

# Modelos para la detección anticipada de riesgos en flujos de datos

**Juan Martín Loyola**  
**Marcelo Errecalde**



Universidad  
Nacional de  
San Luis

# Temas a tratar

- Clasificación anticipada de texto
- Detección anticipada de riesgos
- Modelos para detección anticipada de riesgo



[https://jmloyola.github.io/files/talks/2021\\_encuentro\\_posgrado.pdf](https://jmloyola.github.io/files/talks/2021_encuentro_posgrado.pdf)

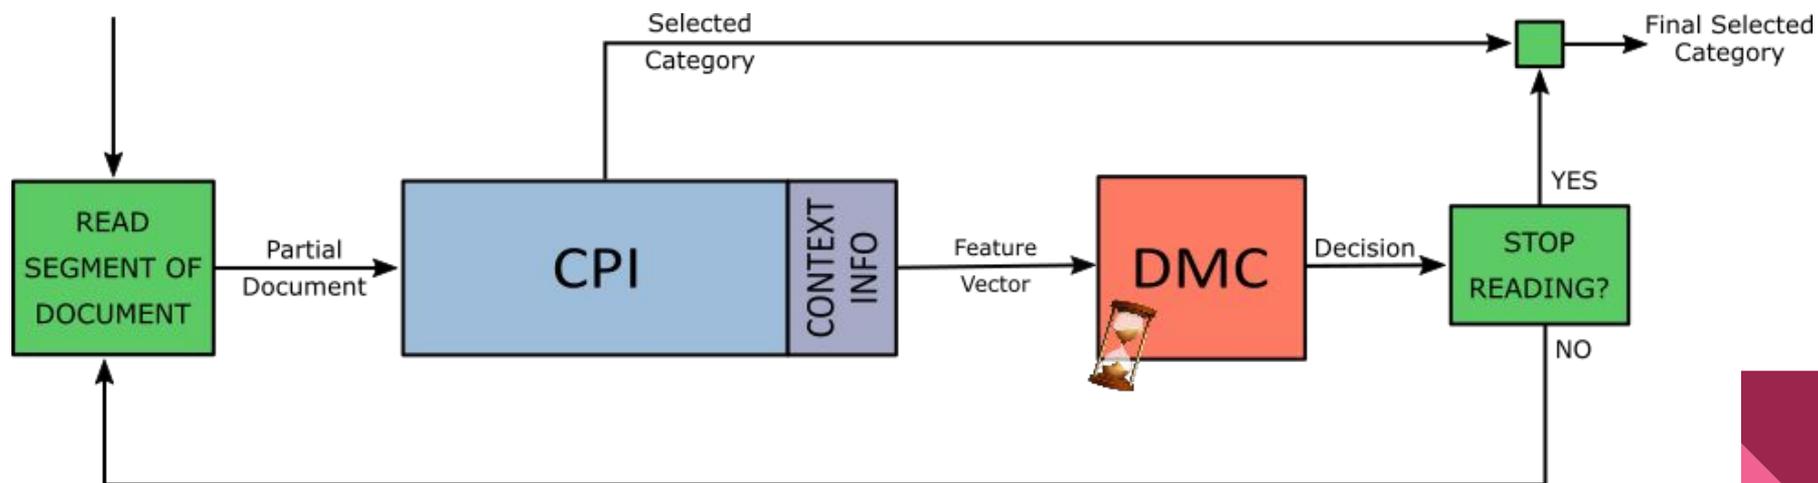
# Clasificación anticipada de texto

- Desarrollo de modelos predictivos que determinen la categoría de un documento lo antes posible.
- Encontrar equilibrio entre:
  - precisión de la clasificación;
  - tiempo necesario para clasificar.
- Se puede conceptualizar en dos partes:
  - Clasificación con Información Parcial (CPI);
  - Decisión del Momento de Clasificación (DMC).

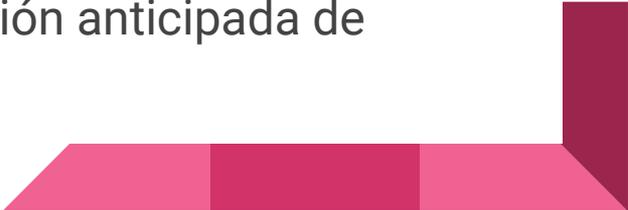


# Clasificación anticipada de texto

- CPI → Clasificación con Información Parcial
- DMC → Decisión del Momento de Clasificación

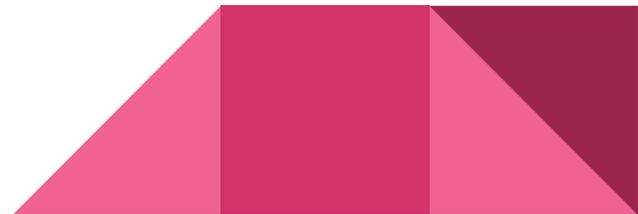


# Detección anticipada de riesgo

- Caso especial de la clasificación anticipada de texto.
  - Sólo nos preocupa predecir lo antes posible un subconjunto de las categorías (categoría de riesgo).
  - Si la entrada parcial actual se clasifica como clase sin riesgo, el modelo sigue acumulando información en caso de que, en el futuro, el usuario comience a mostrar patrones de riesgo.
  - Es fundamental recuperar a tantos usuarios en riesgo como sea posible ya que sus vidas podrían estar en peligro.
  - Ejemplos: detección anticipada de depresión, detección anticipada de pedófilos.
- 

# Medidas de desempeño

- Precisión, exhaustividad (recall), medida F1



# Medidas de desempeño

- Precisión, exhaustividad (recall), medida F1
- ERDE
- F latency



# ERDE (error de detección de riesgo temprano)

$$ERDE_o(d, k) = \begin{cases} c_{fp} & \text{if } d=\text{positive AND ground truth}=\text{negative (FP)} \\ c_{fn} & \text{if } d=\text{negative AND ground truth}=\text{positive (FN)} \\ lc_o(k) \cdot c_{tp} & \text{if } d=\text{positive AND ground truth}=\text{positive (TP)} \\ 0 & \text{if } d=\text{negative AND ground truth}=\text{negative (TN)} \end{cases}$$

$$lc_o(k) = 1 - \frac{1}{1 + e^{k-o}}$$

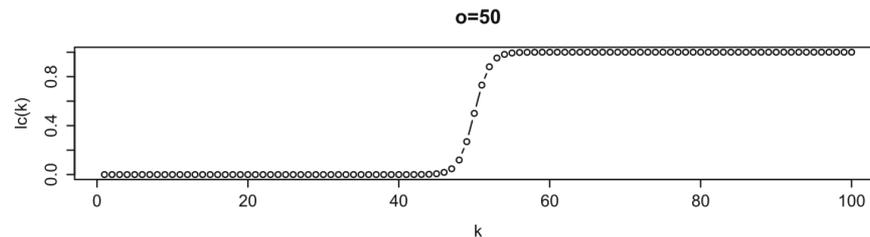
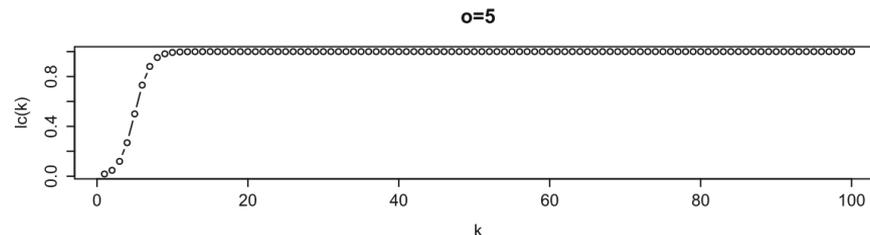


Fig. 1. Latency cost functions:  $lc_5(k)$  and  $lc_{50}(k)$



## ERDE (error de detección de riesgo temprano)

$$ERDE_o(d, k) = \begin{cases} c_{fp} & \text{if } d=\text{positive AND ground truth}=\text{negative (FP)} \\ c_{fn} & \text{if } d=\text{negative AND ground truth}=\text{positive (FN)} \\ lc_o(k) \cdot c_{tp} & \text{if } d=\text{positive AND ground truth}=\text{positive (TP)} \\ 0 & \text{if } d=\text{negative AND ground truth}=\text{negative (TN)} \end{cases}$$



## ERDE (error de detección de riesgo temprano)

$$ERDE_{\theta}(d, k) = \begin{cases} c_{fp} & \text{if } d=\text{positive AND ground truth}=\text{negative (FP)} \\ c_{fn} & \text{if } d=\text{negative AND ground truth}=\text{positive (FN)} \\ lc_{\theta}(k) \cdot c_{tp} & \text{if } d=\text{positive AND ground truth}=\text{positive (TP)} \\ 0 & \text{if } d=\text{negative AND ground truth}=\text{negative (TN)} \end{cases}$$

Umbral de penalización



# ERDE (error de detección de riesgo temprano)

$$ERDE_o(d, k) = \begin{cases} c_{fp} & \text{if } d=\text{positive AND ground truth}=\text{negative (FP)} \\ c_{fn} & \text{if } d=\text{negative AND ground truth}=\text{positive (FN)} \\ lc_o(k) \cdot c_{tp} & \text{if } d=\text{positive AND ground truth}=\text{positive (TP)} \\ 0 & \text{if } d=\text{negative AND ground truth}=\text{negative (TN)} \end{cases}$$



Categoría predicha para el usuario



# ERDE (error de detección de riesgo temprano)

$$ERDE_o(d, k) = \begin{cases} c_{fp} & \text{if } d=\text{positive AND ground truth}=\text{negative (FP)} \\ c_{fn} & \text{if } d=\text{negative AND ground truth}=\text{positive (FN)} \\ lc_o(k) \cdot c_{tp} & \text{if } d=\text{positive AND ground truth}=\text{positive (TP)} \\ 0 & \text{if } d=\text{negative AND ground truth}=\text{negative (TN)} \end{cases}$$

Cantidad de posts leídos del usuario



# ERDE (error de detección de riesgo temprano)

$$ERDE_o(d, k) = \begin{cases} c_{fp} & \text{if } d=\text{positive AND ground truth}=\text{negative (FP)} \\ c_{fn} & \text{if } d=\text{negative AND ground truth}=\text{positive (FN)} \\ lc_o(k) \cdot c_{tp} & \text{if } d=\text{positive AND ground truth}=\text{positive (TP)} \\ 0 & \text{if } d=\text{negative AND ground truth}=\text{negative (TN)} \end{cases}$$

Costo falsos positivos

$(\#positivos) / (\#positivos + \#negativos)$



# ERDE (error de detección de riesgo temprano)

$$ERDE_o(d, k) = \begin{cases} c_{fp} & \text{if } d=\text{positive AND ground truth}=\text{negative (FP)} \\ c_{fn} & \text{if } d=\text{negative AND ground truth}=\text{positive (FN)} \\ lc_o(k) \cdot c_{tp} & \text{if } d=\text{positive AND ground truth}=\text{positive (TP)} \\ 0 & \text{if } d=\text{negative AND ground truth}=\text{negative (TN)} \end{cases}$$

Costo falsos negativos

Costo verdaderos positivos

1



# ERDE (error de detección de riesgo temprano)

$$ERDE_o(d, k) = \begin{cases} c_{fp} & \text{if } d=\text{positive AND ground truth}=\text{negative (FP)} \\ c_{fn} & \text{if } d=\text{negative AND ground truth}=\text{positive (FN)} \\ lc_o(k) \cdot c_{tp} & \text{if } d=\text{positive AND ground truth}=\text{positive (TP)} \\ 0 & \text{if } d=\text{negative AND ground truth}=\text{negative (TN)} \end{cases}$$

Penalización por demora



# ERDE (error de detección de riesgo temprano)

$$ERDE_o(d, k) = \begin{cases} c_{fp} & \text{if } d=\text{positive AND ground truth}=\text{negative (FP)} \\ c_{fn} & \text{if } d=\text{negative AND ground truth}=\text{positive (FN)} \\ \underbrace{lc_o(k)}_{\text{red circle}} \cdot c_{tp} & \text{if } d=\text{positive AND ground truth}=\text{positive (TP)} \\ 0 & \text{if } d=\text{negative AND ground truth}=\text{negative (TN)} \end{cases}$$



$$lc_o(k) = 1 - \frac{1}{1 + e^{k-o}}$$

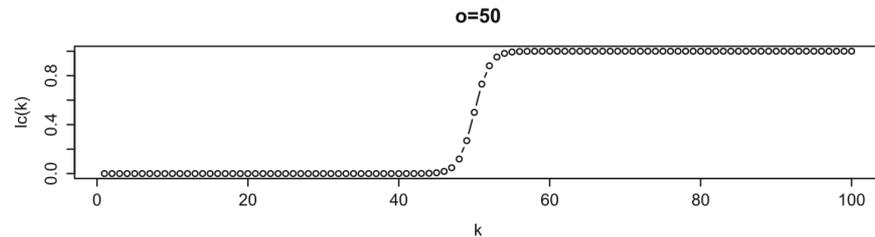
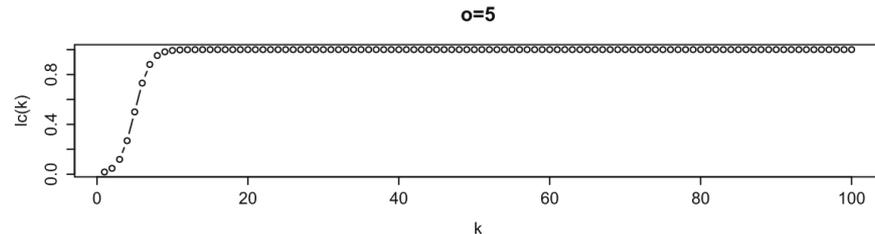
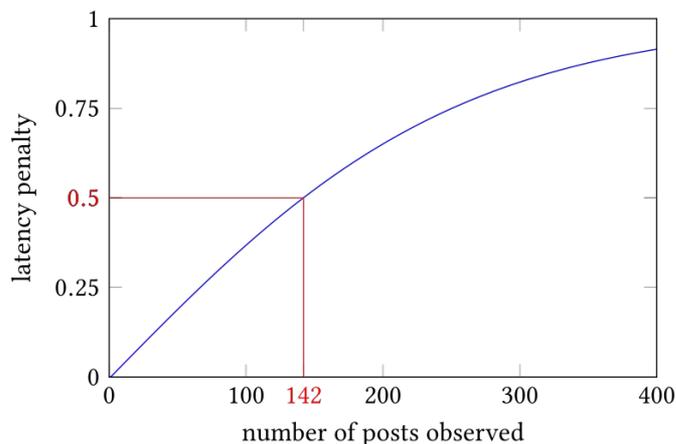


Fig. 1. Latency cost functions:  $lc_5(k)$  and  $lc_{50}(k)$

# F latency

$$F_{latency} = F \cdot speed$$

$$speed = (1 - \text{median}\{penalty(k_u) : u \in U, d_u = g_u = 1\})$$



$$penalty(k_u) = -1 + \frac{2}{1 + \exp^{-p \cdot (k_u - 1)}}$$



# F latency

$$F_{latency} = F \cdot speed$$



# F latency

$$F_{latency} = \overset{\circ}{F} \cdot speed$$

Medida F1



## F latency

$$F_{latency} = F \cdot \textit{speed}$$



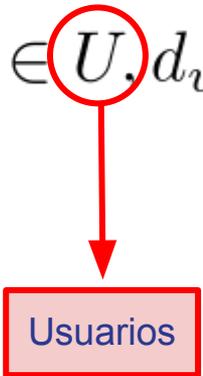
$$\textit{speed} = (1 - \text{median}\{\textit{penalty}(k_u) : u \in U, d_u = g_u = 1\})$$



## F latency

$$F_{latency} = F \cdot speed$$

$$speed = (1 - \text{median}\{penalty(k_u) : u \in U, d_u = g_u = 1\})$$



Usuarios



# F latency

$$F_{latency} = F \cdot speed$$

$$speed = (1 - \text{median}\{penalty(k_u) : u \in U, d_u = g_u = 1\})$$

Verdadera categoría del usuario  $u$

Categoría predicha para el usuario  $u$



## F latency

$$F_{latency} = F \cdot speed$$

$$speed = (1 - \text{median}\{penalty(k_u) : u \in U, d_u = g_u = 1\})$$



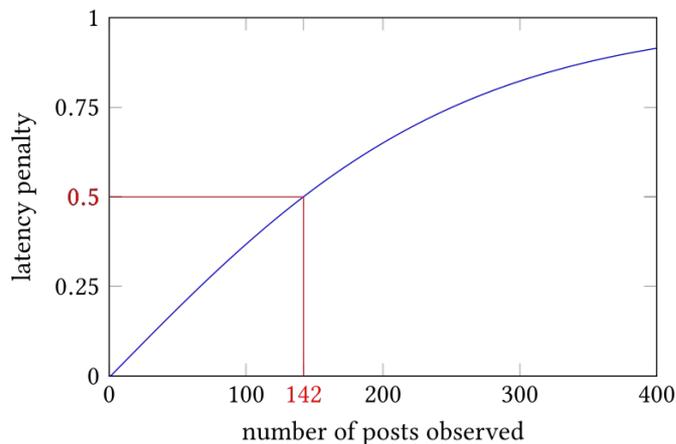
Cantidad de posts leídos del usuario  $u$



# F latency

$$F_{latency} = F \cdot speed$$

$$speed = (1 - \text{median}\{penalty(k_u) : u \in U, d_u = g_u = 1\})$$



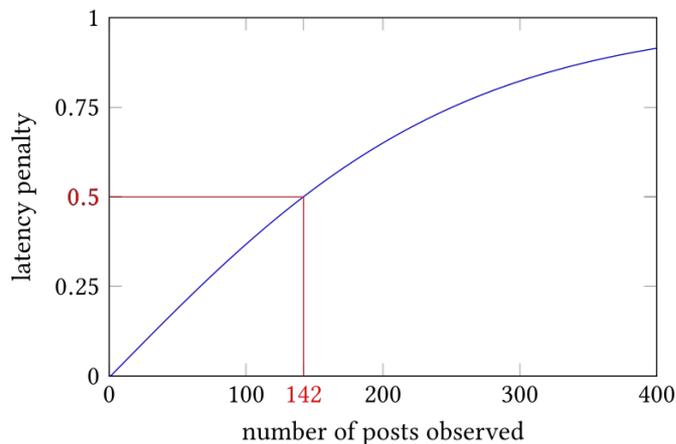
$$penalty(k_u) = -1 + \frac{2}{1 + \exp^{-p \cdot (k_u - 1)}}$$



# F latency

$$F_{latency} = F \cdot speed$$

$$speed = (1 - \text{median}\{penalty(k_u) : u \in U, d_u = g_u = 1\})$$



El valor de  $p$  se elige de forma tal que la penalidad sea 0,5 para la mediana de cantidad de posts

$$penalty(k_u) = -1 + \frac{2}{1 + \exp(-p \cdot (k_u - 1))}$$

# Modelos para detección anticipada de riesgo

- EarlyModel
- SS3
- EARLIEST

## UNSL at eRisk 2021: A Comparison of Three Early Alert Policies for Early Risk Detection

Juan Martín Loyola<sup>1,3</sup>, Sergio Burdisso<sup>1,2</sup>, Horacio Thompson<sup>1,2</sup>, Leticia Cagnina<sup>1,2</sup>  
and Marcelo Errecalde<sup>1</sup>

<sup>1</sup>Universidad Nacional de San Luis (UNSL), Ejército de Los Andes 950, San Luis, C.P. 5700, Argentina

<sup>2</sup>Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)

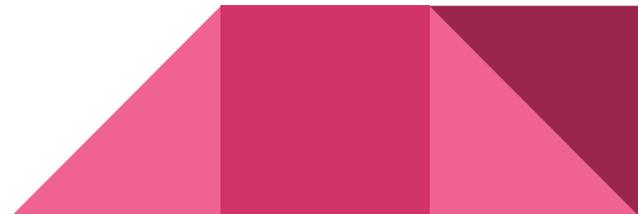
<sup>3</sup>Instituto de Matemática Aplicada San Luis (IMASL), CONICET-UNSL, Av. Italia 1556, San Luis, C.P. 5700, Argentina



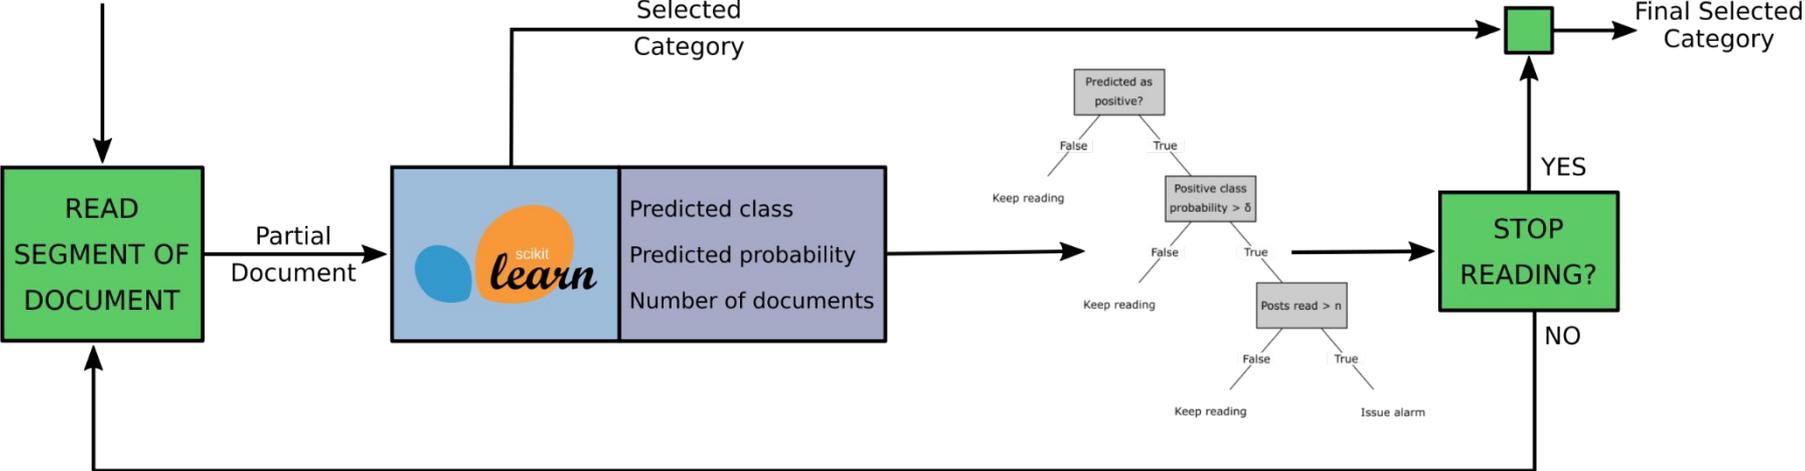
# Modelos para detección anticipada de riesgo

Para cada modelo se puede identificar:

- Representación de la entrada
- Modelo de clasificación con información parcial (CPI)
- Política de alerta temprana (DMC)



# EarlyModel





# EarlyModel

Representación de la entrada:

- Bolsa de palabras
- Linguistic Inquiry and Word Count (LIWC)
- Latent Dirichlet Allocation (LDA)
- Latent Semantic Analysis (LSA)
- doc2vec





# EarlyModel

Modelo de clasificación con información parcial:

- Árboles de decisión
- K-Vecinos más cercanos
- Máquinas de vectores de soporte (SVM)
- Regresión logística
- Perceptrón multicapa (MLP)
- Random forests
- LSTM
- BERT



 PyTorch

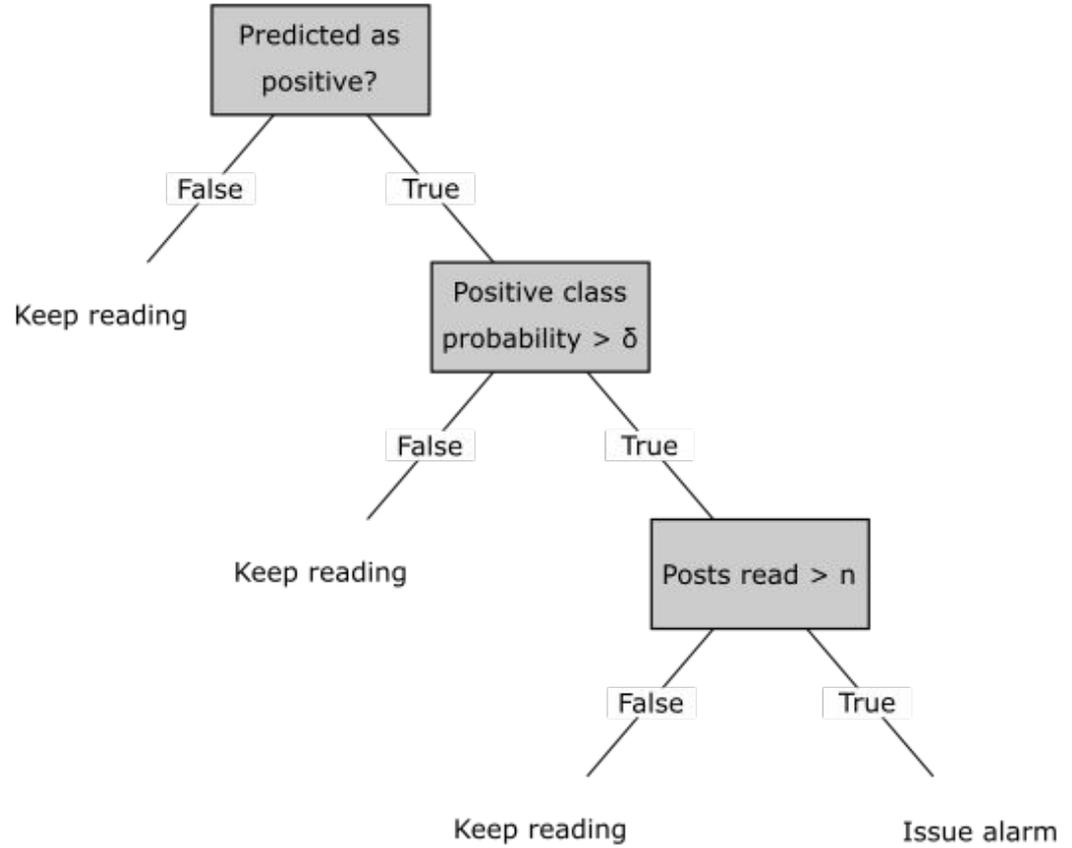
 **Transformers**





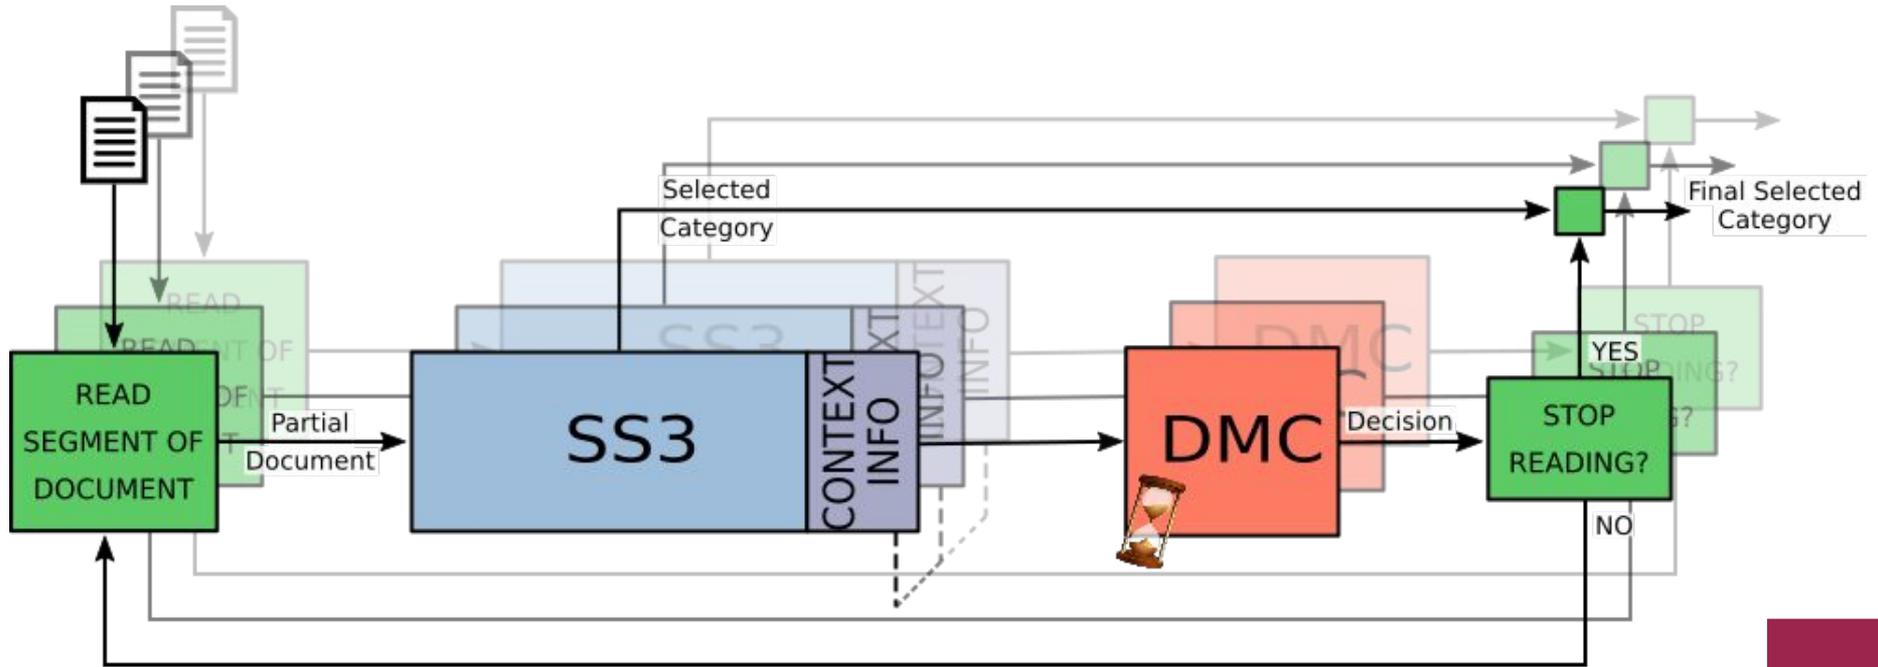
# EarlyModel

Política de alerta temprana:

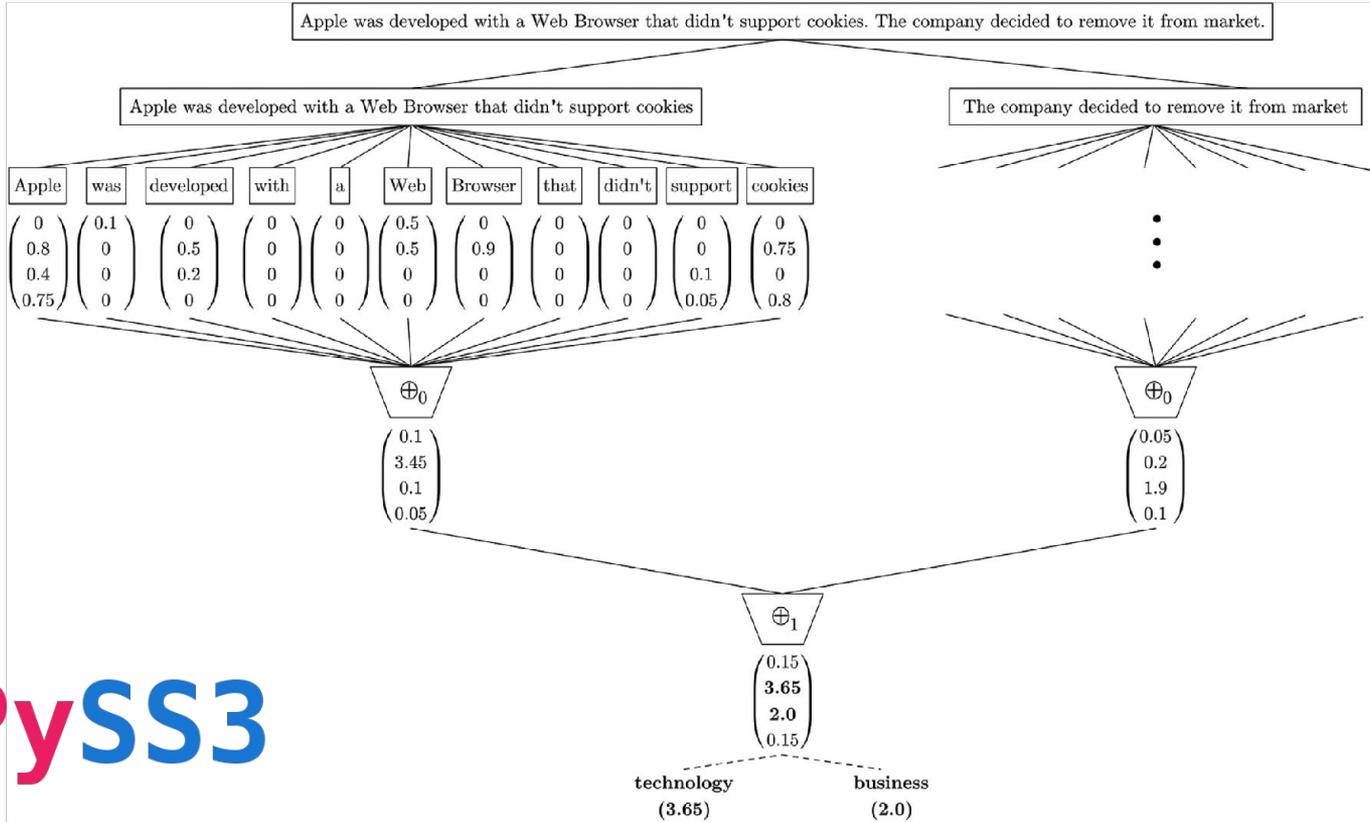




# SS3

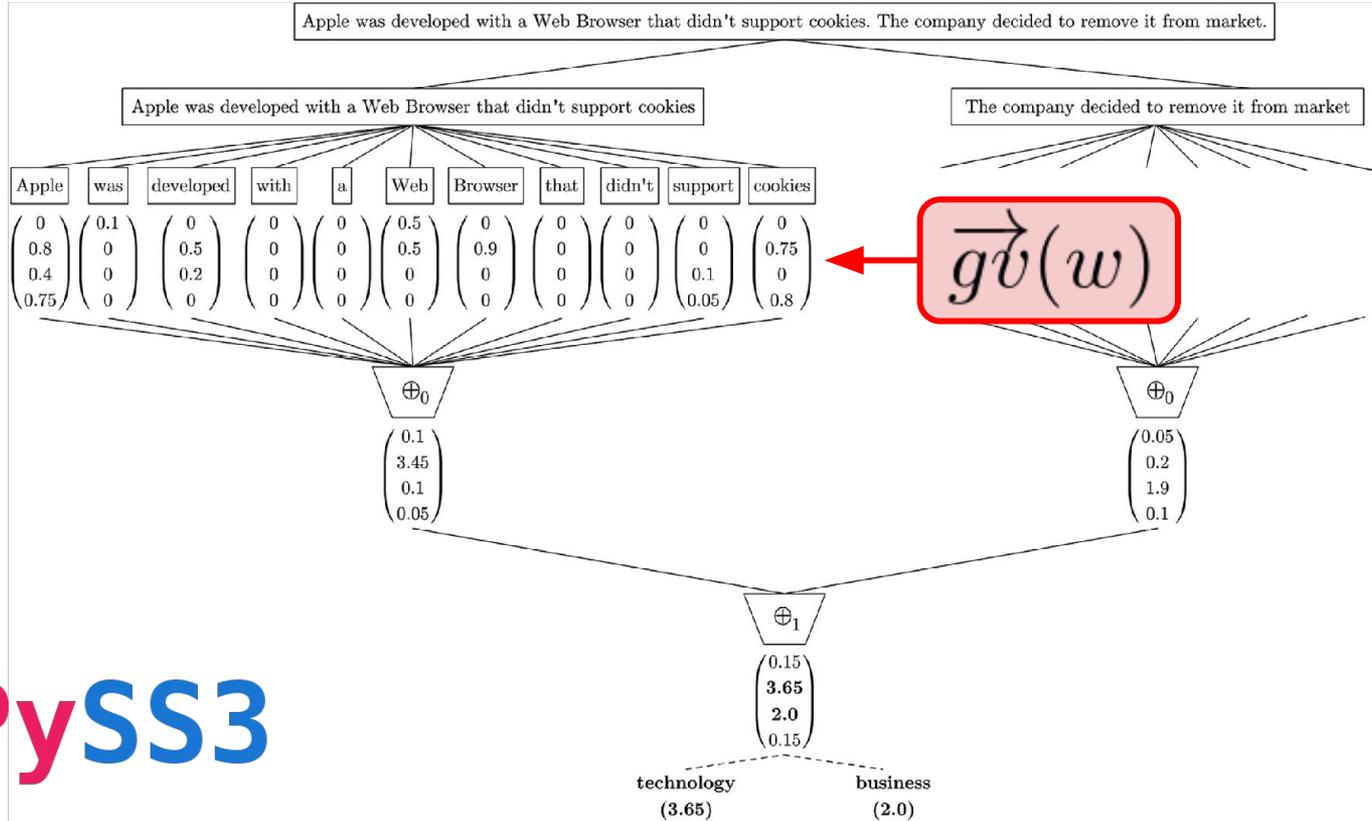


# SS3



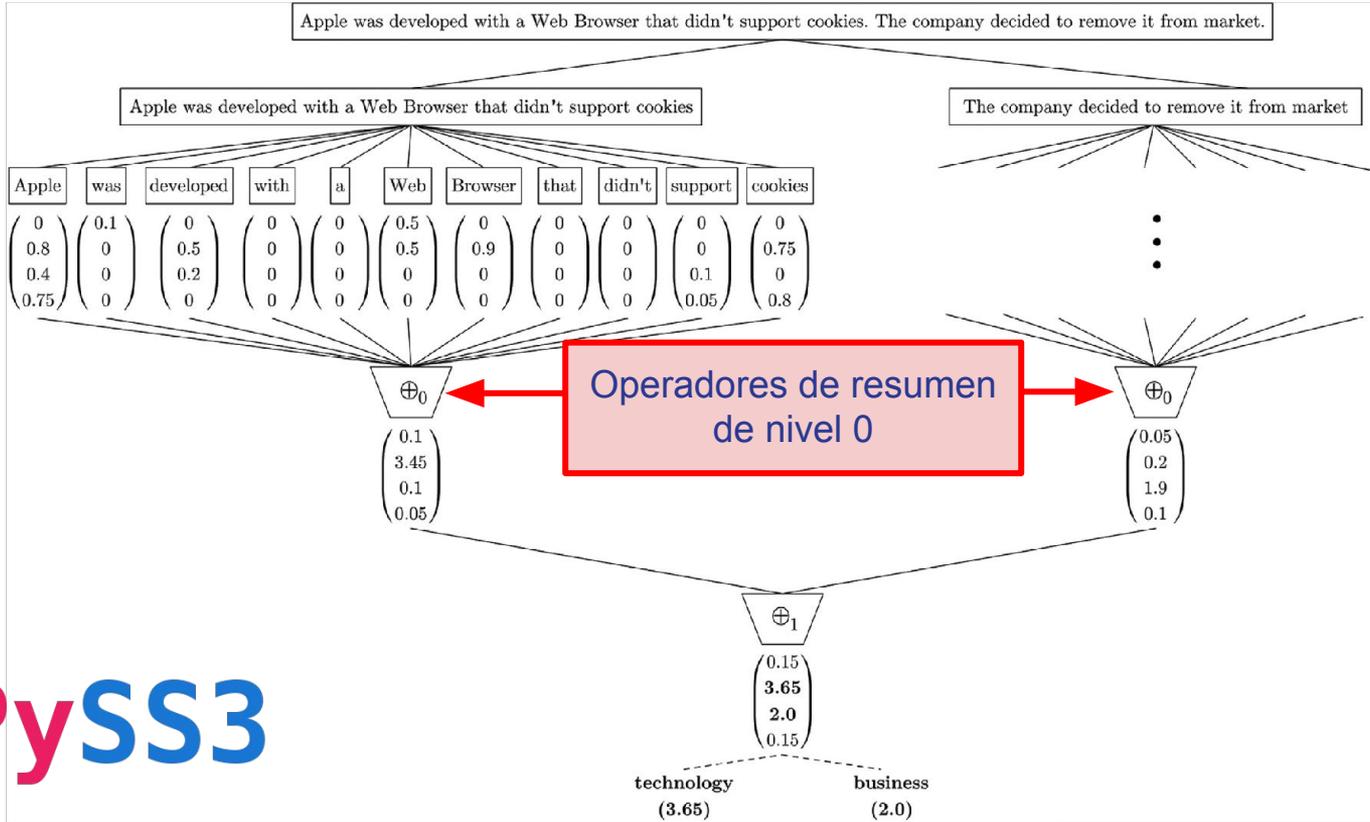


# SS3



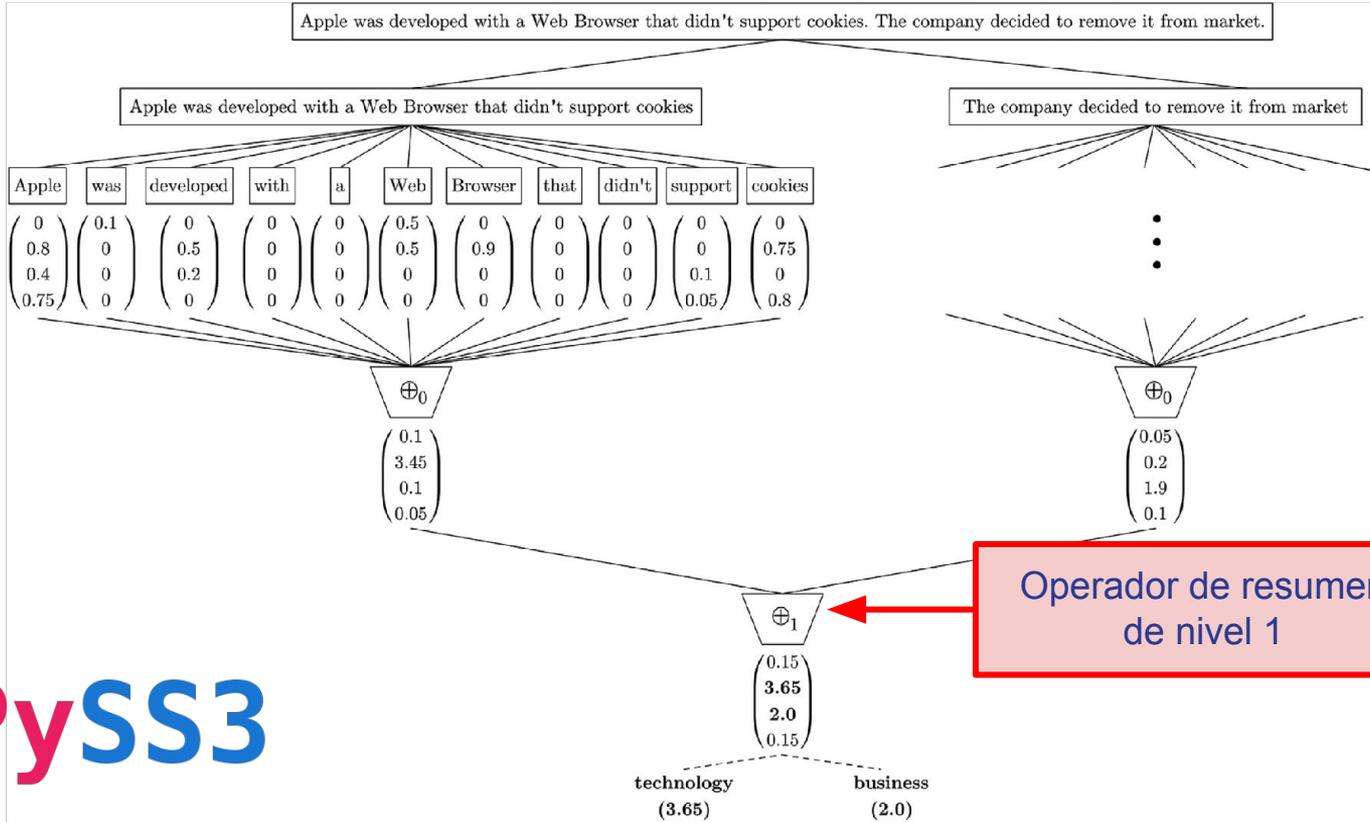


# SS3



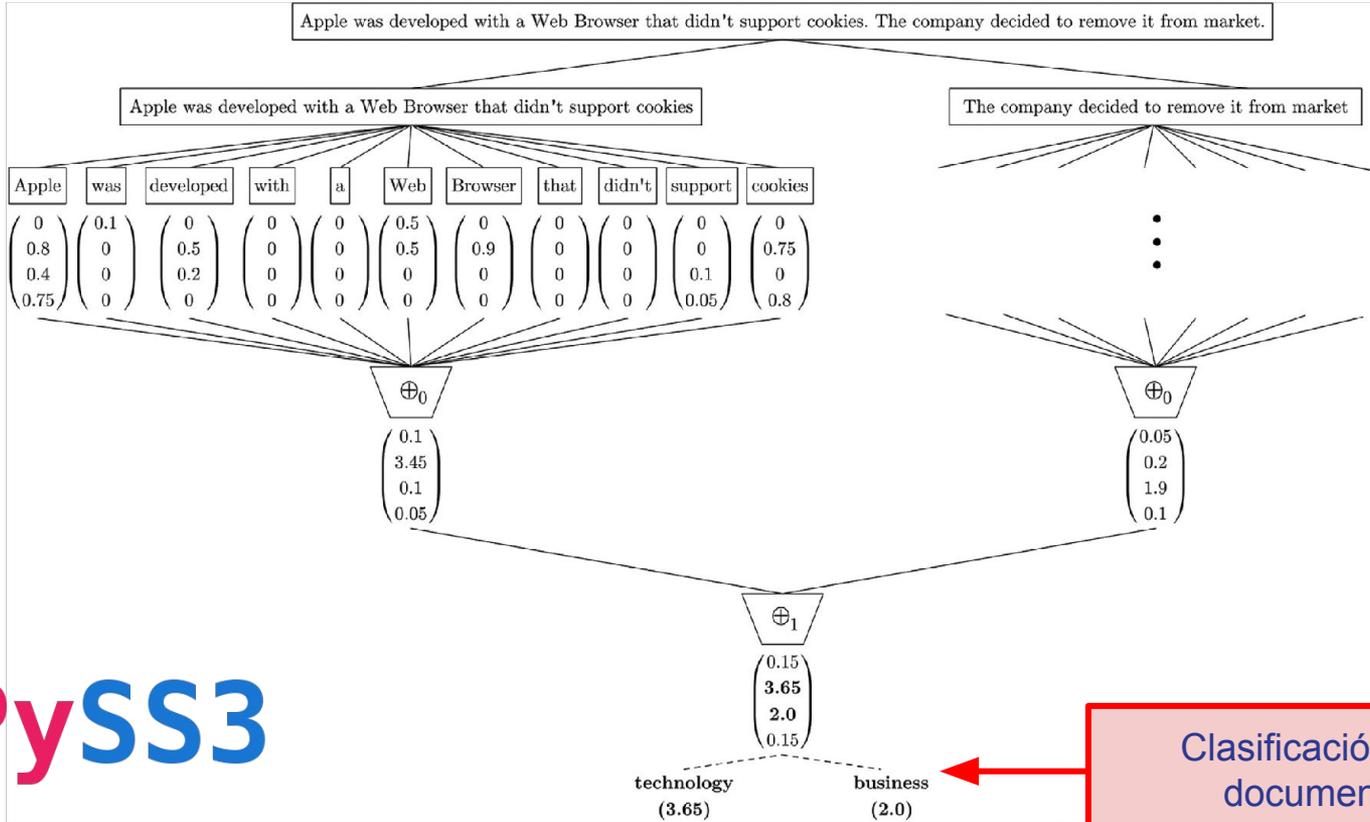


# SS3





# SS3

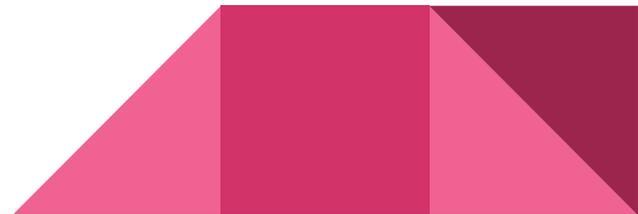




## SS3

Política de alerta temprana:

$$decision_u = \begin{cases} 1, & \text{if } score_u > \text{median}(scores) + \gamma \cdot \text{MAD}(scores) \\ 0, & \text{otherwise.} \end{cases}$$





# SS3

Política de alerta temprana:

$$decision_u = \begin{cases} 1, & \text{if } \underline{score_u} > \text{median}(scores) + \gamma \cdot \text{MAD}(scores) \\ 0, & \text{otherwise.} \end{cases}$$



Puntaje clase riesgo  
-  
Puntaje clase no riesgo






# SS3

Política de alerta temprana:

$$decision_u = \begin{cases} 1, & \text{if } score_u > \text{median}(scores) + \gamma \cdot \text{MAD}(scores) \\ 0, & \text{otherwise.} \end{cases}$$

$scores = \{score_u | u \in \text{Users}\}$





# SS3

Política de alerta temprana:

$$decision_u = \begin{cases} 1, & \text{if } score_u > \text{median}(scores) + \gamma \cdot \text{MAD}(scores) \\ 0, & \text{otherwise.} \end{cases}$$



Mediana de la  
desviación absoluta





# SS3

Política de alerta temprana:

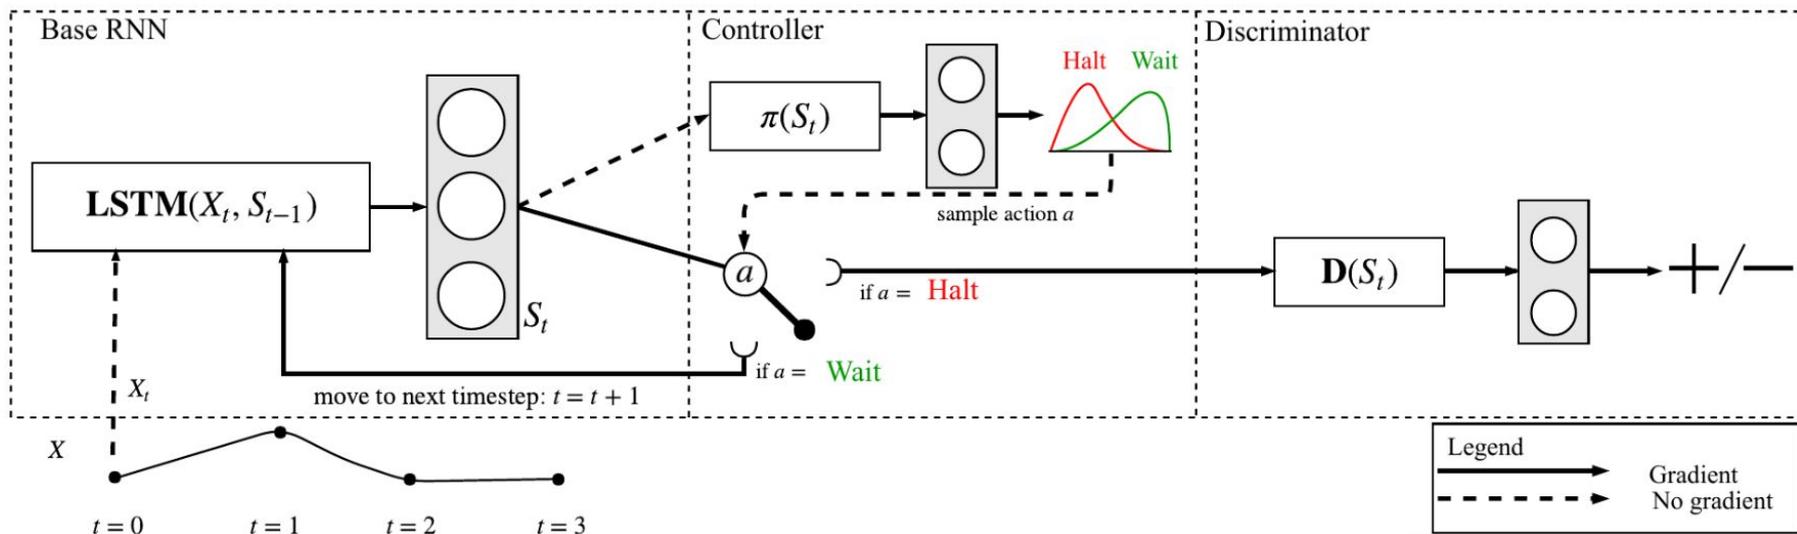
$$decision_u = \begin{cases} 1, & \text{if } score_u > \text{median}(scores) + \gamma \cdot \text{MAD}(scores) \\ 0, & \text{otherwise.} \end{cases}$$



Hiper-parámetro de la política de alerta temprana



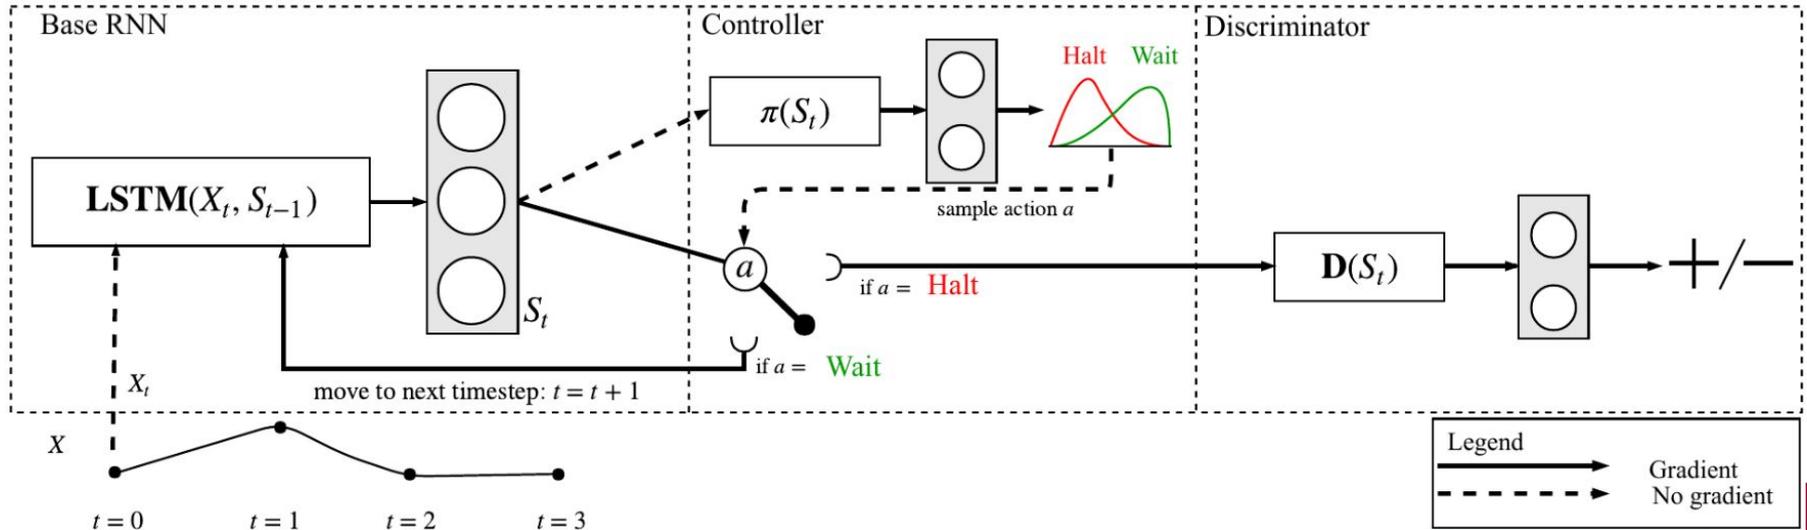
# EARLIEST





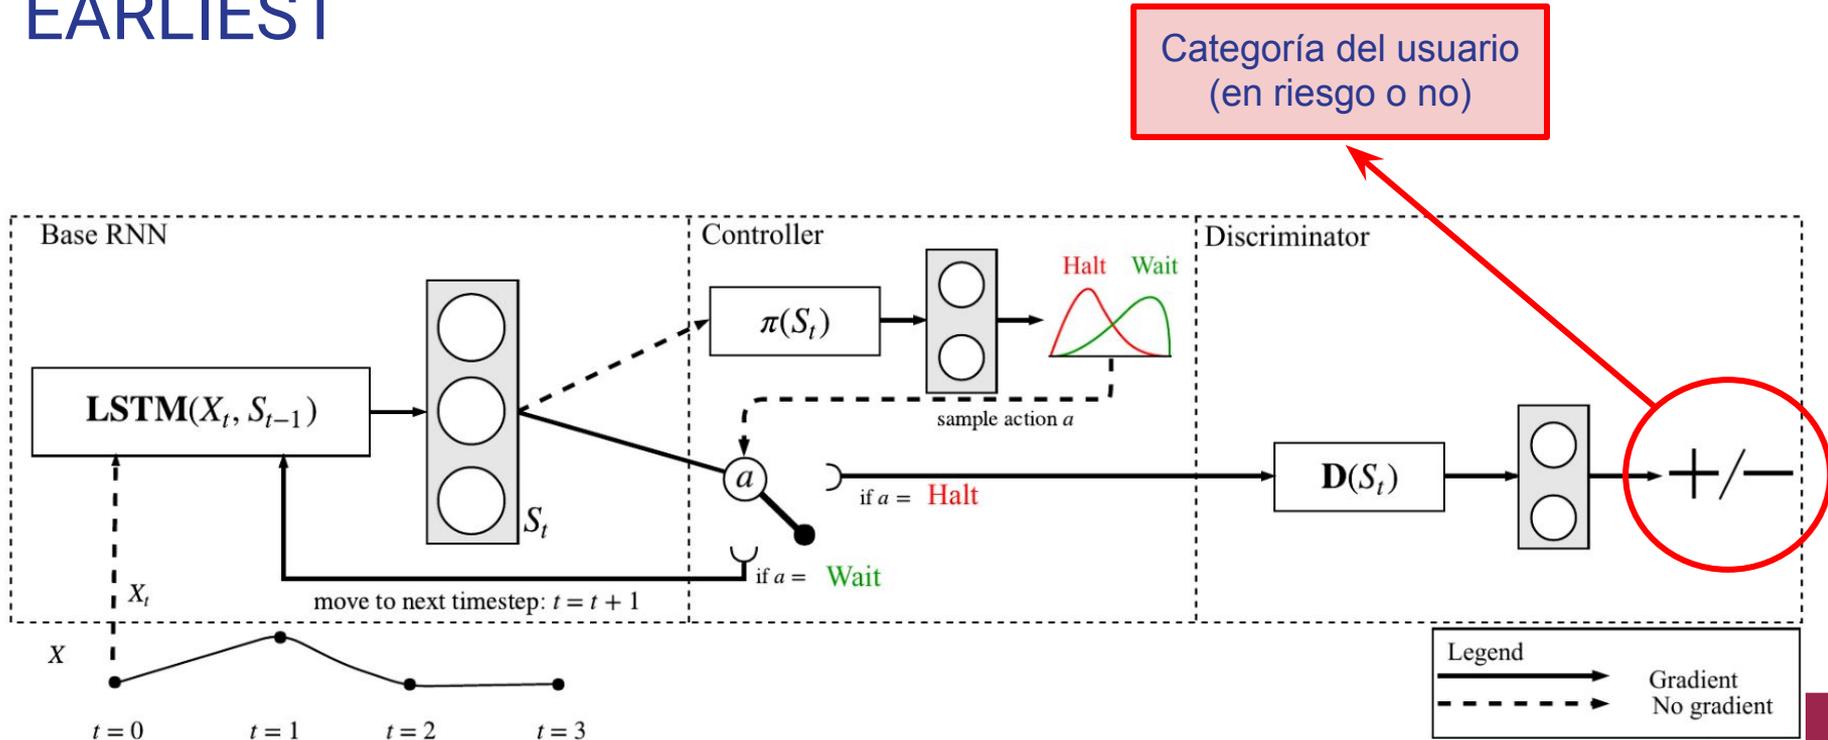
# EARLIEST

Early and Adaptive Recurrent Label ESTimator



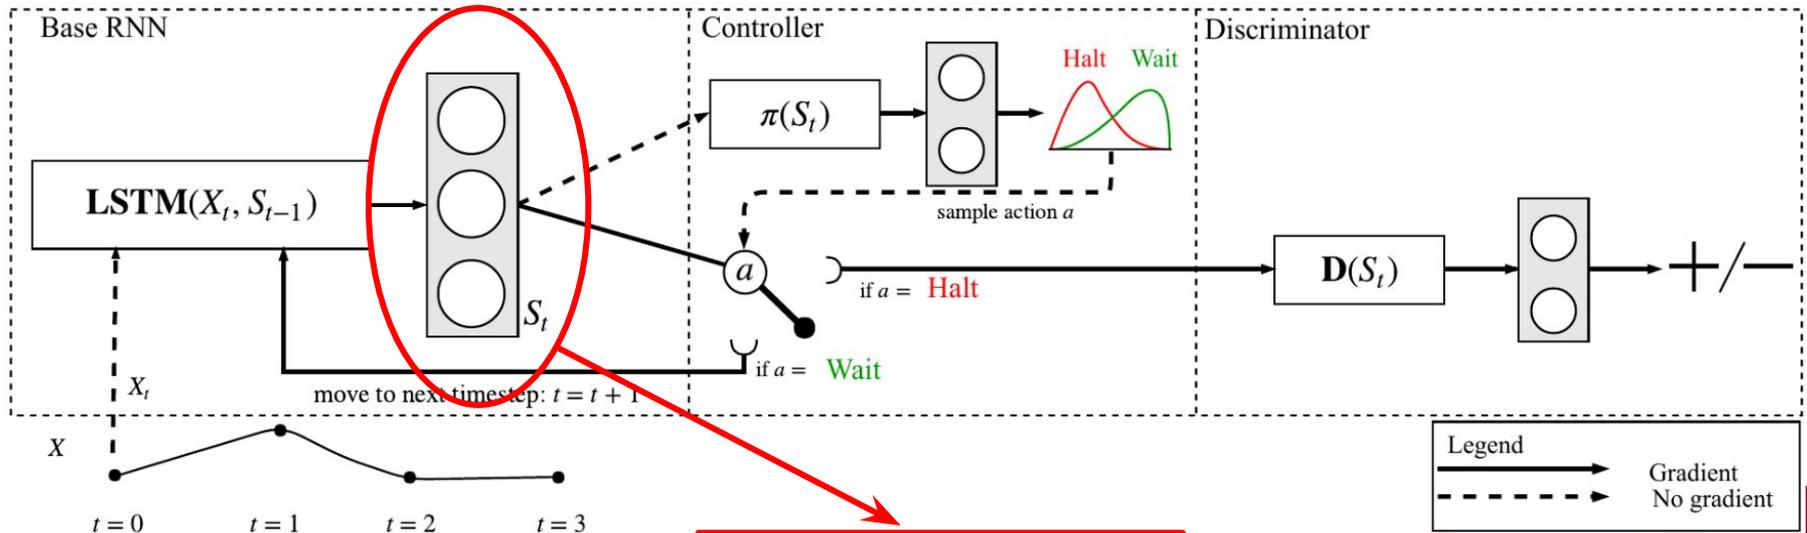
Secuencia de documentos de entrada para un usuario (doc2vec)

# EARLIEST





# EARLIEST

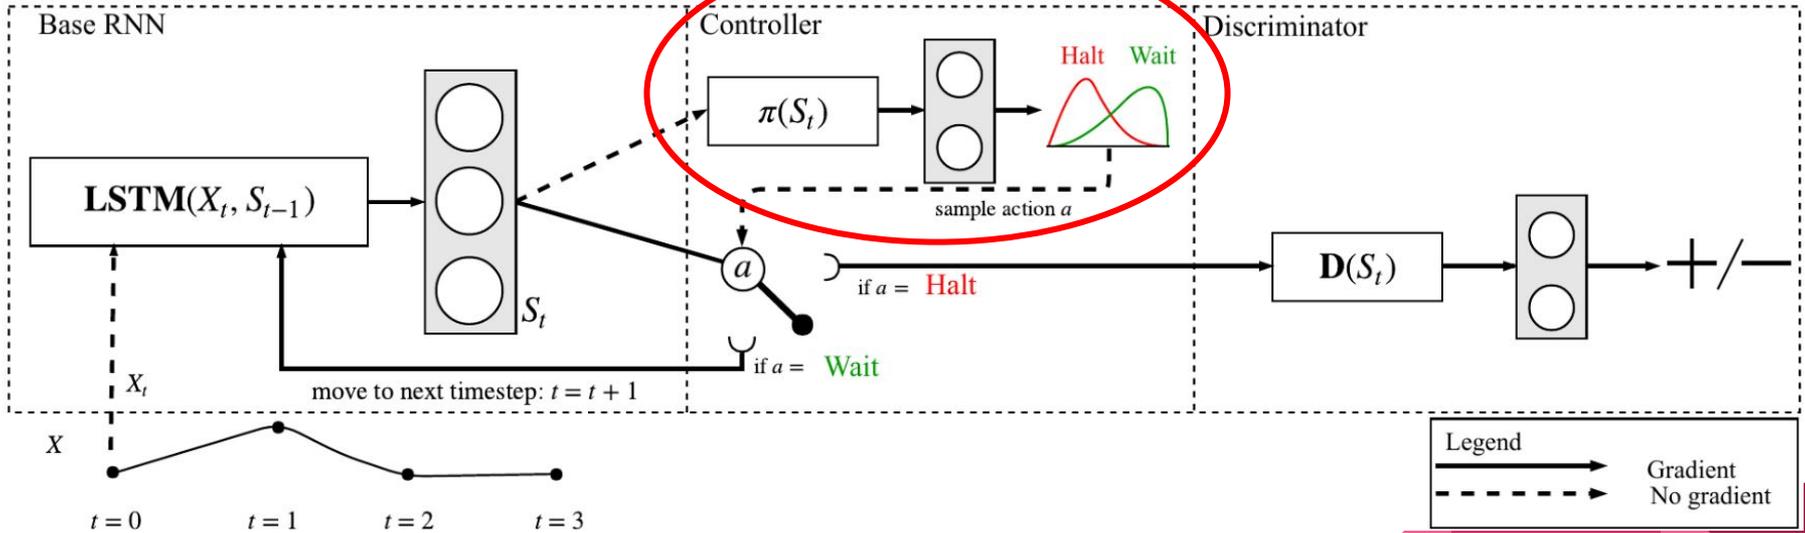


Representación parcial de los documentos

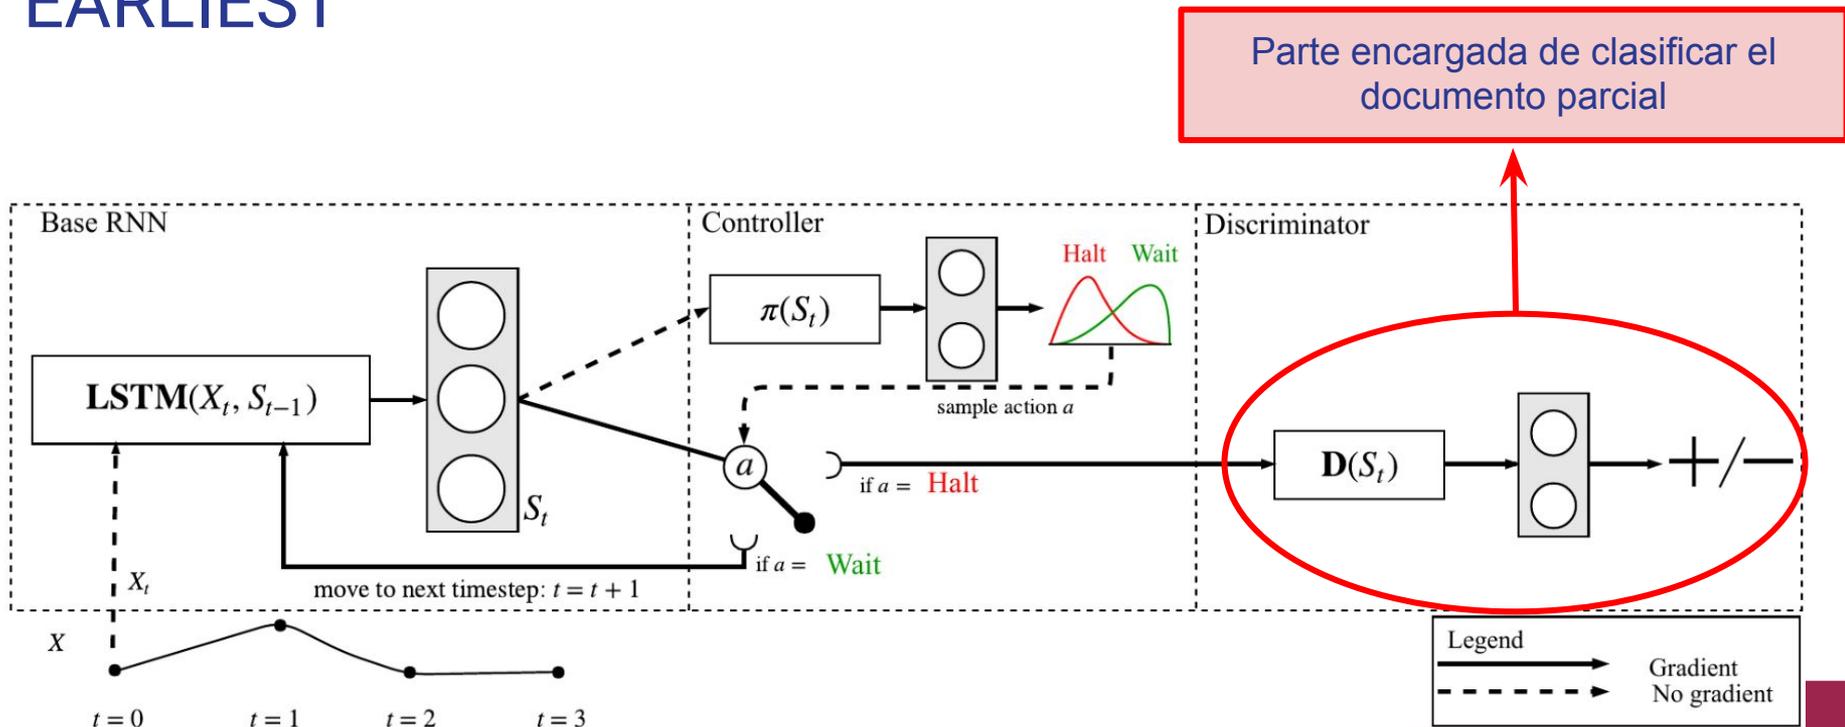


# EARLIEST

Parte encargada de decidir cuándo dejar de procesar la entrada



# EARLIEST





# EARLIEST

Para controlar la velocidad de la clasificación, el modelo cuenta con el hyper-parámetro  $\lambda$  que penaliza al modelo por la tardanza en la clasificación.

# eRisk 2021

- Laboratorio parte de CLEF 2021.
- Predicción temprana de riesgos en Internet.
- Explora la metodología de evaluación, las métricas de efectividad y las aplicaciones prácticas de la detección temprana de riesgos en Internet.
- Tareas:
  - Tarea 1 - Detección temprana de signos de juego patológico.
  - Tarea 2 - Detección temprana de signos de autolesión.





# Modelos para T1

- UNSL#0 (EarlyModel):
  - Representación → bolsa de palabras (unigrama de palabras con tf-idf)
  - Modelo → regresión logística
  - Política de decisión → umbral = 0,7 y número mínimo de posts = 10
- UNSL#1 (EarlyModel):
  - Representación → doc2vec
  - Modelo → regresión logística
  - Política de decisión → umbral = 0,85 y número mínimo de posts = 3
- UNSL#2 (EarlyModel):
  - Representación → bolsa de palabras (4-gramas de caracteres con tf-idf)
  - Modelo → SVM
  - Política de decisión → umbral = 0,75 y número mínimo de posts = 10



# Modelos para T1

- UNSL#3 (EARLIEST):
  - Representación → doc2vec
  - Modelo → LSTM
  - Política de decisión →  $\lambda = 0,000001$
- UNSL#4 (EARLIEST):
  - Representación → doc2vec
  - Modelo → LSTM
  - Política de decisión →  $\lambda = 0,00001$



# Resultados de tarea “Detección temprana de signos de juego patológico”

team name	run id	$P$	$R$	$F1$	$ERDE_5$	$ERDE_{50}$	$latency_{TP}$	$speed$	$latency-weighted F1$
UNSL ( EarlyModel )	0	.326	.957	.487	.079	.023	11	.961	.468
UNSL ( EarlyModel )	1	.137	.982	.241	.060	.035	4	.988	.238
UNSL ( EarlyModel )	2	<b>.586</b>	.939	<b>.721</b>	.073	<b>.020</b>	11	.961	<b>.693</b>
UNSL ( EARLIEST )	3	.084	.963	.155	.066	.060	1	<b>1</b>	.155
UNSL ( EARLIEST )	4	.086	.933	.157	.067	.060	1	<b>1</b>	.157
RELAI	0	.138	.988	.243	<b>.048</b>	.036	1	<b>1</b>	.243
BLUE	1	.157	.988	.271	.054	.036	2	.996	.270
UPV-Symanto	0	.042	.415	.077	.088	.087	1	<b>1</b>	.077
CeDRI	0	.076	<b>1</b>	.142	.079	.060	2	.996	.141
EFE	2	.233	.750	.356	.082	.033	11	.961	.342

**Table 2.** Decision-based evaluation




# Modelos para T2

- UNSL#0 (EarlyModel):
  - Representación → doc2vec
  - Modelo → MLP
  - Política de decisión → umbral = 0,7 y número mínimo de posts = 10
- UNSL#1 (EARLIEST):
  - Representación → doc2vec
  - Modelo → LSTM
  - Política de decisión →  $\lambda = 0,000001$
- UNSL#2 (EARLIEST):
  - Representación → doc2vec
  - Modelo → LSTM
  - Política de decisión →  $\lambda = 0,00001$



# Modelos para T2

- UNSL#3 (SS3):
  - Representación → texto
  - Modelo → SS3
  - Política de decisión →  $\gamma = 2$
  
- UNSL#4 (SS3):
  - Representación → texto
  - Modelo → SS3
  - Política de decisión →  $\gamma = 2,5$



# Resultados de tarea “Detección temprana de signos de autolesión”

team name	run id	$P$	$R$	$F1$	$ERDE_5$	$ERDE_{50}$	$latency_{TP}$	speed	latency-weighted $F1$
UNSL (EarlyModel)	0	.336	.914	.491	.125	<b>.034</b>	11	.961	.472
UNSL (EARLIEST)	1	.11	.987	.198	.093	.092	<b>1</b>	<b>1.0</b>	.198
UNSL (EARLIEST)	2	.129	.934	.226	.098	.085	<b>1</b>	<b>1.0</b>	.226
UNSL (SS3)	3	.464	.803	.588	.064	.038	3	.992	.583
UNSL (SS3)	4	.532	.763	<b>.627</b>	.064	.038	3	.992	<b>.622</b>
NLP-UNED	4	.453	.816	.582	.088	.04	9	.969	.564
Birmingham	0	.584	.526	.554	.068	.054	2	.996	.551
Birmingham	2	<b>.757</b>	.349	.477	.085	.07	4	.988	.472
EFE	2	.366	.796	.501	.12	.043	12	.957	.48
BLUE	2	.454	.849	.592	.079	.037	7	.977	.578
UPV-Symanto	1	.276	.638	.385	<b>.059</b>	.056	1	1.0	.385

**Table 5.** Decision-based evaluation



**Gracias por su  
atención. ¿Preguntas?**

**[jmloyola@unsl.edu.ar](mailto:jmloyola@unsl.edu.ar)**

# Referencias

- Loyola, J. M., Errecalde, M. L., Escalante, H. J., & y Gomez, M. M. (2017, October). Learning when to classify for early text classification. In Argentine Congress of Computer Science (pp. 24-34). Springer, Cham.
- Losada, D. E., Crestani, F., & Parapar, J. (2018, September). Overview of eRisk: early risk prediction on the internet. In International conference of the cross-language evaluation forum for european languages (pp. 343-361). Springer, Cham.
- Sadeque, F., Xu, D., & Bethard, S. (2018, February). Measuring the latency of depression detection in social media. In Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining (pp. 495-503).
- Loyola, J. M., Burdisso, S. G., Thompson, H., Cagnina, L. & Errecalde, M. (2021, September). UNSL at eRisk 2021: A comparison of three early alert policies for early risk detection. In Working Notes of CLEF 2021 - Conference and Labs of the Evaluation Forum, Bucarest, Romania, September 21-24, 2021.
- Burdisso, S. G., Errecalde, M., & Montes-y-Gómez, M. (2019). A text classification framework for simple and effective early depression detection over social media streams. Expert Systems with Applications, 133, 182-197.
- Hartvigsen, T., Sen, C., Kong, X., & Rundensteiner, E. (2019, July). Adaptive-halting policy network for early classification. In Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (pp. 101-110).



# eRisk corpus (T1)

- Basado en publicaciones y comentarios en Reddit (<https://www.reddit.com/>).
- No se suministró corpus para entrenar.

Corpus	#users			#posts	#posts per user			#words per post		
	Total	Pos	Neg		Med	Min	Max	Med	Min	Max
T1_test	2,348	164	2184	1,130,792	244	10	2,001	12	0	10,175
T1_train	726	176	550	71,187	54	31	740	20	1	4,516
T1_valid	726	176	550	74,507	55	31	1,234	19	1	7,479



## eRisk corpus (T2)

- Basado en publicaciones y comentarios en Reddit (<https://www.reddit.com/>).
- Se suministró un corpus de entrenamiento y validación.

Corpus	#users			#posts	#posts per user			#words per post		
	Total	Pos	Neg		Med	Min	Max	Med	Min	Max
T2_test	1,448	152	1296	746,098	275.5	10	1,999	12	0	18,064
T2_train	340	41	299	170,698	282.0	8	1,992	10	1	6,700
T2_valid	423	104	319	103,837	95.0	9	1,990	7	1	2,663
redd_train	1,051	494	557	118,452	61.0	31	1,466	18	1	5,971
redd_valid	1,051	494	557	119,651	59.0	31	1,781	18	1	4,382
comb_train	1,391	535	856	289,150	73.0	8	1,992	13	1	6,700
comb_valid	1,474	598	876	223,488	63.0	9	1,990	11	1	4,382
ilab_train	26,256	10319	15937	259,297	5.0	1	1,825	19	1	11,933



# Procedimiento de generación de corpus

- Basado en publicaciones y comentarios en Reddit (<https://www.reddit.com/>).
- Los casos positivos fueron obtenidos de subreddits particulares
  - T1: <https://www.reddit.com/r/problemgambling/>
  - T2: <https://www.reddit.com/r/selfharm/>
- Los casos negativos fueron obtenidos de subreddits generales, sports, jokes, gaming, politics, news, y LifeProTips.
- Se descartaron todos los usuarios con menos de 31 publicaciones o comentarios, o con un promedio de palabras por publicación menor a 15.



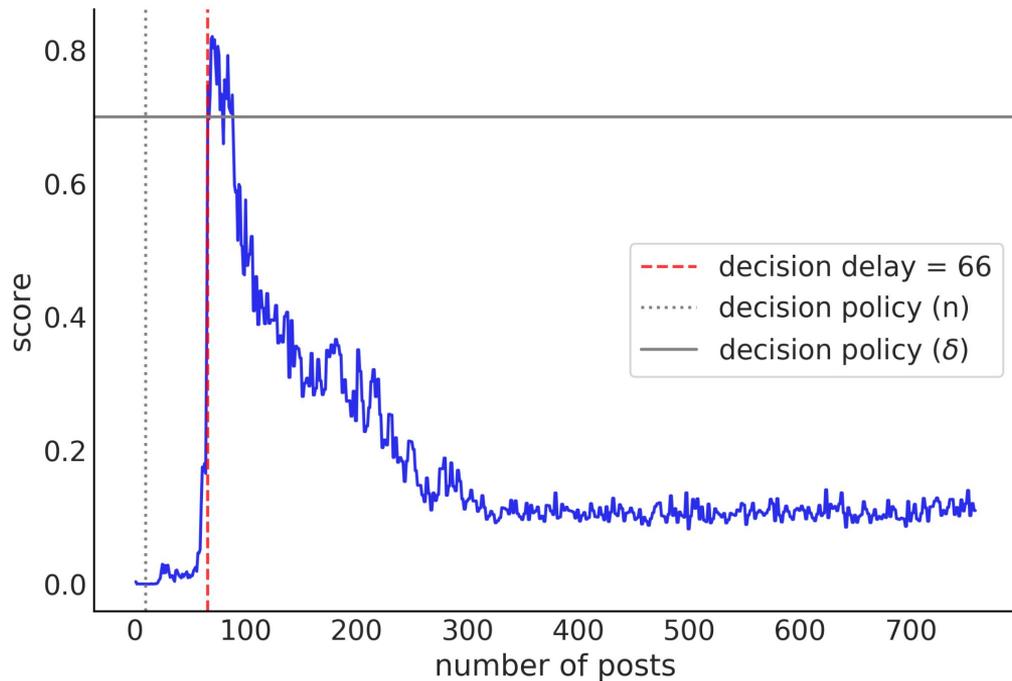
# Pre-procesamiento de entrada

1. Convertir a minúscula.
2. Convertir códigos HTML y Unicode en su símbolos.
3. Reemplazar enlaces a la web con un token.
4. Reemplazar enlaces internos a reddit por sitio al que dirigen.
5. Eliminar símbolos que no sean letras y números.
6. Reemplazar números con un token.
7. Eliminar espacios en blanco consecutivos, nuevas líneas y tabs.



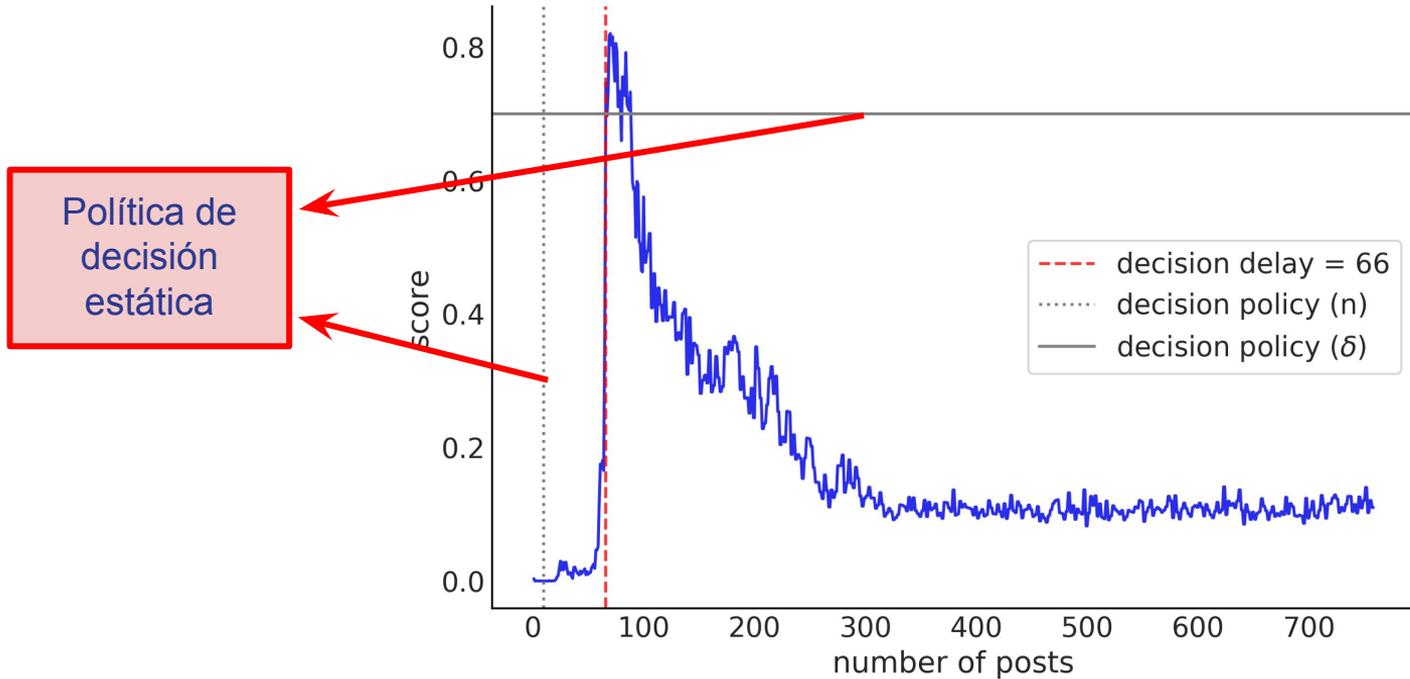


# Visualización puntaje y política de decisión (EarlyModel)





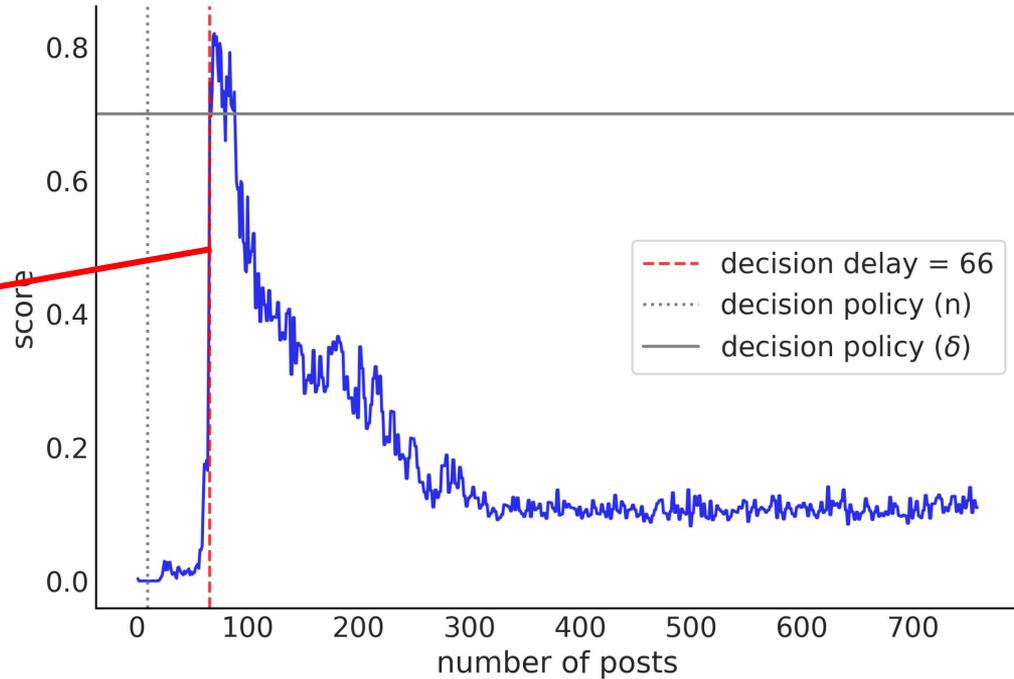
# Visualización puntaje y política de decisión (EarlyModel)





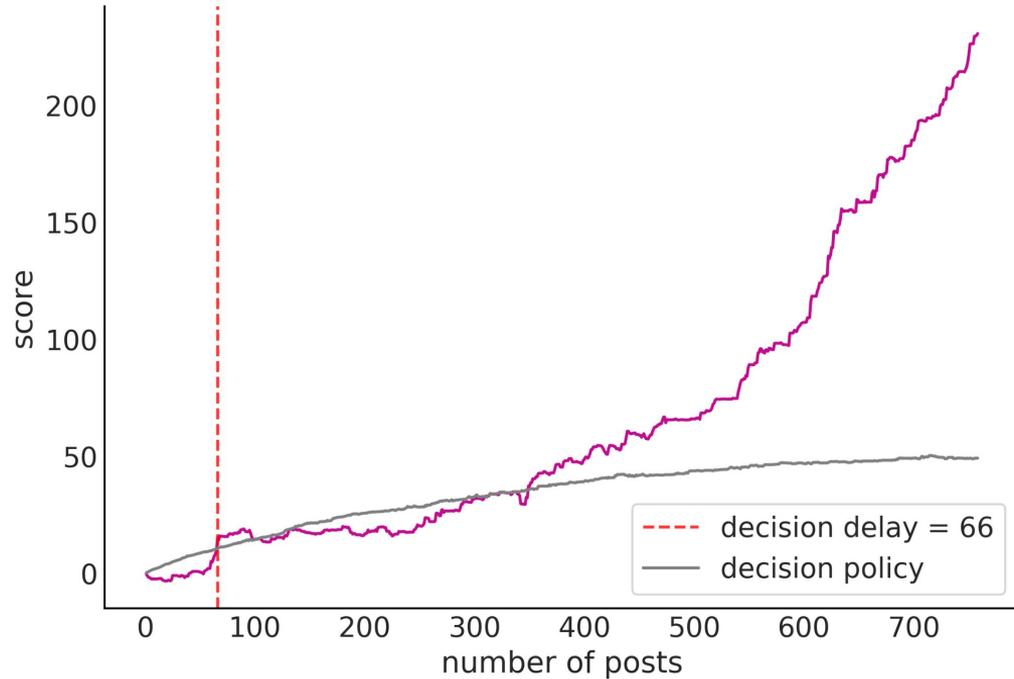
# Visualización puntaje y política de decisión (EarlyModel)

Momento en el que se clasifica como positivo



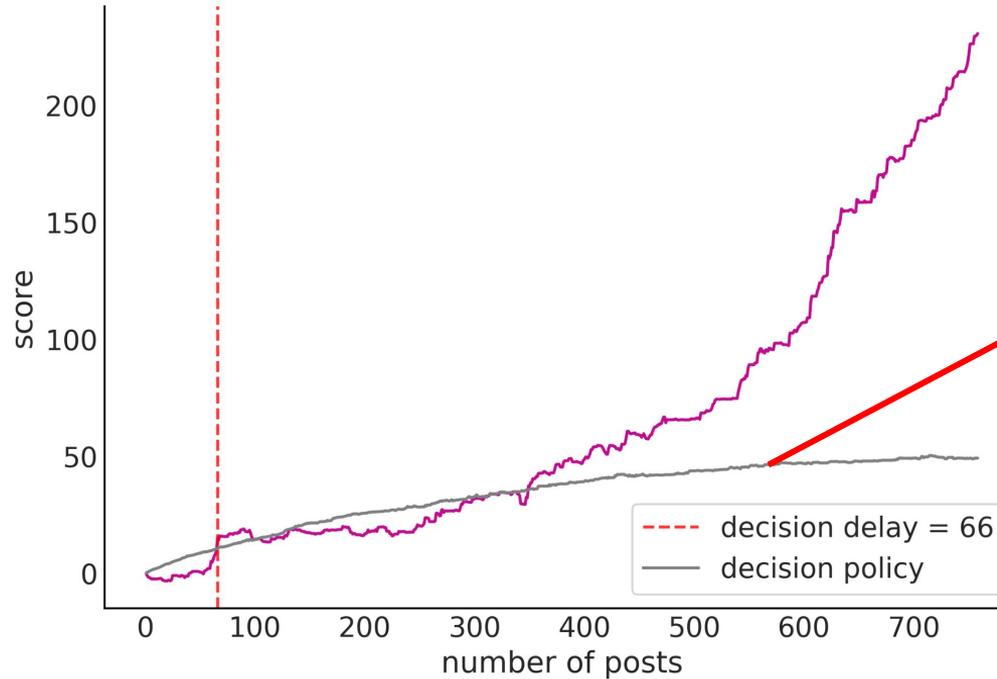


# Visualización puntaje y política de decisión (SS3)





# Visualización puntaje y política de decisión (SS3)

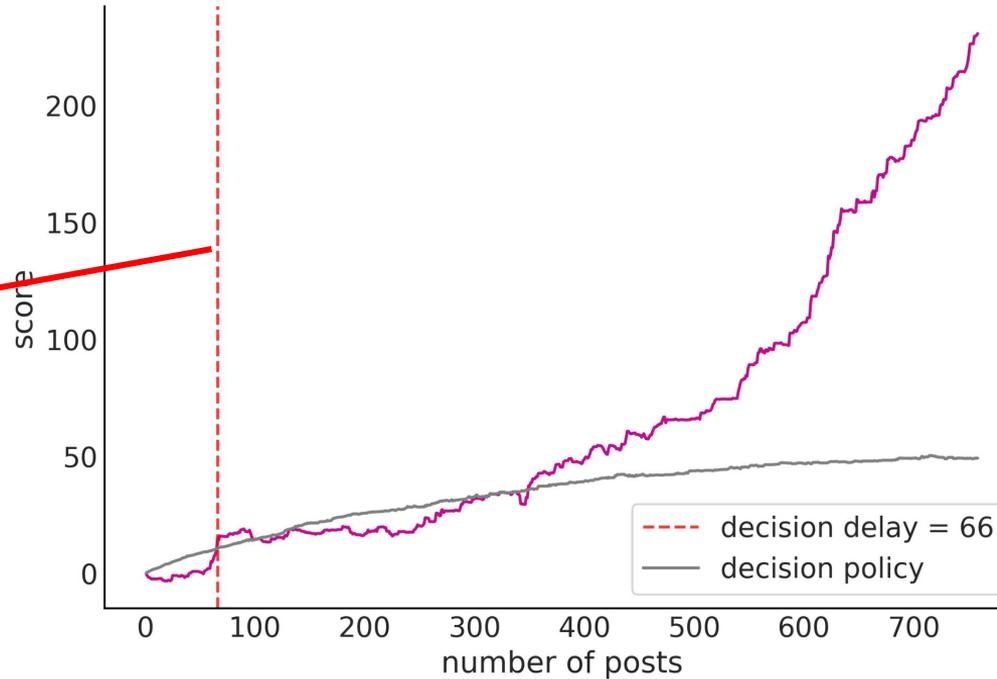


Política de decisión dinámica (depende de los scores de todos los usuarios)



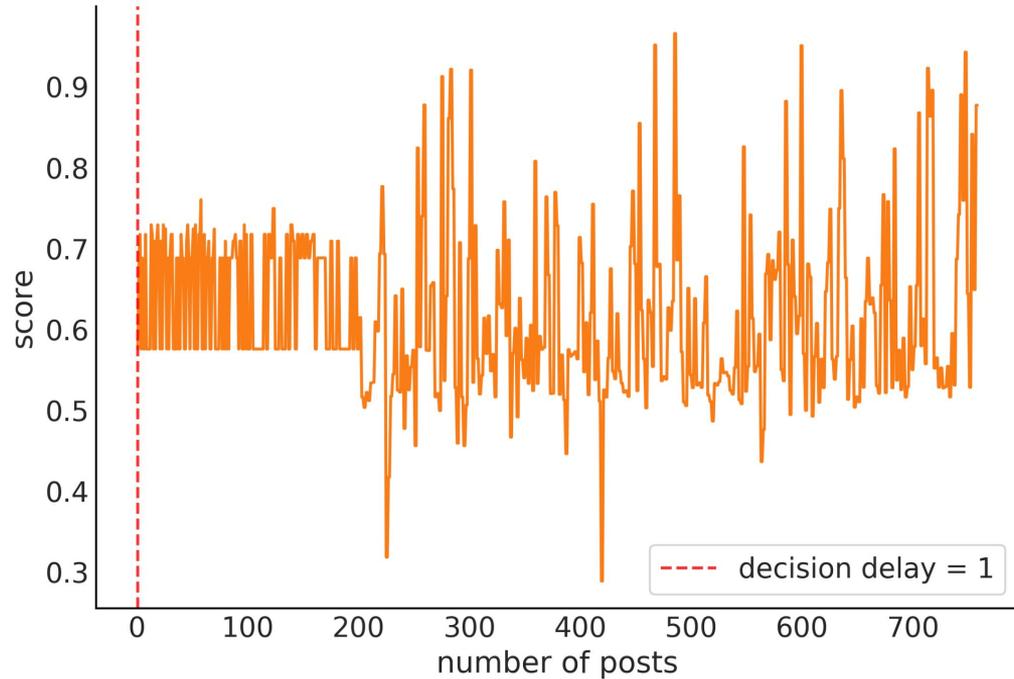
# Visualización puntaje y política de decisión (SS3)

Momento en el que se clasifica como positivo





# Visualización puntaje y política de decisión (EARLIEST)





# Visualización puntaje y política de decisión (EARLIEST)

Momento en el que se clasifica como positivo

