

Machine learning algorithms for Natural Language Processing in stroke discharge reports

ictusnet-sudoe.eu



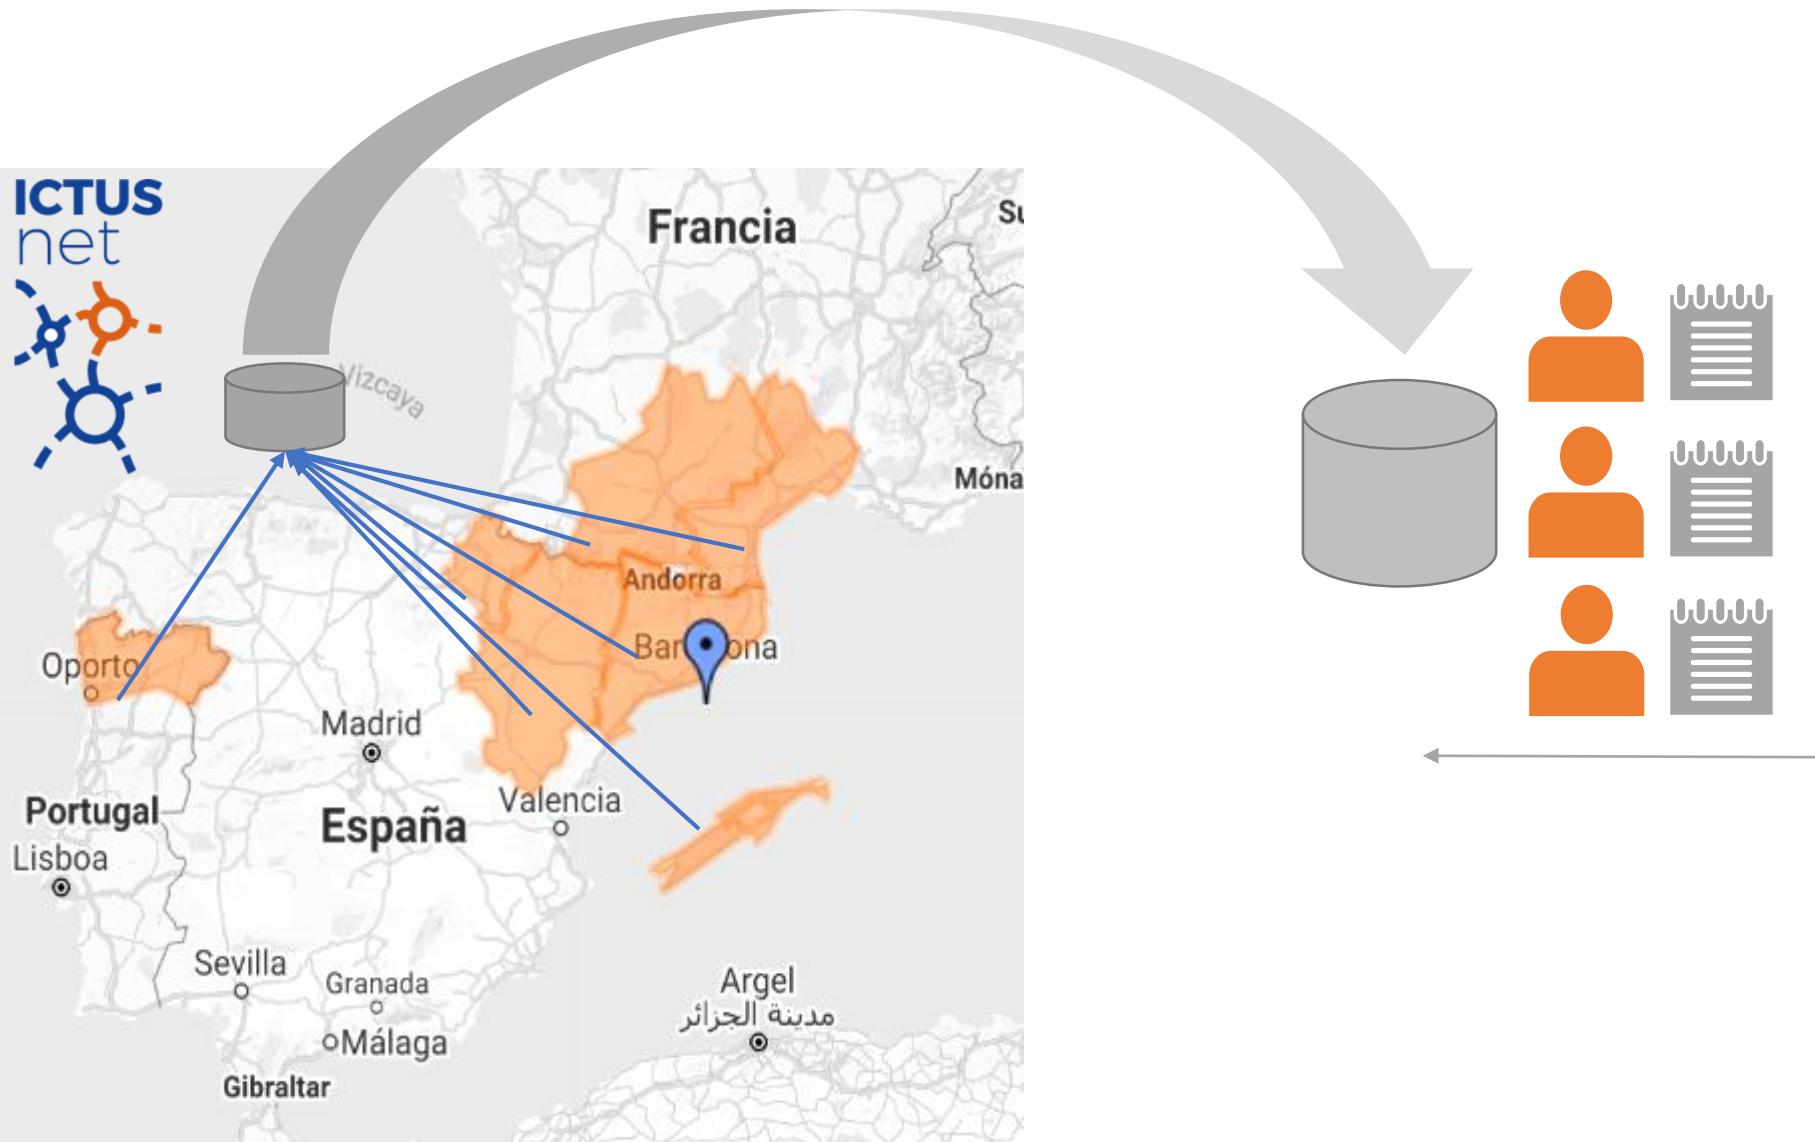
Marta Villegas
Aitor González, Siamak Barzegar,
Casimiro Carrino, Jordi Armengol, Asier Gutiérrez



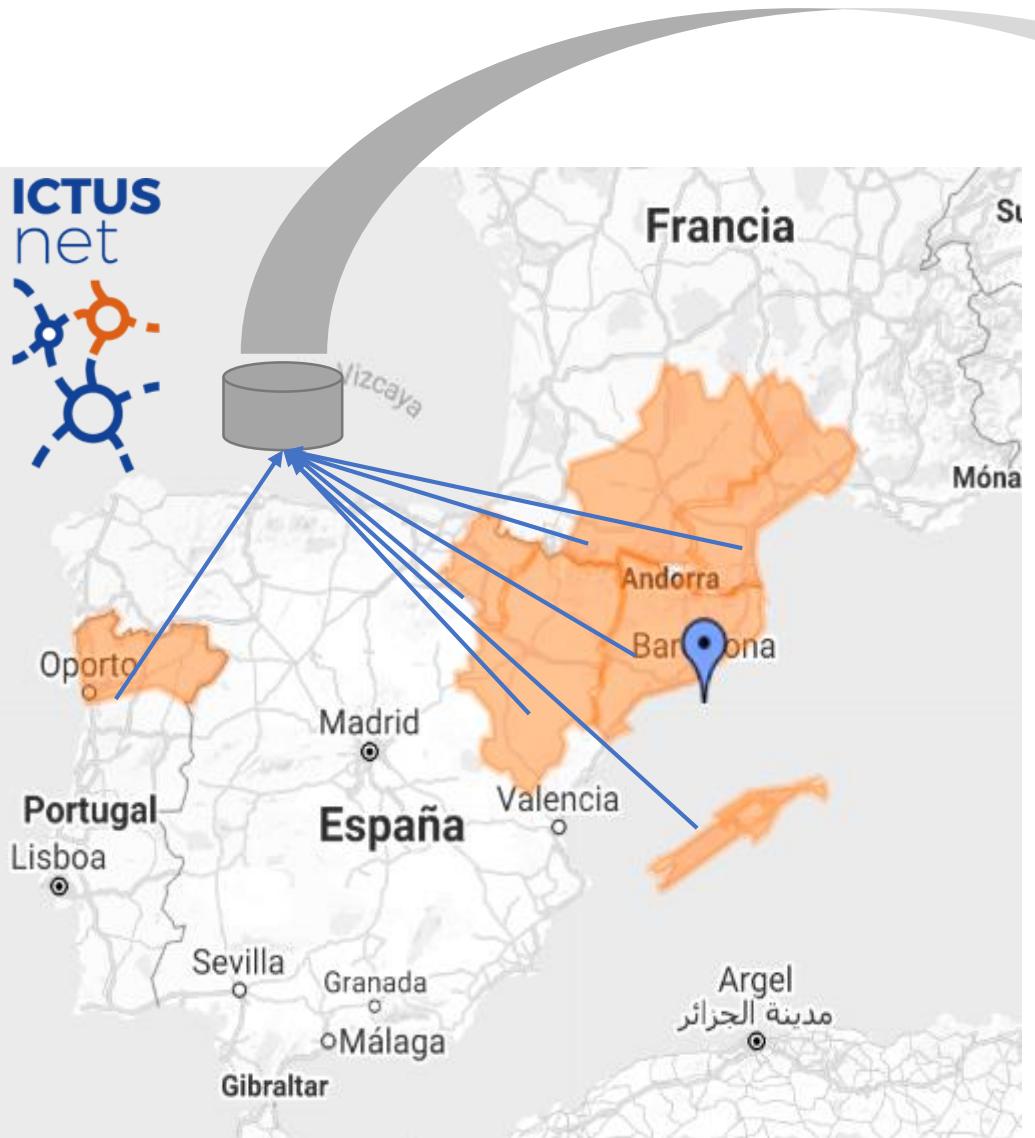
**Barcelona
Supercomputing
Center**
Centro Nacional de Supercomputación

“INNOVATIVE USES OF REAL WORLD DATA ON STROKE”

An information extraction service to support human experts



An information extraction service to support human experts



Screenshot of the ICTUSnet web interface. The interface has a sidebar with categories: Entrada y salida del paciente, Diagnóstico, Procedimientos I - trombólisis, Procedimientos II - trombectomía, and Tratamientos. Below this is a section for Pruebas y escalas de valoración, specifically TAC craneal, with fields for Fecha (17/01/2017) and Hora. An ASPECTS scale is shown with the value 10. The main content area displays a detailed medical report in Spanish:

91). Perfil renal e ionograma sin alteraciones. Hemograma sin alteraciones. Hb glicada 6%.

Radiología / Radiología

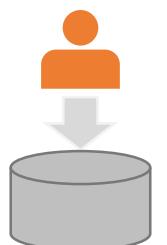
*RADIOGRAFIA DE TORAX: ICT dentro de la normalidad. No se observan infiltrados ni condensaciones.

*TC CRANEO MULTIMODAL:

- TC CRANEAL BASAL: No hay hemorragia intracraneal. Parénquima cerebral sin pérdida de la diferenciación cortico- subcortical. **ASPECTS 10**.
- TC PERFUSIÓN CEREBRAL: Territorio afectado: superficial de la ACM1. TTP: Retraso a nivel frontal, parietal, temporal superior e insular. CBF: Disminuido en territorio prácticamente superponible al de retraso del TTP. CBV: No se observan focos de caída del volumen cerebral. Porcentaje del área penumbra: >20%.
- ANGIO-TC EXTRA E INTRACRANEALES: Leve ateromatosis que no condiciona estenosis en arco aórtico y salida/segmentos proximales de troncos supraaórticos. Ateromatosis calcificada en ambas bifurcaciones carotideas, con estenosis de aprox. el 50% en el origen de la carótida interna izquierda. Se aprecia un STOP en el paso de contraste en una rama M1 distal/M2 proximal de la ACM1.. El resto de principales arterias cerebrales intracranales.

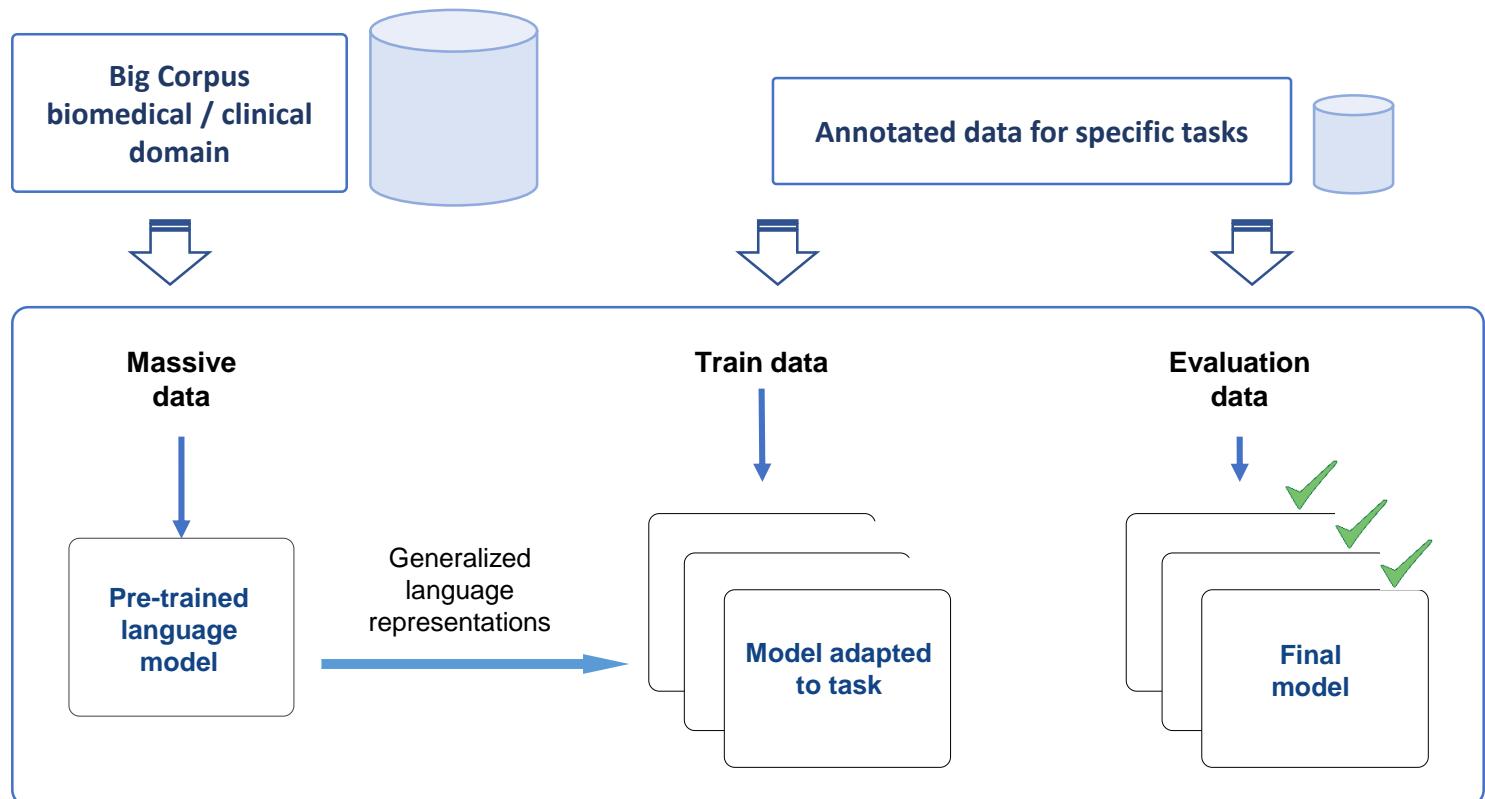
*TC CRANEO DUAL: Hipodensidad lineal en cisura silviana izquierda así como otros focos de hipodensidad a nivel temporal posterior y parietal izquierdo, que tras el postprocesado de las imágenes corresponde prácticamente en su totalidad a sangrado agudo.

*TC CRANEO CONTROL (17/1): Resolución parcial de hemorragia en cisura silviana. No otras alteraciones.

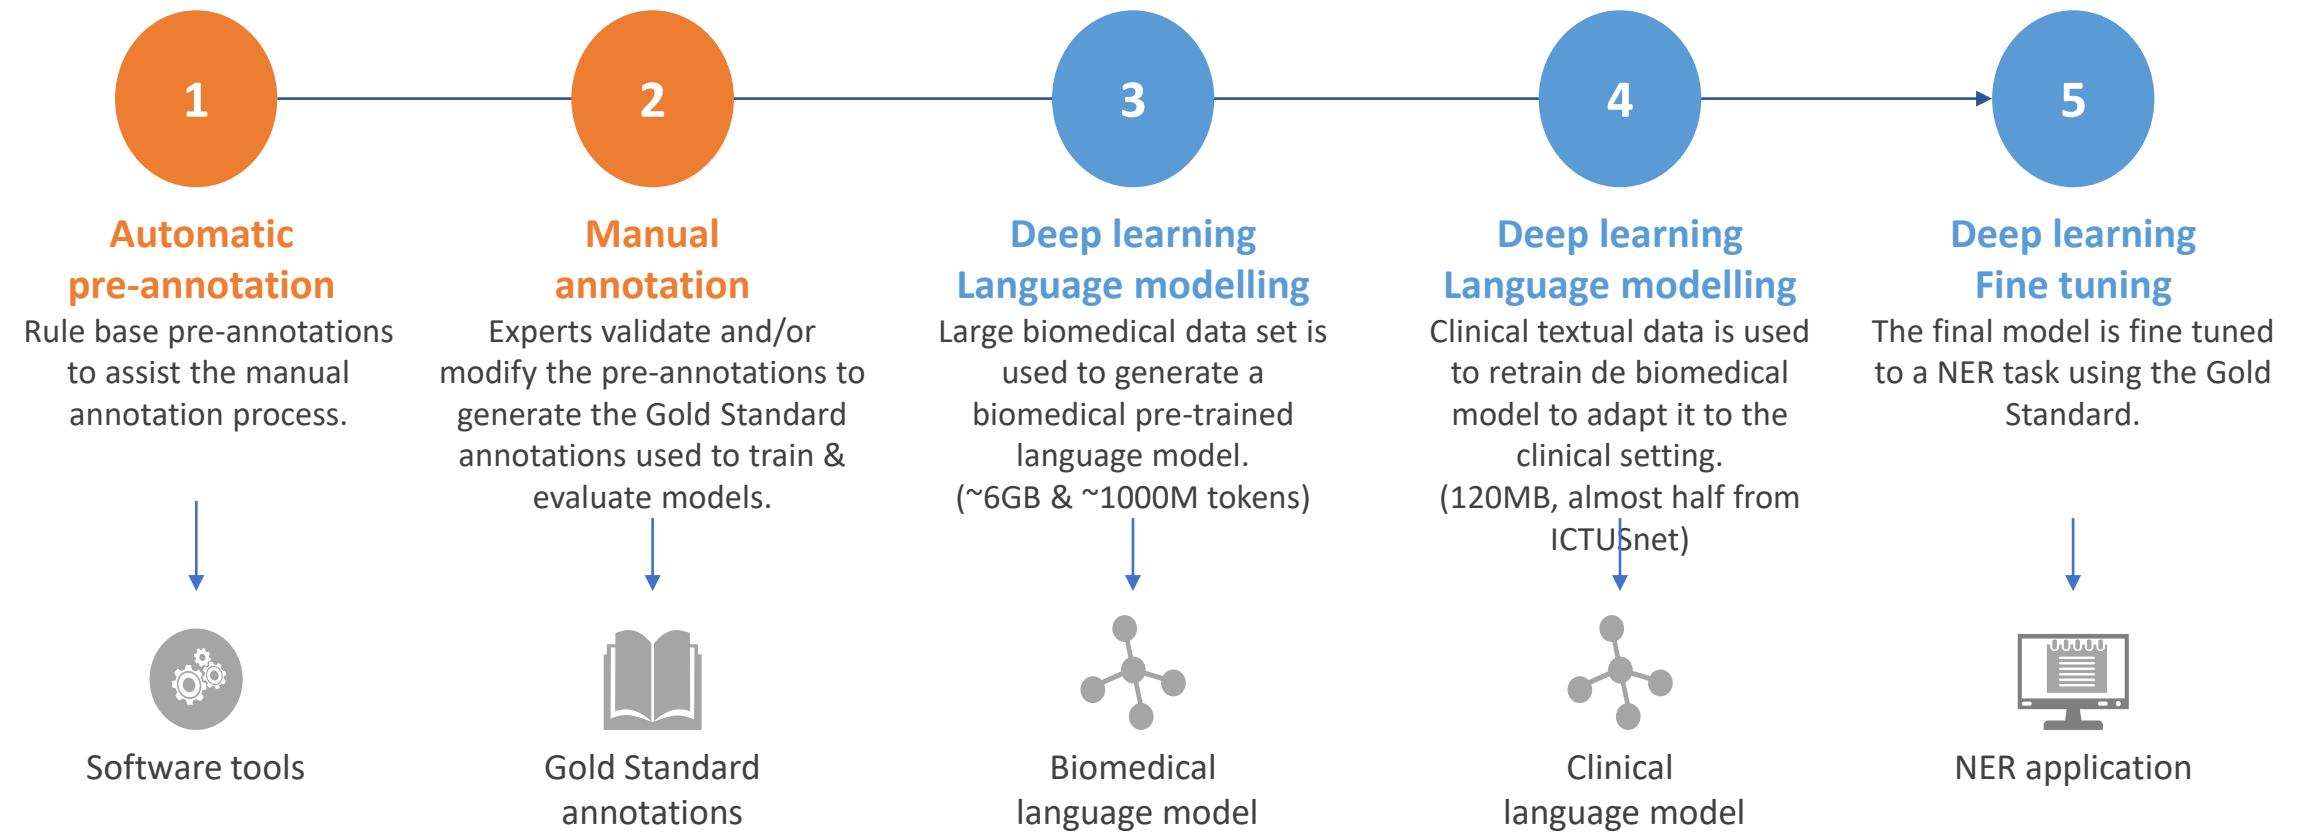


Methodology

1. We used deep learning techniques and deep neural networks to generate a **domain specific language model**.
2. Then, we adapt this model (**fine tune** it) to a specific task (Named Entity Recognition, NER)



Methodology



INDEX

1. Annotation variables & main challenges
2. (Pre)-annotation task
3. Language modelling & fine-tuning to NER
4. Evaluation
5. Summary & Conclusions
6. Examples & demo

VARIABLES and main challenges

ICTUSnet includes **51 different variables of interest** to be identified in discharge clinical reports.

These can be grouped into 6 groups:

- Section headers
- Main diagnosis & associated variables
- Procedures & associated temporal information
- Treatments
- Scales
- Temporal variables


 /joint_files/all/321459759.utf8

28 Fibrilación auricular en tratamiento con **Tratamiento anticoagulante hab**
 29 5.
 30 Vertigo posicional poroxístico benigno en tratamiento médico Intervenciones quirúrgicas: cataratas de ambos ojos.
SECCION SITUACION FUNCIONAL
 31 Situación basal: Indpendiente para las ABVD, continente biesfinteriana.
mRankin_previa
 32 Barthel: 85, mRS0
SECCION TRATAMIENTO HABITUAL **Tratamiento_anticoagulante_hab**
 33 Tratamiento habitual: Serc 8 mg 1c/24h, sintrom según pauta, pravastatina 40 mg 1c/24h, bisoprolol
SECCION PROCESO ACTUAL
 35 ENFERMEDAD ACTUAL:
 36 Paciente de 84 años el día 02/01/2017 a las 10:00am en la sala de espera de oftalmología inicia clínica de afasia motora, her
 37 A su llegada a urgencias la paciente presenta afasia, hemiplejia derecha, babinski derecho y desviación de la mirada hacia la **TAC_craneal**
 38 Se le realiza un **TAC craneal** simple que descarta lesiones expansivas o sangrado agudo, se realiza posteriormente una Angio **Trombectomia_mecánica**
 39 En el **SS** se realiza microcateterismo selectivo de la arteria ocluida, logrando atravesar el trombo a las 13 horas y 15 min
 40 Se realiza extracción mecánica con sistema TREVO 6 X 25 y aspiración manualdesde CAD sofia 5F obteniendo revascularizac
 41 Se da por concluido el procedimiento sin complicaciones a confirmándose en la arteriografía un grado de reperfusión grado 3 **TAC_craneal**
 42 Se realiza un **TAC craneal** posterior que muestra Hipodensidad en región temporal anteromedial izquierda y en ganglios de l
 43 Tras el procesado de las imágenes se evidencia que mayormente corresponde a contraste, identificando un tenue sangrado a
 44 Hipodensidad con desdiferenciación corticosubcortical temporal posteromedial en relación con lesión isquémica establecida.
 45 Se realiza translado a HUMT y se ingresa en Neurología para completar estudio.
SECCION EXPLORACION FISICA
EXPLORACIÓN FÍSICA:

Section headers (need to normalize)

- Data coming from different providers with different structures and formats, need to normalize (use of Arquetipos suggested by Spanish Health Ministry as a mapping standard)).
- Some variables are ‘context dependent’ (they are only relevant provided they are in a specific section)
- We need *zoning* to discriminate variables by context

DIAGNÓSTICOS:

1. ICTUS TACI DE ACM IZQUIERDA
2. FIBRINOLÍSIS IV + UROKINASA INTRAARTERIAL
3. HIPERTENSIÓN ARTERIAL
4. DISLIPEMIA
5. FORAMEN OVAL PERMEABLE

Paciente varón de 66 años, sin alergias conocidas.

*Hábitos tóxicos: fumador de 15 cig/día.

*Sociofuncional: independiente para las ABVD, vive con su esposa. Rankin 0

PROCEDIMIENTOS:

- TC craneal
 Angio TC craneal
 Fibrinolisis IV con alteplasa
 Arteriografía con administración de urokinasa local.
 Monitorización en UCI
 Monitorización en Unidad de Ictus

ANTECEDENTES:

- Hipertensión arterial en tratamiento con 2 fármacos.
- Dislipemia en tratamiento dietético.
- Lumbociatalgía izquierda L5. En seguimiento por Reumatología y Unidad del dolor.
- Espondiloartrosis cervical C5-C7 con calcificación de tejidos blandos (miositis osificante).
- Neuropatía bilateral cubital en tratamiento con Gabapentina.

MEDICACIÓN HABITUAL:

Enalapril 10mg/12h, Hidroclorotiazida 12.5mg/24h, Gabapentina 150mg/12h, Domperidone 10mg/12h
 Zaldiar 50mg/12h ÍNDICE BARTHÉL PREVI : 100

ENFERMEDAD ACTUAL:

Paciente traído el 29/11 a las 23:18 como código ICTUS extrahospitalario. Presenta cuadriplejia derecha, afasia y desviación de la comisura bucal de inicio a las 21:45h.

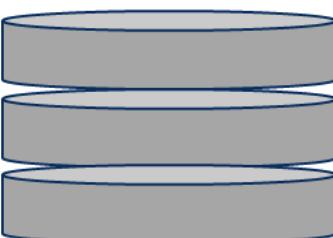
Set of variables

V1

V2

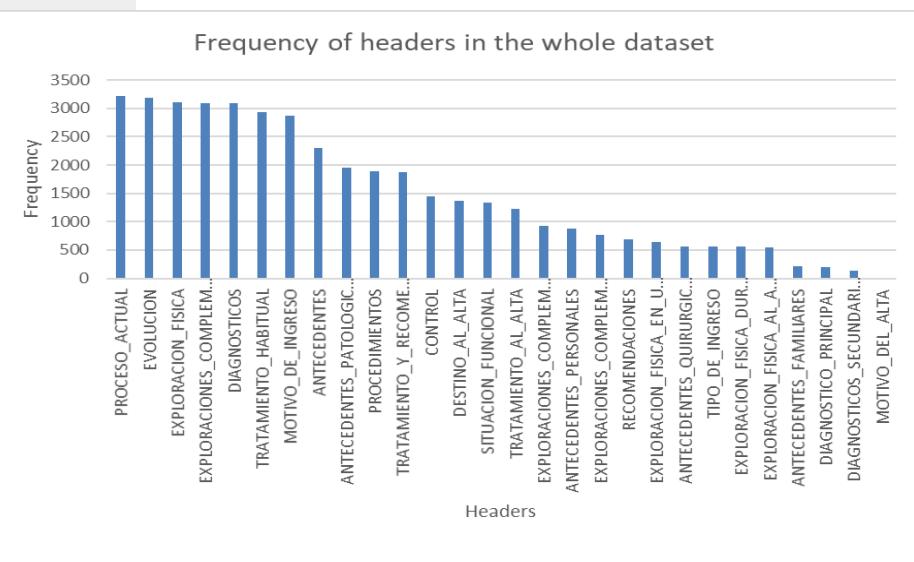
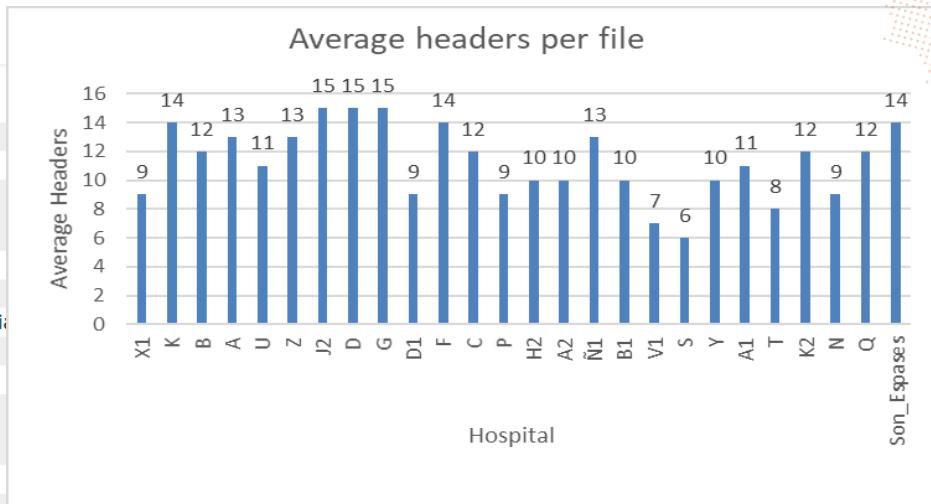
V3

V4



Section headers (and structural heterogeneity)

SECCION MOTIVO DE INGRESO	MOTIU D'INGRÉS Paciente que ingresa por ictus ACM izq y ACA izq cardioembólicas.
SECCION ANTECEDENTES	ANTECEDENTS No alergias conocidas No hábitos tóxicos FRCV: -No HTA, no DLP, no DM -Cardiopatías: FA anticoagulada con Sintrom (control en privada Dr. _NAME_ centro.), valvulopatía mitral no tributaria -Niega otros antecedentes de interés.
SECCION ANTECEDENTES QUIRURGICOS	IQ: osteosíntesis húmero proximal izq. apendice y colecistectomía. mrankin 0. Vive sola. Deamulación autónoma. Independiente para las ABVD.
SECCION TRATAMIENTO HABITUAL	MEDICACIÓ HABITUAL CO-VALS FORTE 160MG/25MG VALSARTAN+DIURETIC 1 x 24 h. Indefinida EMCONCOR COR 2,5MG BISOPROLOL, FUMARAT 1 x 24 h. Indefinida SINTROM 4MG ACENOCUMAROL 1 x 24 h. Indefinida
SECCION PROCESO ACTUAL	PROCÉS ACTUAL Fecha llegada hospital Paciente de 82 años que el día 11/01 es encontrada por familiares a las 19.40h en domicilio acostada en quien objetiva RACE 8 y activa código ictus desde domicilio a las 20.15h. La paciente estaba vestida con ropa de cama (ella siempre va a la cafetería a desayunar y hoy no la han visto, por lo q

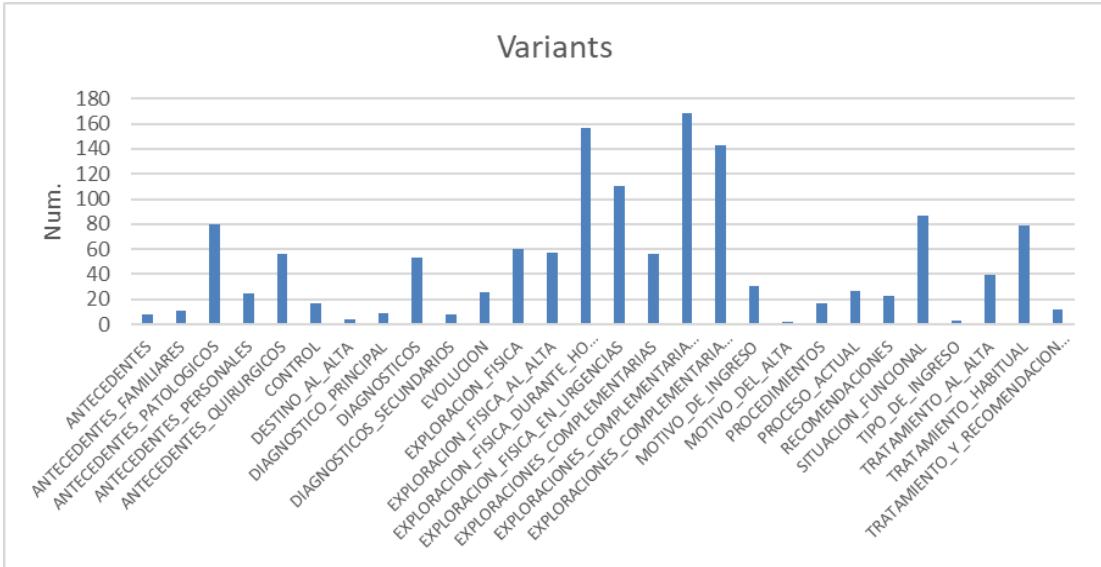


Section headers (and naming conventions)

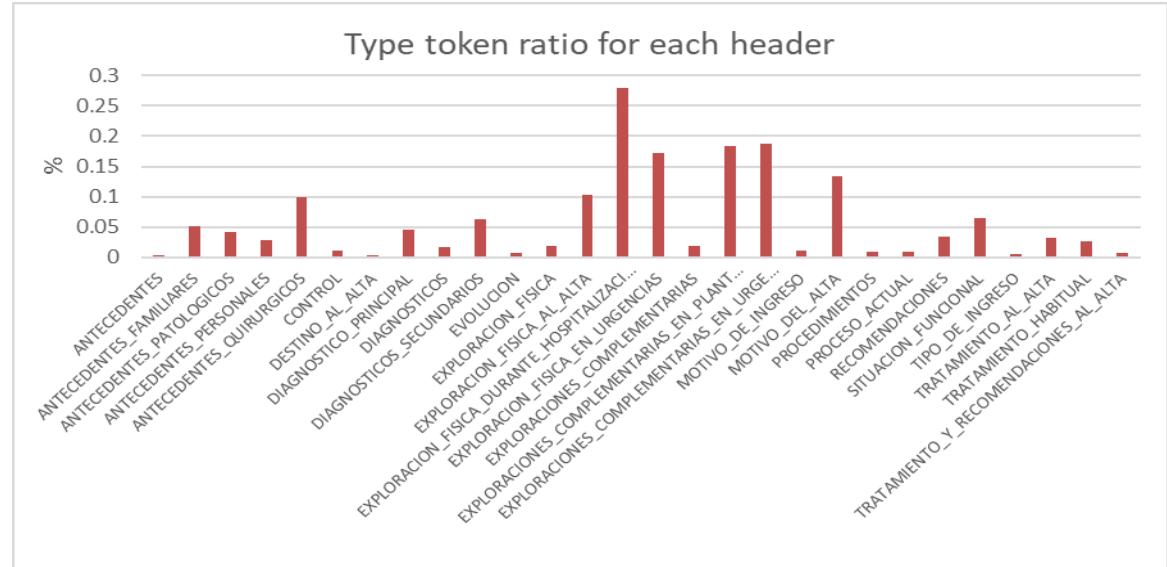
ANTECEDENTES_PATOLOGICOS		
A. patológicos	ANTECEDENTES PATOLÒGICOS	ANTECEDETES PATOLÓGICOS
Anetecedentes médicos	Antecedentes patològicos	ANTECEDETNES MÉDICOS
ANTECDENTES PATOLÓGICOS	ANTECEDENTES PATOLOGICS	Antecedetnes Patològicos
ANTECDENTES PATOLÓGICOS	ANTECEDENTES PATOLÒGICS	ANTECEDNETES PATOLÓGICOS
ANTECECENTES MÉDICOS	ANTECEDENTES PATOLÒGICS	Antecednetes Patològicos
ANTECEDENETS PATOLOGICOS	ANTECEDENTS PATOLOGICS	ANTECENDENTES PATOLÓGICOS
Antecedente Patologicos	Antecedents patològics	Antecedentes patològicos
ANTECEDENTE PATOLOGICOS	ANTECEDENTS PATOLÒGICS	ANTECENDETES PATOLÓGICOS
ANTECEDENTE PATOLÓGICOS	ANTECEDENTS MÉDICOS	ANTECENTES PATOLÓGICOS
ANTECEDENTES PATOLÓGICOS	ANTECEDENTS MÉDICS	ANTECENTS PATOLÒGICS
ANTECEDENTES PATOLÒGICOS	Antecedents mèdics	Antedentes Patològicos
Antecedentes Medicos	ANTECEDENTS PATOLÒGIC	ANTEEDENTS PATOLÒGICS
ANTECEDENTES MEDICOS	ANTECEDENTS PATOLOGIC S	APatològicos
Antecedentes médicos	ANTECEDENTS PATOLÒGIC S	HISTORIAL MÈDIC
ANTECEDENTES MÉDICOS	ANTECEDENTS PATOLOGICOS	Historial mèdic
Antecedentes Médicos	ANTECEDENTS PATOLÓGICOS	HISTORIAL MEDICO
Antecedentes mèdics	Antecedents Patològicos	HISTORIAL MÉDICO
ANTECEDENTES PAOTLÓGICOS	ANTECEDENTS PATOLÒGICOS	Historial médico
ANTECEDENTES PATOLIOGICOS	ANTECEDENTS PATOLOGICS	Malalties prèvies
Antecedentes patològices	Antecedents patològics	Otros antecedentes patològicos
ANTECEDENTES PATOLOGICOS	ANTECEDENTS PATOLÓGICS	PATOLÓGICAS
Antecedentes Patologicos	ANTECEDENTS PATOLÒGICS	PATOLOGICOS
Antecedentes patologicos	Antecedents patològics	PATOLÓGICOS
Antecedentes patològicos	Antecedents Patològics	Patològicos
ANTECEDENTES PATOLÓGICOS	ANTECEDENTS PATÒLOGICS	PATOLOGICS
Antecedentes Patològicos	Antecedents patològics FRCV	PATOLÒGICS
ANtecedentes Patològicos	Antecedents patoògics	

The 80 variants for
ANTECEDENTES PATOLOGICOS

Section headers (and naming conventions)



Number of variants per header (i.e. different ways to mention a header)



TTR is the total number of unique headers (types) divided by the total number of headers (tokens) in the documents

Section headers (and format heterogeneity)

SECCION MOTIVO DE INGRESO

MOTIU D'INGRÉS

Catalan / uppercase / no special markup / full line

SECCION TRATAMIENTO HABITUAL

* MEDICACIÓN HABITUAL: insulina aspi

Spanish / uppercase/ special markup / inserted in paragraph

SECCION PROCESO ACTUAL

Proceso actual / Procés actual

Bilingual / lowercase / no special markup / full line

SECCION SITUACION FUNCIONAL

- Situación sociofuncional: Vive solo, no tiene hijos.
Trabajó de agente comercial. Independiente para todas las ABVD.

Spanish / lowercase / special markup / inserted in paragraph

SECCION PROCEDIMIENTOS

Proc.:

ANALÍTICA SANGUÍNEA () RADIOGRAFÍA DE TÓRAX () ECG.

? / abbreviation / lowercase / no markup / full line

← Upper case!!

Main diagnosis and associated variables

This includes three main diagnoses: *ictus isquémico*, *ataque isquémico transitorio* and *hemorragia cerebral* and their associated attributes:

- affected vessel,
- localization,
- lateralization and
- etiology.

*Context dependent variables
(only relevant if in DIAGNOSTICOS section)*

SECCION DIAGNOSTICOS
DIAGNÒSTICS

SUG_Ictus_isquemico	SUG_Arteria_afectada	SUG_Lateralizacion	SUG_Localizacion	SUG_Etiologia
- Ictus isquèmic de territori de	ACM	esquerra	(big lacunar)	de etiología indeterminada
-Hipertensió arterial essencial				
-Diabetis Mellitus tipus 2				
-Dislipèmia				
-Glaucoma				

Procedures & associated temporal information

Procedures

Trombolisis_intravenosa
Trombectomia_mecanica
Trombolisis_intraarterial
Test_de_disfagia
Tac_craneal

Associated temporal information:

Fecha / hora Tc craneal inicial
Fecha trombólisis iv
Hora inicio primer bolus de la trombólisis rtPA
Fecha trombectomía mecánica
Hora punción arterial para la trombectomía mecánica

Fecha / hora primera serie trombectomía mecánica
Hora trombólisis intraarterial
Fecha / hora recanalización
Fecha / hora finalización trombectomía
Fecha / hora trombólisis intraarterial

Hora_primer_bolus_trombolisis_rtPA

Trombolisis_intravenosa

La pacient compleix criteris per rebre tractament fibrinolític amb rtPA que s'administra a les 11'37h sense incidiències.

T30	Trombolisis_intravenosa	2568 2600	tractament fibrinolític amb rtPA
T14 #3	Hora_primer_bolus_trombolisis_rtPA	2568 2631	tractament fibrinolític amb rtPA que s'administra a les 11'37h

AnnotatorNotes T14 11:37

TAC_craneal

Fecha_TAC

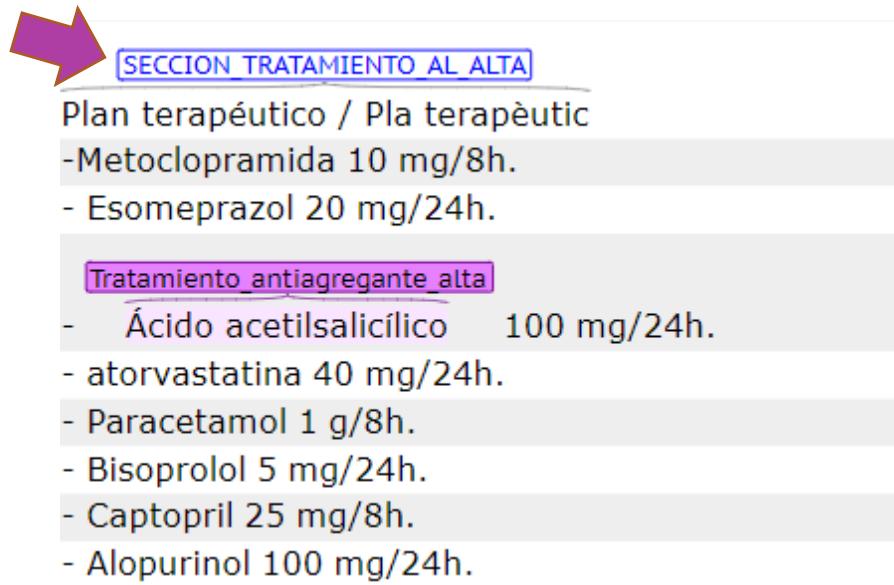
TAC_craneal

-TC craneal de control a las 24h (22/3/17): En valoración comparativa con estudio TC previo no identificado

Treatments

For **treatments**, the objective is to find **anticoagulants** and **antiaggregants** and to classify them as “**pre admission medication**” or “**discharge medication**”.

This task is essentially a NER task that includes a classification part (pre-admission vs discharge). This classification mostly depends on the context of the mention (i.e. the section in which the medication is listed).



SECCION TRATAMIENTO AL ALTA

Plan terapéutico / Pla terapèutic

- Metoclopramida 10 mg/8h.
- Esomeprazol 20 mg/24h.

Tratamiento antiagregante alta

- Ácido acetilsalicílico 100 mg/24h.
- atorvastatina 40 mg/24h.
- Paracetamol 1 g/8h.
- Bisoprolol 5 mg/24h.
- Captopril 25 mg/8h.
- Alopurinol 100 mg/24h.

Scales

The relevant **scales** to be annotated include:

ASPECTS

mRankin_previa, mRankin_alta
NIHSS_previa, NIHSS_alta

The main challenge in this case is to find the numerical value of the rating scale (often this comes in a complex format) and to distinguish between *pre-admission vs discharge* categories.

Note that in the vast majority of cases, this distinction is not explicitly expressed in the reports. Again, these are context dependent variables.

NIHSS_previa

Escala NIHSS $(0-2-0-0-2)+(1-0-0-0-0)+(0-1-2-2-0)= 10.$

SECCION ANTECEDENTES QUIRURGICOS

IQ:

mRankin_previa

osteosíntesis húmero proximal izq. apendice y colecistectomía. mrankin 0.

SECCION SITUACION FUNCIONAL

Estado basal:

viu amb el marit, autonoma per les AVD.

mRankin_previa

Rankin previo 2

VARIABLES and main challenges

- Multiple providers
 - Heterogeneous data with different formats, structure, headers, naming conventions, ...
- Nature of Language
 - Acronyms and abbreviations.
 - Ambiguity.
 - Negation
- User generated content
 - Ungrammatical/telegraphic sentences.
 - Text in different languages.
 - Text written by different personnel.
 - Typos.

Mujer de 84 años sin **ACM**. Niega hábitos tóxicos. Parcialmente dependiente **ABVD**. Vive en residencia. Antecedentes de **HTA**, **DLF** y **FA** antiagregada. Ictus **POCI ACP** izquierda en 2008, etiología cardioembólica.

Mujer de 84 años sin **alergias medicamentosas conocidas**. Niega hábitos tóxicos. Parcialmente dependiente **adriamycin bleomycin vinblastine and dacarbazin**. Vive en residencia. Antecedentes de **hipertensión arterial, depresión a largo plazo** y **fibrilación auricular** antiagregada. Ictus **circulación posterior, arteria cerebral posterior** izquierda en 2008, etiología cardioembólica.

TC craneal urgente multimodal: No es visualitzzen signes hemorràgics aguts intra ni extraxials.

TC de control (24h post tratamiento fibrinolítico): Infart fronto-parieto-temporal dret establert, en territori d'ACM dreta, sense signes de transformació hemorràgica

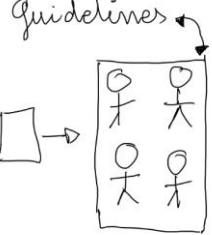
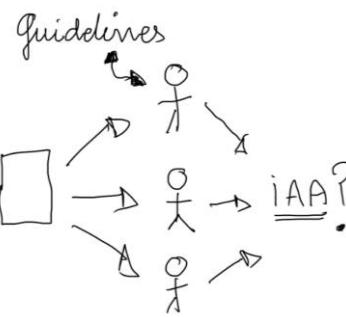
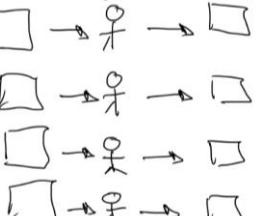
Fàcil masticació. 1º Plato sopa o pure.

Durante el ingreso en la unidad de ictus, presenta un empeoramiento neurológico, por lo que se realiza un TC craneal de control que evidencia una nueva lesión isquémica en ACP izquierda. También presenta una fibrilación auricular de debut, por lo que se decide iniciar tratamiento anticoagulante. Avui control INR (s'enviarà resultat a IAS).

AngioTC craneal (6.12.2017): Polígono de Willis normoconfigurado, sin imágenes de adicción ni defectos de replección. No se observan imágenes sugestivas de malformación vascular. Segmento V4 esquerre hipoplàstico.

Annotation task

Annotation task is difficult and needs good annotation guidelines, good protocols and a friendly annotation tool.

- 1 
- 2 
- 3 

[/joint_files/all/321459759.utf8](#)

28 Fibrilación auricular en tratamiento con **Tratamiento anticoagulante hab** sintrom.
 29 5.
 30 Vertigo posicional poroxístico benigno en tratamiento médico Intervenciones quirúrgicas: cataratas de ambos ojos.

SECCION SITUACION FUNCIONAL

31 Situacion basal: Indenpendiente para las ABVD, continente biesfinteriana.

mRankin_previa

32 Barthel: 85, mRS0

SECCION TRATAMIENTO HABITUAL **Tratamiento anticoagulante hab**

33 Tratamiento habitual: Serc 8 mg 1c/24h, **sintrom** según pauta, pravastatin

SECCION PROCESO ACTUAL

35 ENFERMEDAD ACTUAL:
 36 Paciente de 84 años el día 02/01/2017 a las 10:00am en la sala de espera de oftalmología inicia
 37 A su llegada a urgencias la paciente presenta afasia, hemiplejia derecha, babinski derecho y des

TAC_craneal

38 Se le realiza un TAC craneal simple que descarta lesiones expansivas o sangrado agudo, se realiza penumbra por lo que se envía al _SS_ para realizar embolectomía mecánica.

Trombectomía_mecánica

39 En el _SS_ se realiza microcateterismo selectivo de la arteria ocluida, logrando atravesar el trom

40 Se realiza extracción mecánica con sistema TREVO 6 X 25 y aspiración manual desde CAD sofia 5

41 Se da por concluido el procedimiento sin complicaciones a confirmarse en la arteriografía un c

TAC_craneal

42 Se realiza un TAC craneal posterior que muestra Hiperdensidad en región temporal anteromedial

43 Tras el procesado de las imágenes se evidencia que mayormente corresponde a contraste, identi

44 Hipodensidad con desdiferenciación corticosubcortical temporal posteromedial en relación con le

45 Se realiza translado a HUMT y se ingresa en Neurología para completar estudio.

SECCION EXPLORACION FISICA

EXPLORACIÓN FÍSICA:

New Annotation

Text: embolectomía mecánica

Search: Google, Wikipedia

Entity type

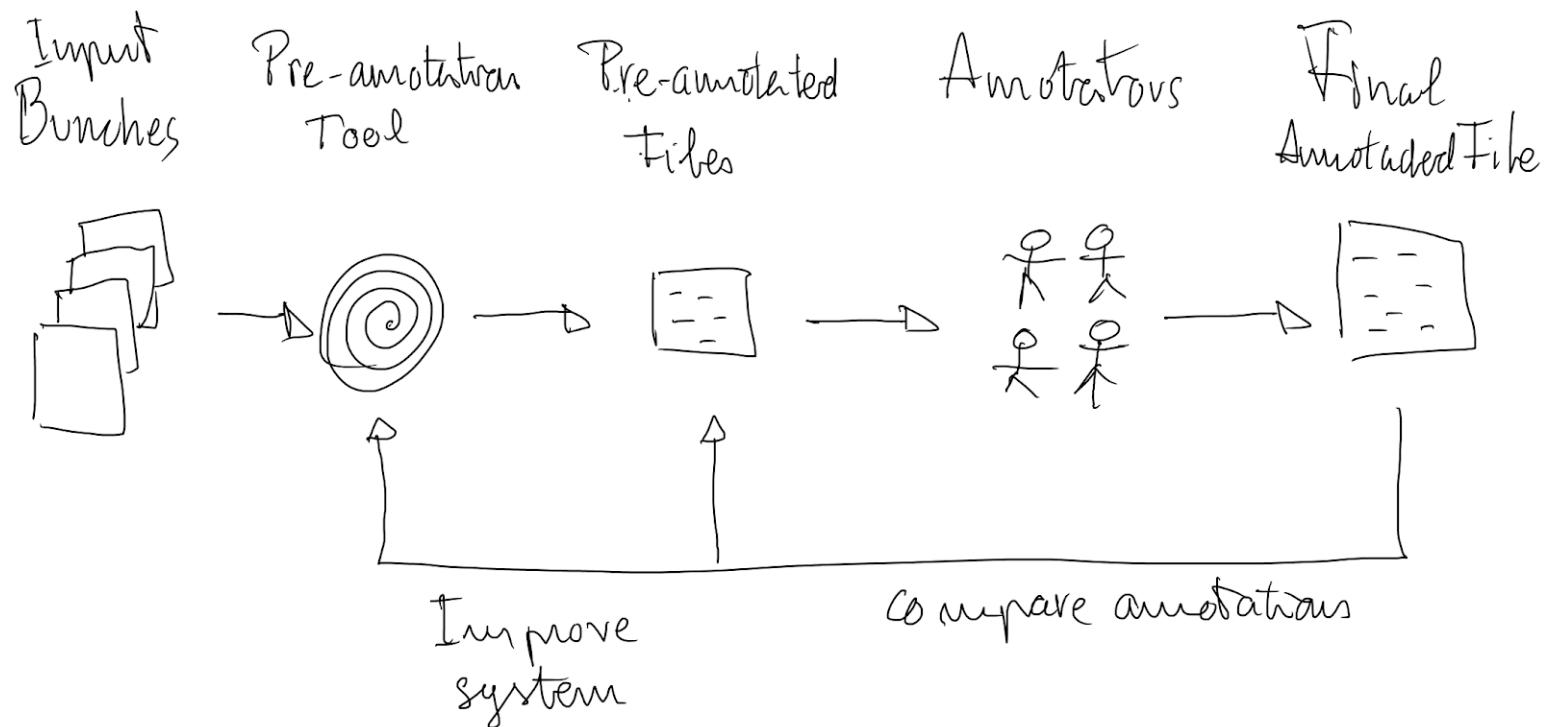
- DIAGNOSTICOS
- PROCEDIMIENTOS
 - Trombosis_intravenosa
 - Trombectomía_mecánica
 - Trombosis_intraarterial
 - TAC_craneal
 - Test_de_displasia
 - Recanalización
 - Pueraria
- TRATAMIENTOS
- ESCALAS
- TIEMPO
- HORAS
- SECCIONES

Notes

OK Cancel

(Pre-)annotation

To ease the task, an **automatic pre-annotation system** was developed in an **iterative way**, so that the process was split into different steps, each consisting of ~100 discharge reports. At each new bunch of annotated files, the system is evaluated against the human annotations and modified to improve its performance



(Pre-)annotation (evaluation)

Num examples	True positives	False positives	False negatives	Accuracy	Precision	Recall	F1
5710	5012	894	698	0.759	0.849	0.878	0.863

Global average results using the Test set

Language Modelling

3 We generated a **RoBERTa-base model** with 12 layers/heads and 768 hidden layer sizes for a total number of 126M parameters.

- We kept the original Roberta hyperparameter configuration and trained with a **masked language model** objective.
- The model was trained for 48 hours using 16 NVIDIA V100 GPUs of 16GB DDRAM.
- After training, we selected as the best model the checkpoint that achieved the lowest perplexity.

4 Then, we adapted the model to the clinical domain by **overtraining it** with 120MG of clinical textual data (including nearly 34MB of ICTUSnet data provided by AQuAS, Son Espases and IACS).

- We continued the training process for 48h more using the learning rate value reached by the best checkpoint trained on the biomedical corpora.

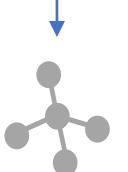
5 Finally, we **fine-tuned** our pre-trained models for NER task using the ICTUSnet Gold Standard dataset.

- The gold standard was split into train, dev and test sets with standard proportions: 80% for training (656 documents), 10% for valid (83 documents), 10% for test (83 documents).
- We fine-tuned for 10 epochs and selected the best epoch validating on the dev set.

3

Deep learning Language modelling

Large biomedical data set is used to generate a biomedical pre-trained language model.
(~6GB & ~1000M tokens)

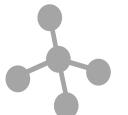


Biomedical language model

4

Deep learning Language modelling

Clinical textual data is used to retrain de biomedical model to adapt it to the clinical setting.
(120MB, almost half from ICTUSnet)



Clinical language model

5

Deep learning Fine tuning

The final model is fine tuned to a NER task using the Gold Standard.



NER application

Language Modelling

We collected a big **biomedical corpora** gathering from a variety of medical resources, namely scientific literature, clinical cases and crawled data.

We cleaned each corpus independently using a **cleaning pipeline** with customized operations designed to read data in different formats, split into sentences, detect the language, remove noisy and bad-formed sentences, ...

Finally we **deduplicate** and eventually output the data with their original document boundaries.

Corpus name	Text Size (GB)	Final size (GB)	Raw tokens	Cleaned tokens	Num. sentences
Clinical cases cardiology	0.0035	0,001	149,904.00	147,790.00	9,970.00
Clinical cases radiology	0.0066	0,001	177,366.00	170,997.00	9,948.00
libros_casos_clinicos	0.0083	0,007	1,137,555.00	1,024,797.00	68,833.00
Clinical cases COVID	0.0084	0,001	82,201.00	82,091.00	3,896.00
EMEA corpus	0.087	0,034	13,797,362.00	5,377,448.00	284,575.00
Patents	0.087	0,084	14,022,520.00	13,463,387.00	253,924.00
wikipedia_life_sciences	0.172	0,088	18,771,176.00	13,890,501.00	832,027.00
barr2_background	0.188	0,159	28,868,022.00	24,516,442.00	1,029,600.00
Pubmed	0.211	0,013	1,957,479.00	1,858,966.00	103,674.00
REEC (casos clínicos)	0.823	0,028	4,581,755.00	4,283,453.00	220,726.00
mespen_medline	1.2	0,38	6,864,901.00	4,166,077.00	322,619.00
pdfs_general	3.3		09,124,996.00	7,146,139.00	5,252,481.00
Scielo	3.891	0,631	61,837,972.00	60,007,289.00	2,668,231.00
Medical crawler	606	4,5	?	746,368,185.00	32,766,976.00
TOTAL	615.9858	5,927	261,373,209.00	972,503,562.00	43,827,480.00

Language Modelling

We used the resulting corpus to train a **RoBERTa-base model** with 12 layers/heads and 768 hidden layer sizes for a total number of 126M parameters.

- We kept the original Roberta hyperparameter configuration and trained with a **masked language model** objective.
- The model was trained for 48 hours using 16 NVIDIA V100 GPUs of 16GB DDRAM.
- After training, we selected as the best model the checkpoint that achieved the lowest perplexity.

Then, we adapted the model to the clinical domain by **overtraining it** with 120MG of clinical textual data (including nearly 1GB of ICTUSnet data provided by AQuAS, Son Espases and IACS).

- We continued the training process for 48h more.

Finally, we **fine-tuned** our pre-trained models for NER task using the ICTUSnet Gold Standard dataset.

- The gold standard was split into train, dev and test sets with standard proportions: 80% for training (656 documents), 10% for valid (83 documents), 10% for test (83 documents).
- We fine-tuned for 10 epochs and selected the best epoch validating on the dev set.

We used both, the Biomedical model and the Clinical model to generate and compare the predictions

Evaluation

Annotations are converted from **BRAT** standoff format to **BIO/IOB** (beginning, inside, outside) format.

- the prefix "B" in front of a Tag indicates the beginning of a chunk,
- an "I" indicates that we are still inside that chunk.
- the "O" tag is used to indicate that a token does not correspond to any of the entities to be tagged.

Given the high number of tokens with the class "O", we do not consider them when predictions and GS we have an O label

this avoids raising the result due to the fact that O is the majority class, i.e., that the vast majority of tokens do not belong to any of the entities.

In this example, only the grey rows are evaluated. (in red the wrong ones and in Green the good ones).

Once the lines with double O are removed, we evaluate the model using **accuracy**, **precision**, **recall** and **F1**

Accuracy: number of correct predictions / total number of predictions

Precision: true positives / predicted positives (how many selected items are relevant)

Recall: true positives / actual positives (how many relevant items are selected)

F1: (balance between precision and recall)

token	tag
Vive	O
con	O
su	O
esposa	O
,	O
independiente	O
para	O
ABVD	B-Antecedente
,	O
mRs	B-mRankin_previa
O	I-mRankin_previa
.	O

Evaluation

Annotations are converted from **BRAT** standoff format to **BIO/IOB** (beginning, inside, outside) format.

- the prefix "B" in front of a Tag indicates the beginning of a chunk,
- an "I" indicates that we are still inside that chunk.
- the "O" tag is used to indicate that a token does not correspond to any of the entities to be tagged.

Given the high number of tokens with the class "O", we do not consider them when predictions and GS we have an O label

this avoids raising the result due to the fact that O is the majority class, i.e., that the vast majority of tokens do not belong to any of the entities.

In this example, only the grey rows are evaluated. (in red the wrong ones and in Green the good ones).

Once the lines with double O are removed, we evaluate the model using **accuracy**, **precision**, **recall** and **F1**

Accuracy: number of correct predictions / total number of predictions

Precision: true positives / predicted positives (how many selected items are relevant)

Recall: true positives / actual positives (how many relevant items are selected)

F1: (balance between precision and recall)

tken	GS	prediction
Vive	O	O
con	O	O
su	O	O
esposa	O	O
,	O	O
independiente	O	O
para	O	O
ABVD	O	B-Antecedente
,	O	O
mRs	B-mRankin_previa	B-mRankin_previa
0	I-mRankin_previa	I-mRankin_previa
.	O	O

Evaluation

For time **variables** the evaluation is different. In this case, we have three components:

1. The textual evidence in text containing a time variable (text span)
2. The tag assigned (label)
3. The normalized time expression

When evaluating, we require that the predictions and the Gold standard

- for (2) and (3) above are equal, and
- there is some overlapping in (1) (textual evidences are long and ‘irrelevant’)

Examples:

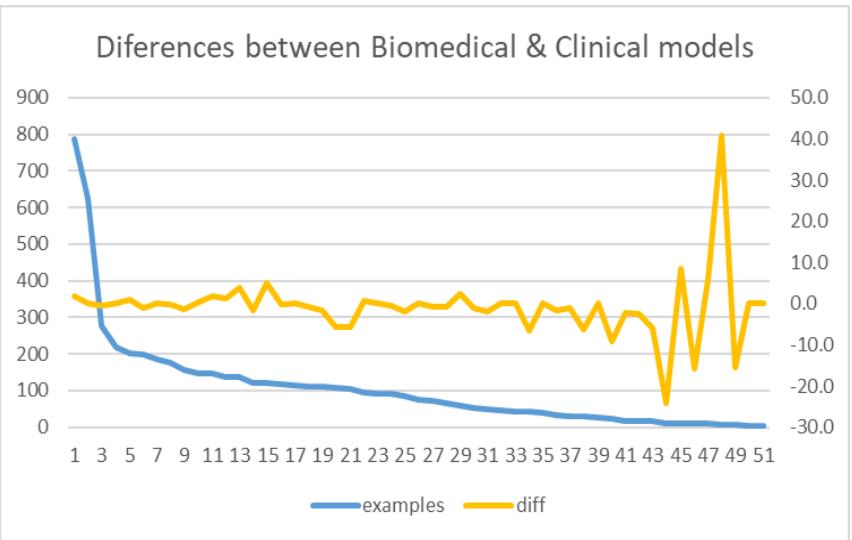
<p>I (23/02/17; <u>13:03h</u>) :</p> <p style="margin-top: 20px;">(23/02/17; <u>13:03h</u>) :</p>	<p>Hora_TAC</p> <p>Hora_primer_bolus_trombolisis_rtPA</p> <p>rTPA a las 13.33 h</p> <p>Trombolisis_intr rtPA a las 13.33 h</p>
---	--

Same tags, same normalized times, overlapping mentions (note the missing *h*), **OK**

Results

Model	Examples	Tp	Fp	Fn	Acc	Pre	Rec	F1
Biomedical	5455	5125	675	330	0.836	0.884	0.940	0.911
Clinical	5455	5104	638	351	0.838	0.889	0.936	0.912

Global average results comparing Biomedical and Clinical models



Differences between Biomedical and Clinical models.

Results

tag	examples	Biomedical	Clinical	diff
NIHSS	786	0.847	0.830	1.7
TAC_craneal	625	0.983	0.983	0.0
mRankin	275	0.961	0.966	-0.5
SECCION_EXPLORACIONES_COMPLEMENTARIAS	217	0.954	0.954	0.0
SECCION_MOTIVO_DE_INGRESO	203	0.983	0.974	0.9
SECCION_TRATAMIENTO_Y_RECOMENDACIONES_AL_ALTA	200	0.980	0.990	-1.0
SECCION_PROCESO_ACTUAL	185	0.981	0.981	0.0
SECCION_EXPLORACION_FISICA	177	0.969	0.972	-0.3
SECCION_TRATAMIENTO_HABITUAL	155	0.937	0.950	-1.3
SECCION_EVOLUCION	147	0.964	0.961	0.3
Trombolisis_intravenosa	146	0.925	0.906	1.9
SECCION_ANTECEDENTES	137	0.974	0.962	1.2
SECCION_EXPLORACION_FISICA_DURANTE_HOSPITALIZACION	136	0.842	0.803	3.9
Trombectomia_mecanica	122	0.799	0.816	-1.7
SECCION_EXPLORACION_FISICA_EN_URGENCIAS	121	0.886	0.836	5.0
Ictus_isquemico	117	0.895	0.896	-0.1
SECCION_DESTINO_AL_ALTA	113	0.968	0.968	0.0
Etiologia	110	0.854	0.861	-0.7
SECCION_DIAGNOSTICOS	110	0.943	0.960	-1.7
ASPECTS	107	0.811	0.869	-5.8
SECCION_EXPLORACIONES_COMPLEMENTARIAS_EN_PLANTA_DE_NEUROLOGIA	104	0.755	0.813	-5.8
Tratamiento_antagregante	93	0.882	0.875	0.7
SECCION_ANTECEDENTES_PATOLOGICOS	91	0.937	0.937	0.0
SECCION_TRATAMIENTO_AL_ALTA	91	0.941	0.945	-0.4
Tratamiento_anticoagulante	86	0.667	0.687	-2.0
SECCION_EXPLORACIONES_COMPLEMENTARIAS_EN_URGENCIAS	75	0.938	0.938	0.0
SECCION_SITUACION_FUNCIONAL	72	0.966	0.973	-0.7
Arteria_afectada	64	0.756	0.764	-0.8
Lateralizacion	59	0.875	0.850	2.5
SECCION_TIPO_DE_INGRESO	53	0.981	0.991	-1.0
SECCION_PROCEDIMIENTOS	50	0.961	0.980	-1.9
SECCION_EXPLORACION_FISICA_AL_ALTA	46	0.893	0.893	0.0
SECCION_ANTECEDENTES_PERSONALES	42	0.988	0.988	0.0
SECCION_RECOMENDACIONES	42	0.864	0.930	-6.6
SECCION_MOTIVO_DEL_ALTA	40	1.000	1.000	0.0
SECCION_ANTECEDENTES_QUIRURGICOS	32	0.853	0.870	-1.7
Localizacion	31	0.703	0.714	-1.1
SECCION_CONTROL	31	0.921	0.984	-6.3
Test_de_disfagia	27	1.000	1.000	0.0
Hora_TAC	22	0.750	0.842	-9.2
Tiempo_puerta_aguja	18	0.955	0.978	-2.3
Hora_primer_bolus_trombolisis_rtPA	18	0.895	0.919	-2.4
Hemorragia_cerebral	17	0.684	0.743	-5.9
Hora_recanalizacion	10	0.667	0.909	-24.2
SECCION_ANTECEDENTES_FAMILIARES	10	0.909	0.824	8.5
SECCION_DIAGNOSTICO_PRINCIPAL	9	0.842	1.000	-15.8
Hora_inicio_trombectomia	9	1.000	0.941	5.9
SECCION_DIAGNOSTICOS_SECUNDARIOS	8	0.941	0.533	40.8
Ataque_isquemico_transitorio	6	0.615	0.769	-15.4
Hora_primera_serie_trombectomia	5	0.600	0.600	0.0
Hora_fin_trombectomia	5	1.000	1.000	0.0
ALL	5455	0.911	0.912	-0.097

Conclusions

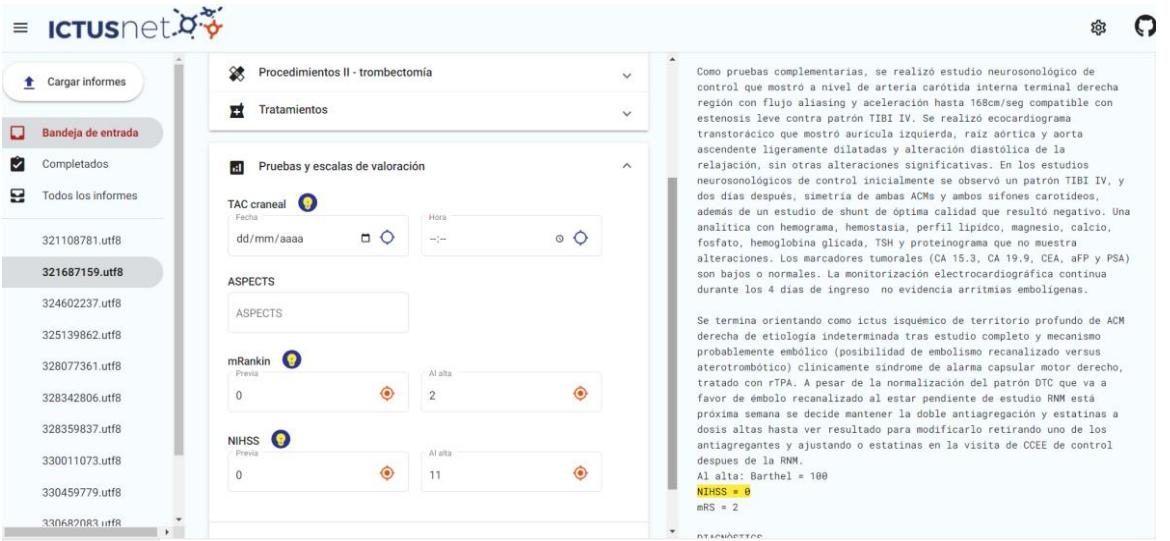
- The information extraction task was complex and ambitious, with 51 different types of variables.
- In most cases, the variables are '**context-dependent**', which adds an extra difficulty of the task.
- Temporal variables** are a case apart: in most cases the textual evidence shows an enormous variety. Such is the variety that, for the pre-annotation tool, we decided not to address the coding of these variables and limited ourselves to coding dates and times without going any further.
- The model managed to learn complex aspects such as the '**context sensitivity**' (this is very clear in the diagnostic variables, for example).
- The model managed to successfully learn the **complex temporal variables** that we had given up in the rule based system.

Time variable	Examples	Biomedical	Clinical
Hora_TAC	22	0.750	0.842
Tiempo_puerta_aguja	18	0.955	0.978
Hora_primer_bolus_trombolisis_rtPA	18	0.895	0.919
Hora_recanalizacion	10	0.667	0.909
Hora_inicio_trombectomia	9	1.000	0.941
Hora_primera_serie_trombectomia	5	0.600	0.600
Hora_fin_trombectomia	5	1.000	1.000

Conclusions

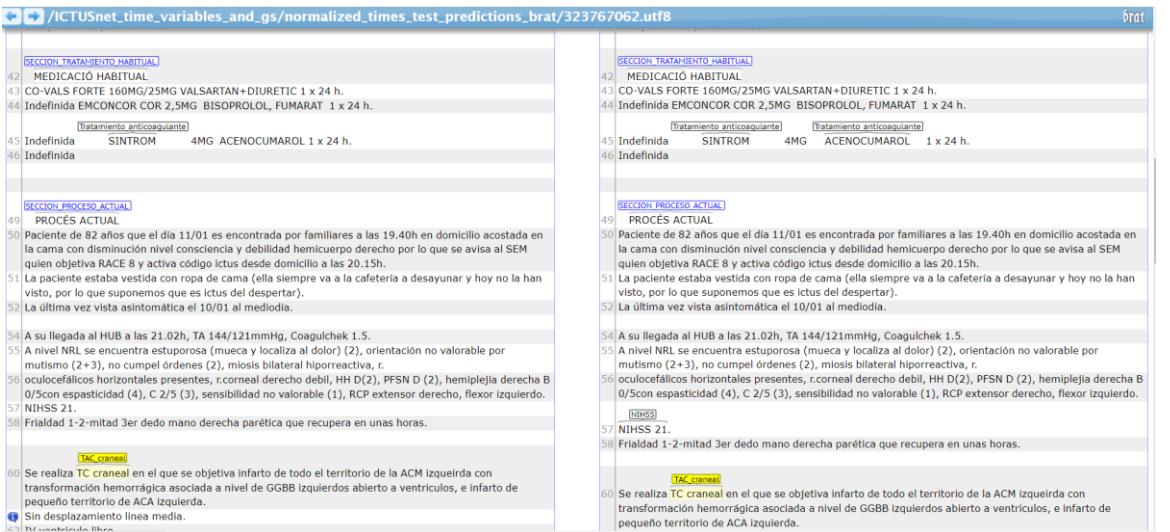
- We did not demonstrate that retraining with clinical data improves the model. We believe that
 - (i) more clinical data (from the stroke domain) could have improved the system,
 - (ii) mixing data from the very beginning would have positive effect, we are working on this
- **The results of the deep learning models are pretty good, reaching 91% F1 on average.** That is without applying any other (post)-process for system improvement. In this exercise we just wanted to evaluate the performance of deep learning techniques.
- **The results obtained demonstrate that the use of language technologies can be of great help in clinical information extraction tasks, as in the case of ICTUSnet.**

Demo & prototype



The screenshot shows a web-based medical record system. On the left, a sidebar lists recent documents: 321108781.utf8, 321687159.utf8, 324602237.utf8, 325139862.utf8, 328077361.utf8, 328342806.utf8, 328359837.utf8, 330011073.utf8, 330459779.utf8, and 330682083.utf8. The main content area is titled 'Procedimientos II - trombectomía'. It includes sections for 'Tratamientos' (Treatments) and 'Pruebas y escalas de valoración' (Tests and scales). Under treatments, there are fields for 'TAC craneal' (Brain CT), 'ASPECTS', 'mRankin', and 'NIHSS'. The 'NIHSS' section shows a score of 11. To the right, a large text box contains clinical notes about the patient's condition, mentioning stroke symptoms, imaging findings, and treatment plans. It also includes a table for 'mRS' (modified Rankin Scale) scores.

<http://temu.bsc.es:81/>



The screenshot displays the raw XML representation of the medical record. The XML is organized into sections such as 'SECCION TRATAMIENTO HABITUAL' (Treatment History) and 'SECCION PROCES ACTUAL' (Current Process). Within these sections, specific treatments like 'CO-VALS FORTE 160MG/25MG VALSARTAN+DIURETIC 1 x 24 h.' and 'Indefinida EMCONCOR COR 2,5MG BISOPROLOL, FUMARAT 1 x 24 h.' are listed. The XML also includes detailed descriptions of the patient's condition, including vital signs (TA 144/121mmHg, Coagulchek 1.5), physical examination findings (RACE 8, NIHSS 21), and imaging results (TAC craneal findings). The XML uses various tags like 'tratamiento', 'medicacion', 'proces', and 'seguimiento' to categorize the data.

https://temu.bsc.es/ICTUSnet/diff.xhtml?dif=f=%2FICTUSnet_time_variables_and_gs%2Ftest_brat_gs%2F#/ICTUSnet_time_variables_and_gs/normalized_times_test_predictions_brat/323767062.utf8

#ICTUSnetBCN2020



THANK YOU