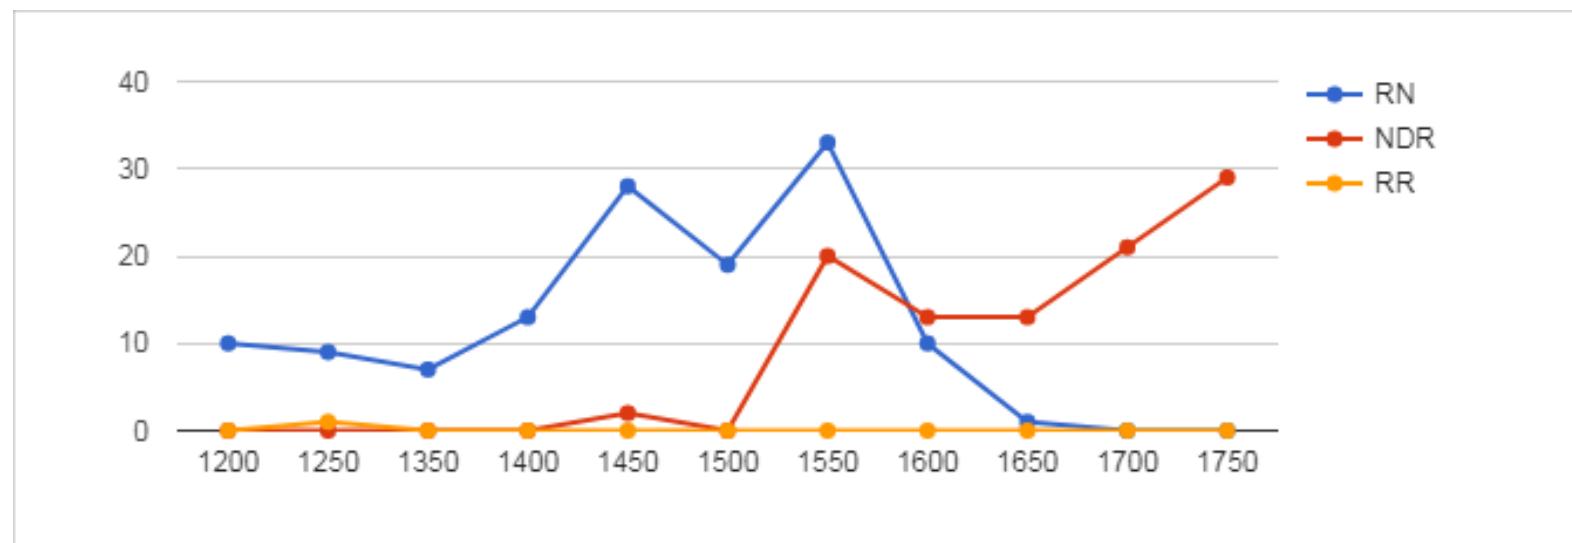


Fig. 4.3.b. Future forms in RN, NDR, RR in Castile. Absolute frequency

Year	1200	1250	1350	1400	1450	1500	1550	1600	1650	1700	1750
RN	21.79	3.58	2.62	6.25	15.31	8.06	14.54	5.20	.05	.00	.00
NDR	.00	.00	.00	.00	.14	.00	7.58	7.77	6.44	22.17	24.75
RR	.00	.05	.00	.00	.00	.00	.00	.00	.00	.00	.00

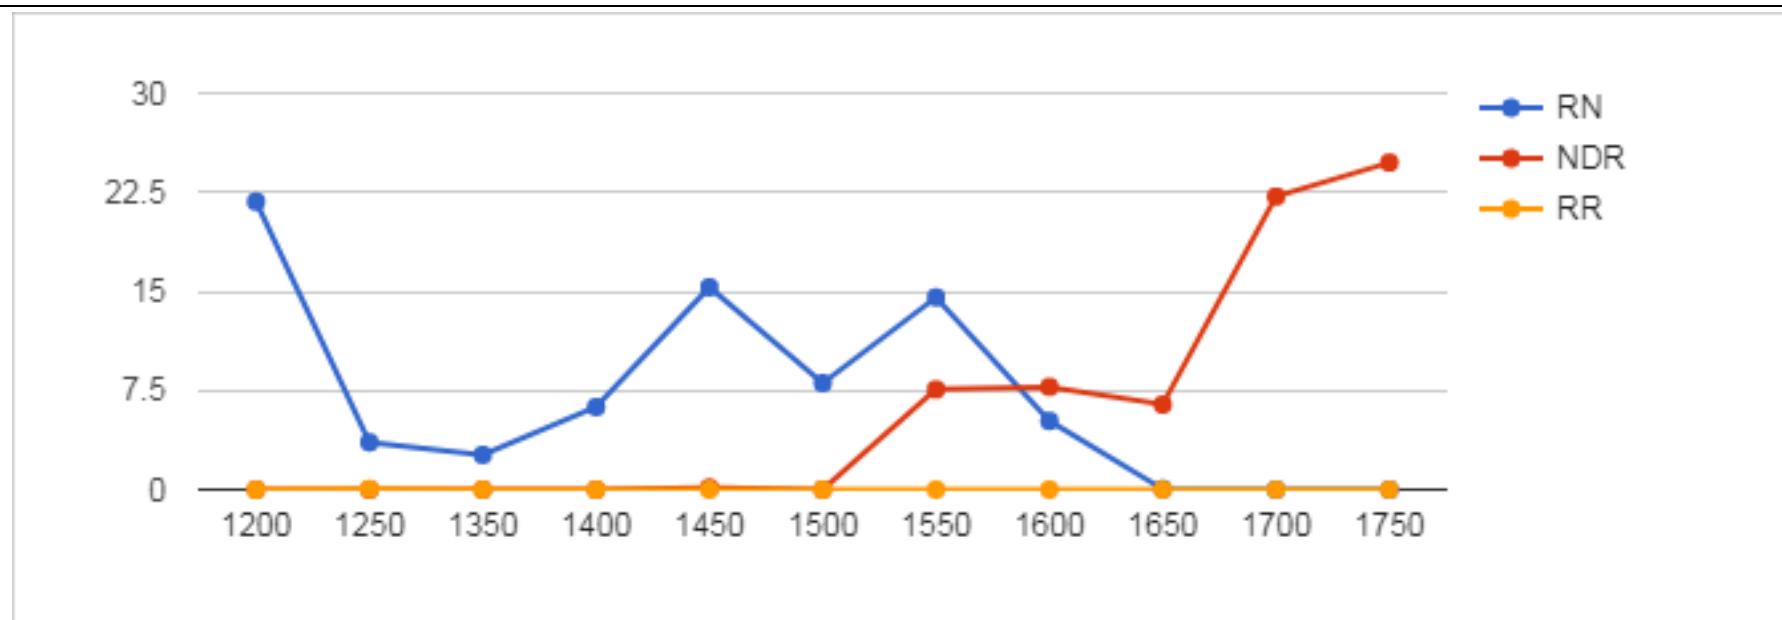


Fig. 4.3.c. Future forms of conjugation in RN, NDR, RR in Castilla

Probabilistic frequency per 100,000 words

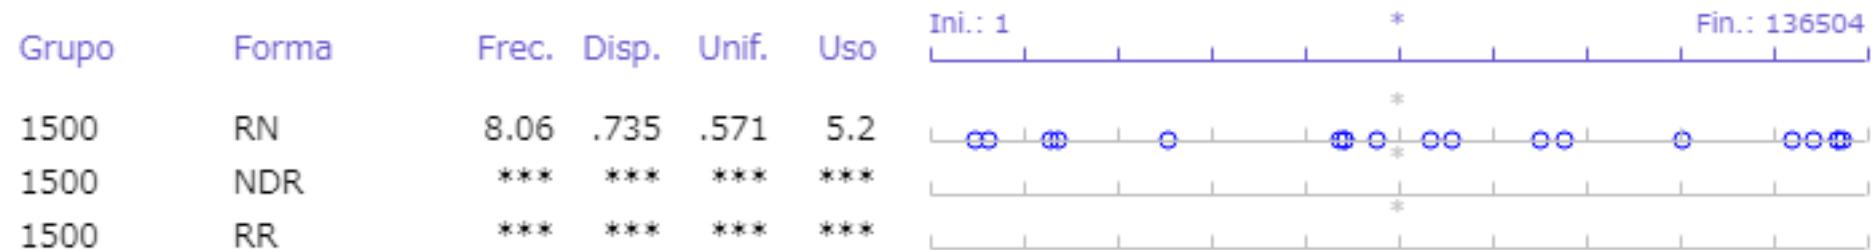


Fig. 4.3.d. Frequency and dispersion of RN, NDR, RR in Castilla de 1500



Fig. 4.3.e. Frequency and dispersion of RN, NDR, RR in Castilla of 1550



Fig. 4.3.f. Frequency and dispersion of RN, NDR, RR in Castilla of 1600

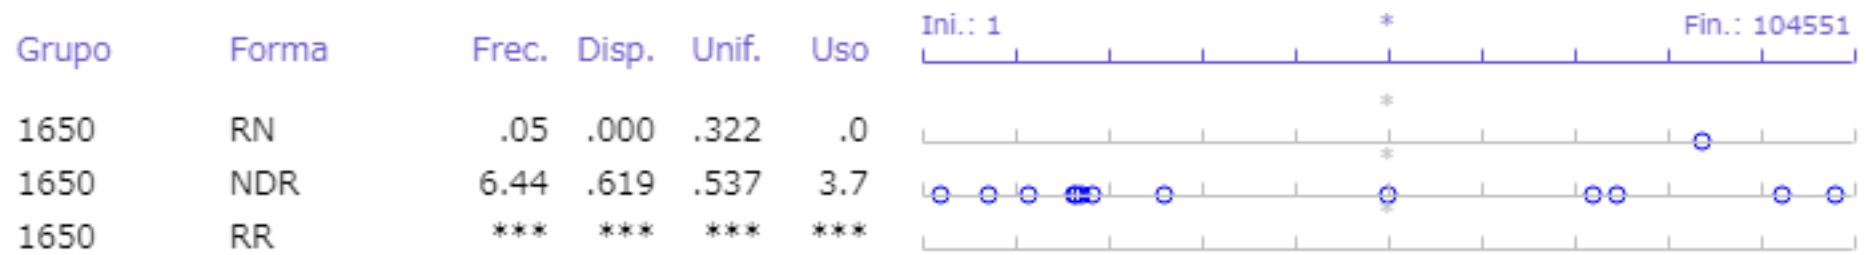


Fig. 4.3.g. Frequency and dispersion of RN, NDR, RR in Castilla of 1650



Fig. 4.3.h. Frequency and dispersion of RN, NDR, RR in Castilla of 1650

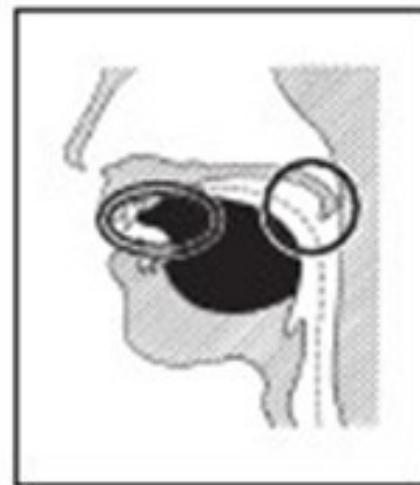
4. Discussion

Aragon in 1400: NR → NDR, for example, *tenrá*, *tenrán*, *venrán*, ('he will have', 'they will have', 'they will come')

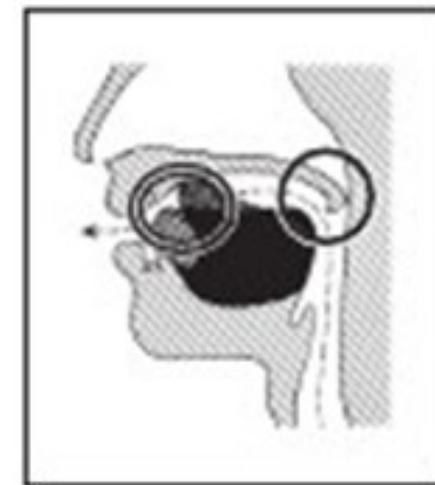
Castile in 1600: RN → NDR, for example, *terné* en *tendré*



[n]



[d]



[r]

Lausberg (1973: 379):

Latin VENIRE HABEO 'I will come': it. *verrò*, fr. a. *vendrai*, fr. m. *viendrai*, prov. a. *venrai*, cat. *vindré*, esp. a. *verné* y esp. m. *vendré*, port. *virei*.

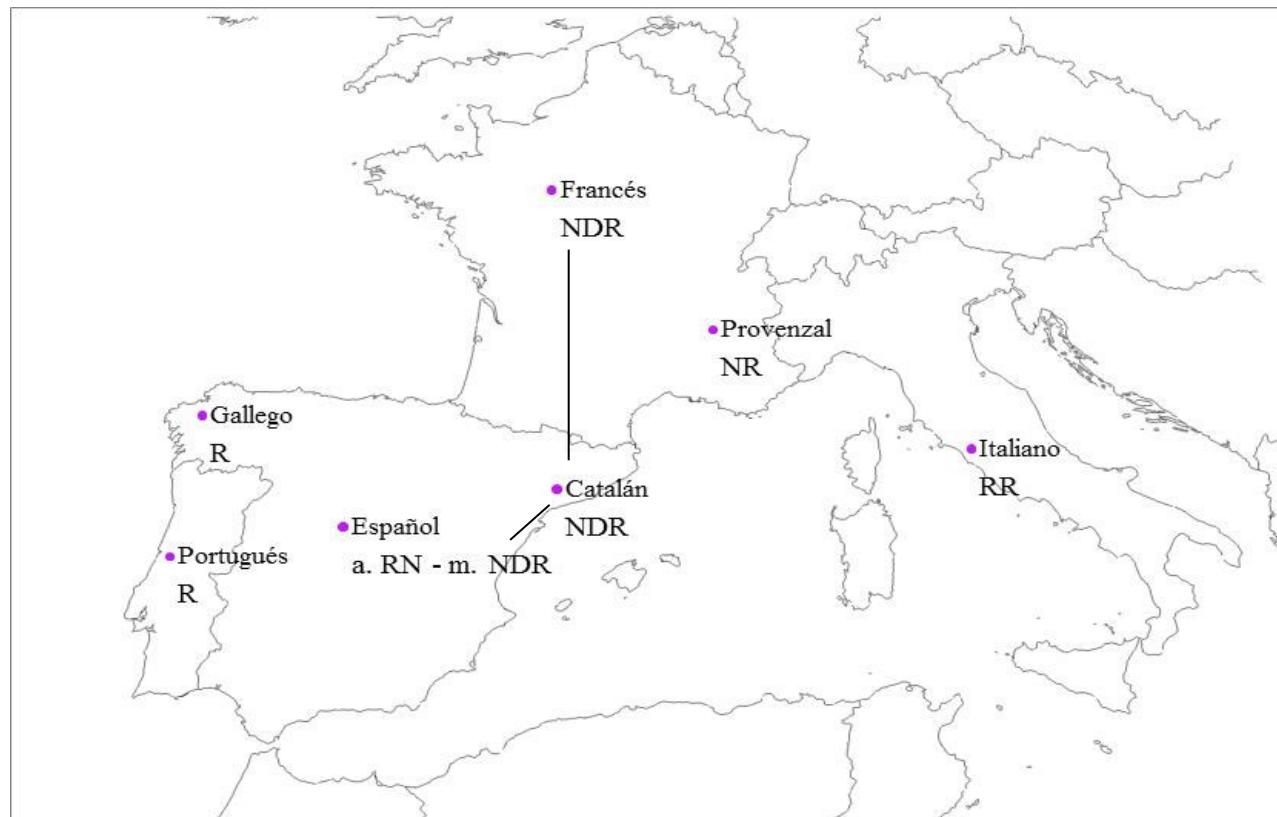
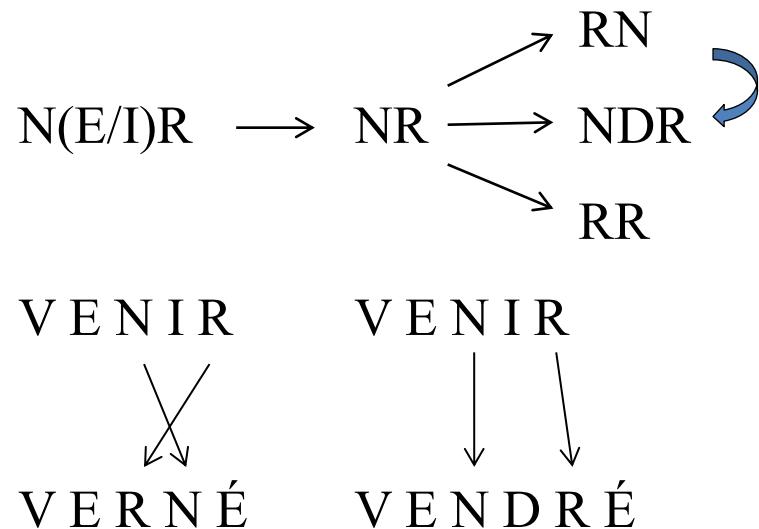


Fig. 5. Future forms with R, RN, NDR, NR, RR in Western Romania



Alvar and Pottier (1983: 251):

"the normal thing was that the language tried to maintain the lexematic uniformity, broken by all these realizations (*com-er*, but *comb-ré*; *ven-ir*, but *vend-ré*, etc.)".

→ *vend-ré* with epenthesis is "more uniform" with the lexeme *venir*, than *verné* with metathesis.

Peny (2006: 111):

Epenthesis: M'N >MBR (HOM(I)NE > *hombre* 'man'; FEM(I)NA > *hembra* 'female'; SEM(I)NARE > *sembrar* 'to seed'), M'R > MBR (HUM(E)RU > *hombro* 'shoulder'), M'L > MBL (TREM(U)LARE > *temblar* 'to shake')

Metathesis: N'R > RN (GEN(E)RU > *yerno* 'son-in-law', VEN(E)RIS > *viernes* 'Friday')

Menéndez Pidal (1972: 160-161):

Epenthesis: "Grupos interiores romances" (Romance interior groups)

Metathesis: "Cambios fonéticos esporádicos" (Sporadic phonetic changes)

The epenthesis is general, while the metathesis is special.

5. Conclusion

Hanssen (1913: 119):

"Some interesting forms are the following: *terné*, *porné*, *verné* (var. *terré*, *tenré*, etc.) by the side of *tendré*, etc."

In our view, the forms in RN and RR were not by the side of the forms in NDR. They were distributed in different manner, both chronologically and geographically.

In Castile the order of RN to NDR is fundamental.

We have observed the phonological change from NR to NDR in Aragón and the lexical transfer from RN to NDR in Castile.

Thanks to the new data presented by the diachronic corpus project CODEA, we can now try to approach the historical-geographical reality.

To statistically evaluate the documentary evidence, we have installed the functions of the Probabilistic Frequency, which offer a high degree of significance (99%) and the Block Dispersion and Uniformity, which confirm the degree of stability of the recorded frequencies.

Reference

- Alvar, Manuel / Pottier, Bernard. 1983. *Morfología histórica del español*. Madrid. Gredos.
- Andrés Díaz, Ramón de. 2013. *Gramática comparada de las lenguas ibéricas*. Gijón, Ediciones Trea.
- Hanssen, Federico. 1913, 1966. *Gramática histórica de la lengua castellana*. París. Ediciones Hispano-americanas.
- Juillard, Alphonse / Chang-Rodríguez, E. 1964. *Frequency dictionary of Spanish words*, The Hague, Mouton.
- Kataoka, Kozaburo. 1982. *Romansugo rekishi bunpo. (Gramática histórica de las lenguas románica.)* Tokio. Asahisyuppansha.
- Lapeza, Rafael. 1980. *Historia de la lengua española*. Madrid, Gredos.
- Lausberg, Heinrich. 1976. *Lingüística románica. Tomo II. Morfología*. Madrid, Gredos.

Lloyd, Paul M. 1987. *Del latín al español. I. Fonología y morfología históricas de la lengua española*, Madrid, Gredos.

López-Davalillo Larrea, Julio. 2000. *Atlas histórico de España y Portugal. Desde el Paleolítico hasta el siglo XX*. Madrid. Editorial Sintesis.

Menéndez Pidal, Ramón. 1968. *Manual de gramática histórica española*, 13ed. Madrid, Espasa-Calpe.

Moreno Bernal, Jesús. 2004. "La morfología de los futuros románicos. Las formas con metátesis". en *Revista de Filología Románica*, núm. 21, pp. 121-169.

Penny, Ralph. 2006. *Gramática histórica del español*. Barcelona, Ariel.

Serrano Marín, Marina. 2018. *Estudio de la morfología verbal del español en fuentes documentales de los siglos XIII-XVI*, Tesis doctora presentada en la Universidad de Alcalá.

Ueda, Hiroto. 2015. «La vocal débil en la apócope extrema medieval: Observaciones sobre el Corpus

- de Documentos Españoles Anteriores a 1700», en Sánchez Méndez, J. P., M. de la Torre / V. Codita (eds.) *Temas, problemas y métodos para la edición y el estudio de documentos hispánicos antiguos*. Valencia: Tirant Humanidades, pp. 585 - 607.
- _____. 2011. *Supeingo bunpoo handobukku. (Manual de la gramática española para estudiantes japoneses)*. Tokio. Kenkyusha.
- _____. 2017. *Análisis de datos cuantitativos para estudios lingüísticos*.
<https://lecture.ecc.u-tokyo.ac.jp/~cueda/gengó4-numeros/doc/numeros-es.pdf>
- _____/ Moreno Sandoval, Antonio. 2018. «Unión y separación de preposición y artículo definido del español. Observaciones con la frecuencia probabilística en el análisis de Pareto», comunicación oral presentada en el *X Congreso Internacional de Lingüística de Corpus*, Cáceres, España, 9 de mayo.

Appendix

Programa-1: BinS (Excel VBA)

```
Function BinS(x, n, e)
    'Significance s (x: occurrence, n: trials, e: expectation probability)
    If x = 0 Then BinS = 0: Exit Function
    BinS = Application.BinomDist(x - 1, n, e, 1)
End Function
```

Programa-2: BinE (Excel VBA)

```
Function BinE(x, n, s)
    'Expectative probability e (x: occurrence, n: trials, s: significance)
    Dim i, k, r, mn, mx, sc: If x = 0 Then BinE = 0: Exit Function
```

$r = 10^6$: mx = r 'precision: maximum search

Do While $k < 1000$

$i = (mx + mn) / 2$ 'midpoint between maximum and minimum

BinE = i / r 'candidate of expectative probability

sc = BinS(x, n, BinE) 'the candidate's own significance

If $sc < s - 1 / r$ Then 'If sc does not reach $s-1 / r$...

 mx = i 'lower the search maximum to the midpoint

ElseIf $sc > s + 1 / r$ Then 'Si sc sobrepasa a $s-1/r$...

 mn = i 'raise the minimum to the midpoint

Else 'If sc falls within the scope of $s \pm 1 / r$...

 Exit Do 'leave the loop

End If

$k = k + 1$

Loop

End Function