

# Clasificación de texto con adversario

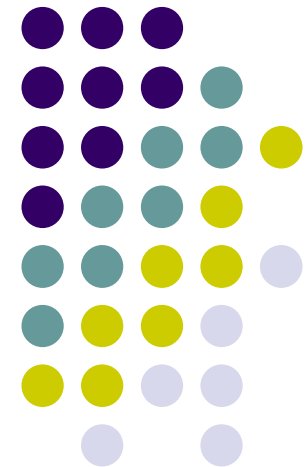
Técnicas de clasificación y filtrado aplicadas a la  
detección de spam en la Web



José María Gómez Hidalgo

Optenet I+D

<http://www.esp.uem.es/jmgomez>



# Índice




1. **Introducción**
2. Categorización de Texto
3. Clasificación de Texto con Adversario
4. Filtrado de correo basura
5. Filtrado de contenidos Web
6. Detección de Spam Web
7. Algunas conclusiones
8. Demostraciones



# Introducción

- Crecimiento exponencial de la Web/Internet





# Introducción

- INTECO: El 84,6% de los correos electrónicos que circulan en España son spam (92M, Marzo/08)
- MAAWG: El 85,2% de los correos mundiales son spam (0.1B, Diciembre/07)



# Introducción

- ¿Qué buscamos en la Web?

Rank	1997 Excite data set (2,414 queries)	1999 Excite data set (2,539 queries)	2001 Excite data set (2,453 queries)
1	19.9% Entertainment or recreation	24.5% Commerce, travel, employment, or economy	24.7% Commerce, travel, employment, or economy
2	16.8% Sex and pornography	20.3% People, places, or things	19.7% People, places, or things
3	13.3% Commerce, travel, employment, or economy	10.9% Computers or Internet	11.3% Non-English or unknown
4	12.5% Computers or Internet	7.8% Health or sciences	9.6% Computers or Internet
5	9.5% Health or sciences	7.5% Sex and pornography	8.5% Sex and pornography
6	6.7% People, places, or things	7.5% Entertainment or recreation	7.5% Health or sciences
7	5.7% Society, culture, ethnicity, or religion	6.8% Non-English or unknown	6.6% Entertainment or recreation
8	5.6% Education or humanities	5.3% Education or humanities	4.5% Education or humanities
9	5.4% Performing or fine arts	4.2% Society, culture, ethnicity, or religion	3.9% Society, culture, ethnicity, or religion
10	4.1% Non-English or unknown	1.6% Government	2.0% Government
11	3.4% Government	1.1% Performing or fine arts	1.1% Performing or fine arts



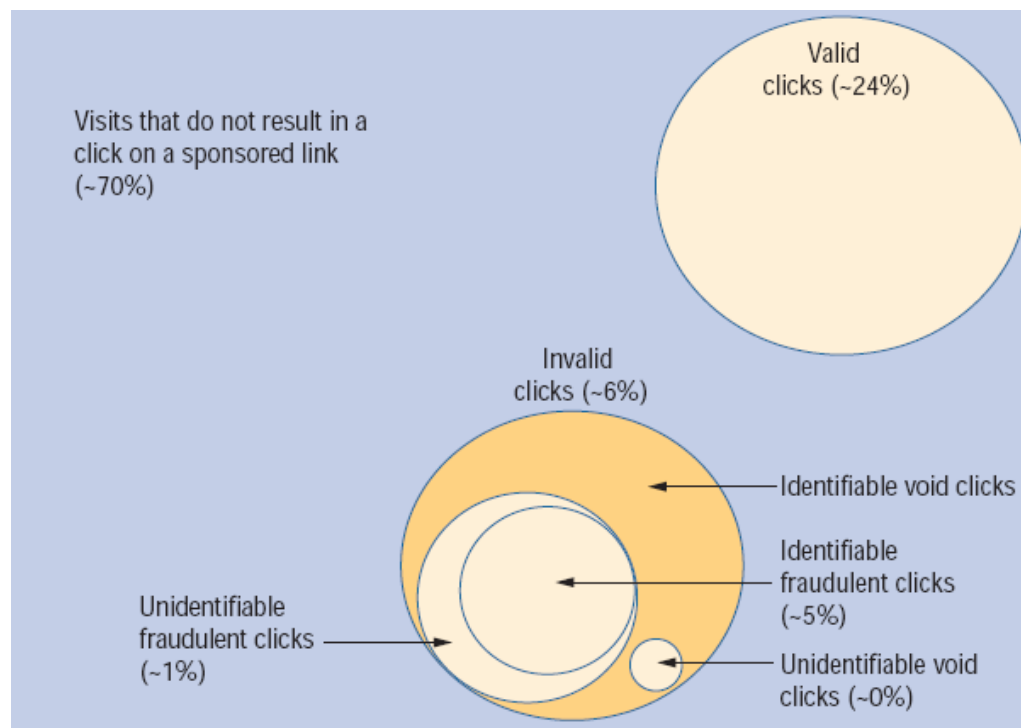
# Introducción

- Google, publicidad, fraude

Year Ended December 31,				
2003	2004	2005	2006	2007
(in thousands, except per share amounts)				
\$ 1,465,934	\$ 3,189,223	\$ 6,138,560	\$ 10,604,917	\$ 16,593,986

Google ingresa \$16,000M  
Por publicidad

¿Es extraño que haya  
Web Spam y fraude de  
clicks?





# Introducción

- Objetivo
  - Abordar distintas tareas de clasificación de contenidos ilícitos/inapropiados de manera unificada
  - Clasificación de texto con adversario
    - El adversario pretende burlar al sistema
  - Un problema general de **categorización de texto**

# Índice



1. Introducción
2. Categorización de Texto
3. Clasificación de Texto con Adversario
4. Filtrado de correo basura
5. Filtrado de contenidos Web
6. Detección de Spam Web
7. Algunas conclusiones
8. Demostraciones



# Categorización de texto

- Categorización (automática) de texto
  - Clasificación (automática) de documentos en categorías predefinidas
    - *Automated Text Categorization (ATC)*
  - RI = categorías NO predefinidas = consultas
  - Agrupamiento = categorías NO predefinidas
  - Importante = número y tipo de categorías
    - Solapamientos, jerarquías, dimensiones temáticas, etc.



# Categorización de texto

- Ejemplos de aplicaciones CAT

## ***Documentos***

## ***Categorías***

libros, noticias



descriptores temáticos

informes técnicos



palabras clave

páginas Web



directorios Web

contenidos inapropiados

mensajes de correo  
electrónico



carpetas personales

correo basura



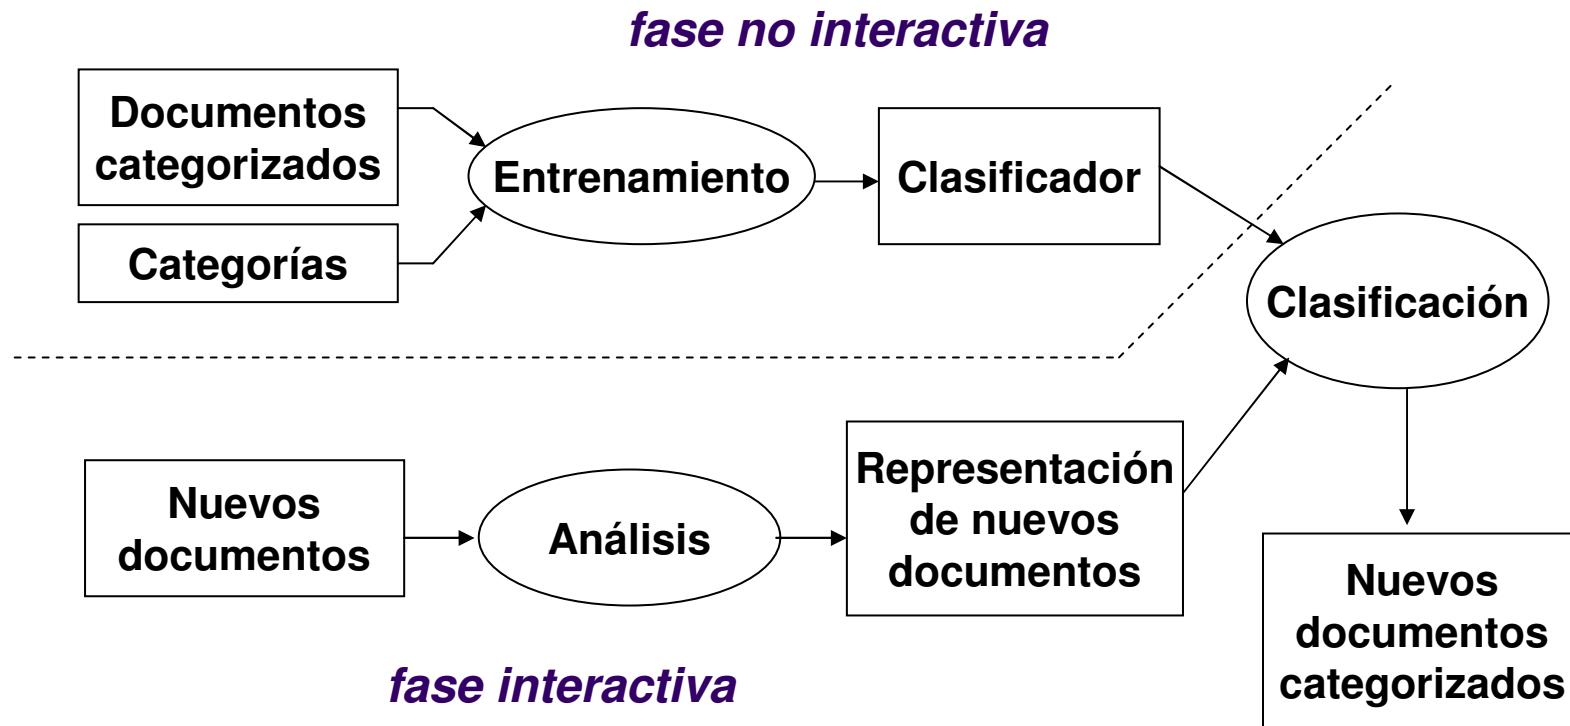
# Categorización de texto

- Técnicas de automatización de CT
  - Construidos manualmente = sistemas expertos
    - Conjuntos de reglas derivadas por expertos anotadores humanos (catalogadores)  
**IF (“sex” IN D) THEN (D IN porn)**
  - Construidos automáticamente (CAT basada en aprendizaje)
    - Aplicación de técnicas de recuperación de Información y Aprendizaje Automático (AA)
    - Reducción del cuello de botella de adquisición del conocimiento



# Categorización de texto

- CAT basada en aprendizaje





# Categorización de texto

- Técnicas de CAT basada en aprendizaje
  - Representación de documentos
    - Vectores de pares atributo-valor
    - Usualmente, Modelo del Espacio Vectorial
    - Vectores de pesos de términos
      - Términos = raíces de palabras y filtrado con lista de parada
      - Pesos = binarios, TF, TF.IDF



# Categorización de texto

- Técnicas de CAT basada en aprendizaje
  - Reducción de la dimensionalidad
    - Selección de términos
      - Métricas de selección (Ganancia de Información, Frecuencia en documentos, etc.)
        - E.g. 10% de términos más frecuentes en documentos
      - Agresividad
    - Extracción de términos
      - Agrupamiento de términos
      - Indexación Semántica Latente



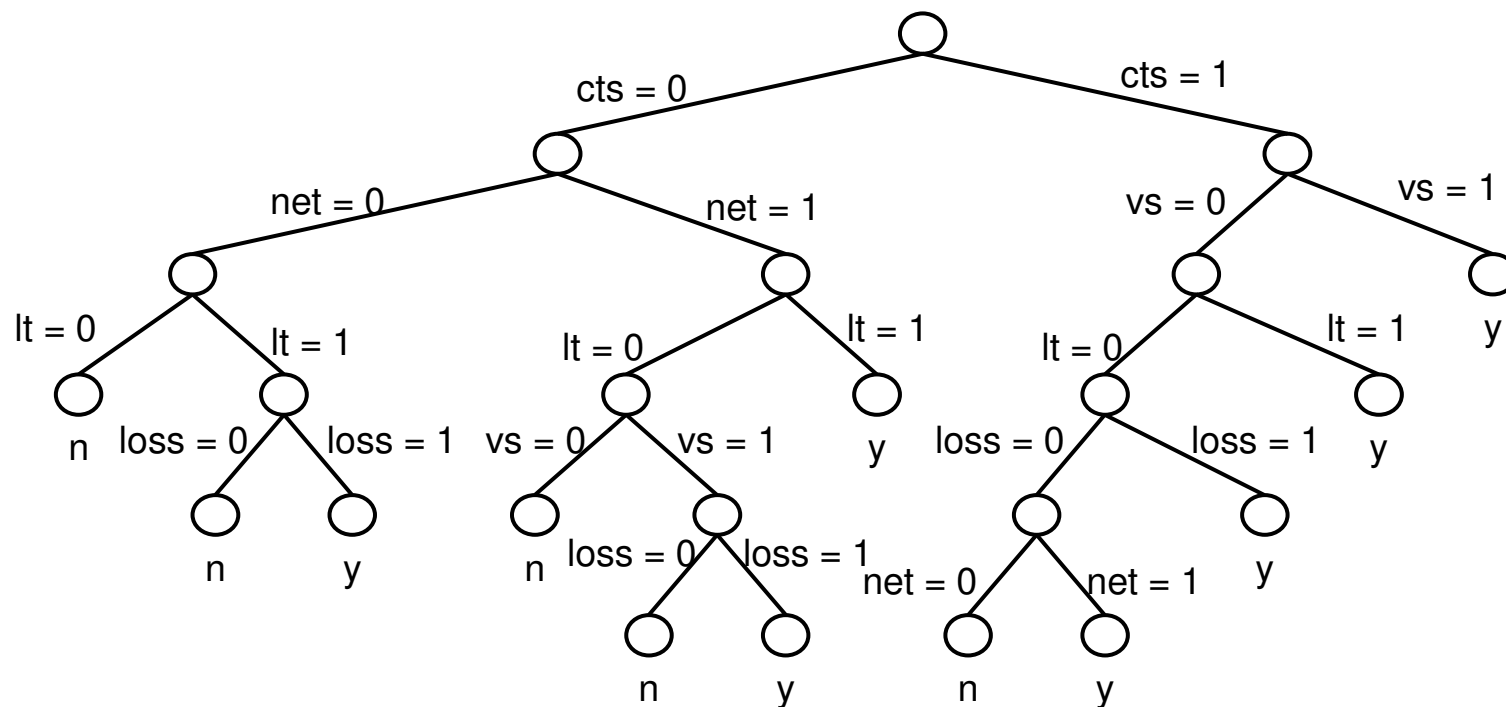
# Categorización de texto

- Técnicas de CAT basada en aprendizaje
  - Aprendizaje
    - Clasificadores lineales (Rocchio, Winnow)
    - Clasificadores probabilísticos (Bayes Ingenuo)
    - Inducción de árboles de decisión (C4.5)
    - Generadores de reglas (Ripper)
    - Support Vector Machines
    - Redes Neuronales (perceptrón)
    - Aprendizaje perezoso (K-Nearest Neighbors)
    - Comités (Boosting)



# Categorización de texto

- Ejemplo de aprendizaje en CAT (C4.5)





# Categorización de texto

- Evaluación
  - Eficiencia
  - Efectividad
    - Estimación de la bondad de la aproximación
    - Colección de prueba
      - Reuters, OHSUMED, RCV1
    - Métricas de IR y ML
      - Cobertura (recall), precisión,  $F_1$
      - Exactitud (accuracy), error



# Categorización de texto

- Efectividad: métricas

Sistema =>	Puestos en C	No puestos en C
En C	TP	FN
No en C	FP	TN

$$\begin{aligned} \text{Cobertura (R)} &= \frac{TP}{TP + FN} \\ \text{Precisión (P)} &= \frac{TP}{TP + FP} \end{aligned} \rightarrow F_1 = \frac{2RP}{R + P}$$



# Categorización de texto

- Efectividad de la CAT
  - Promedio
    - Micro-media vs. macro-media
  - Tratamiento de la colección de evaluación
    - Partición
    - Validación cruzada
  - [Sebastiani02]

*“Automatic TC (...) has reached effectiveness levels comparable to those of trained professionals.”*

# Índice



1. Introducción
2. Categorización de Texto
3. Clasificación de Texto con Adversario
4. Filtrado de correo basura
5. Filtrado de contenidos Web
6. Detección de Spam Web
7. Algunas conclusiones
8. Demostraciones

# Clasificación de Texto con Adversario



- Tarea de clasificación de texto en la que existe un adversario
  - Su objetivo es que el clasificador deje de ser útil
  - Demasiados errores por exceso (falsos positivos)
    - Correos legítimos clasificados como spam
    - Páginas Web legítimas bloqueadas
    - Contenidos legítimos eliminados del ranking
  - Demasiados errores por defecto (falsos negativos)
    - Correos spam pasan el filtro
    - Demasiadas páginas perniciosas accedidas
    - Demasiadas páginas de spam en el ranking

# Clasificación de Texto con Adversario



- Coste de errores

Tarea	Error	Coste	Ejemplo y resultado
<i>Filtrado de correo basura</i>	FN	Bajo	El usuario final recibe un correo basura <b>Resultado:</b> El usuario borra el correo basura
	FP	Alto	El usuario no recibe un correo legítimo, que queda en cuarentena o es eliminado <b>Resultado:</b> El usuario debe revisar la cuarentena periódicamente, y siempre existe el riesgo de que pierda mensajes críticos (e.g. el pedido de un cliente)

# Clasificación de Texto con Adversario



- Coste de errores

Tarea	Error	Coste	Ejemplo y resultado
<i>Filtrado de contenido Web</i>	FN	Alto	El usuario accede a un contenido inapropiado (pornografía, juego de casino, racismo, etc.) <b>Resultado:</b> El usuario puede sentirse disgustado. Alternativamente, el usuario puede no informar del error. El supervisor debe inspeccionar la navegación periódicamente.
	FP	Medio	El usuario ve bloqueado un contenido legítimo. <b>Resultado:</b> El supervisor debe inspeccionar y reclasificar el contenido.


# Clasificación de Texto con Adversario



- Coste de errores


Tarea	Error	Coste	Ejemplo y resultado
<i>Detección de spam Web</i>	FN	Alto	Una página logra un resultado muy alto en una búsqueda popular. <b>Resultado:</b> El buscador pierde credibilidad y sus supervisores deben inspeccionar periódicamente los resultados más altos en las búsquedas más populares.
	FP	Medio	Una página es eliminada en una búsqueda afín y procedente. <b>Resultado:</b> Su autor se queja, el buscador pierde credibilidad, y sus supervisores deben desbloquearla.

# Clasificación de Texto con Adversario

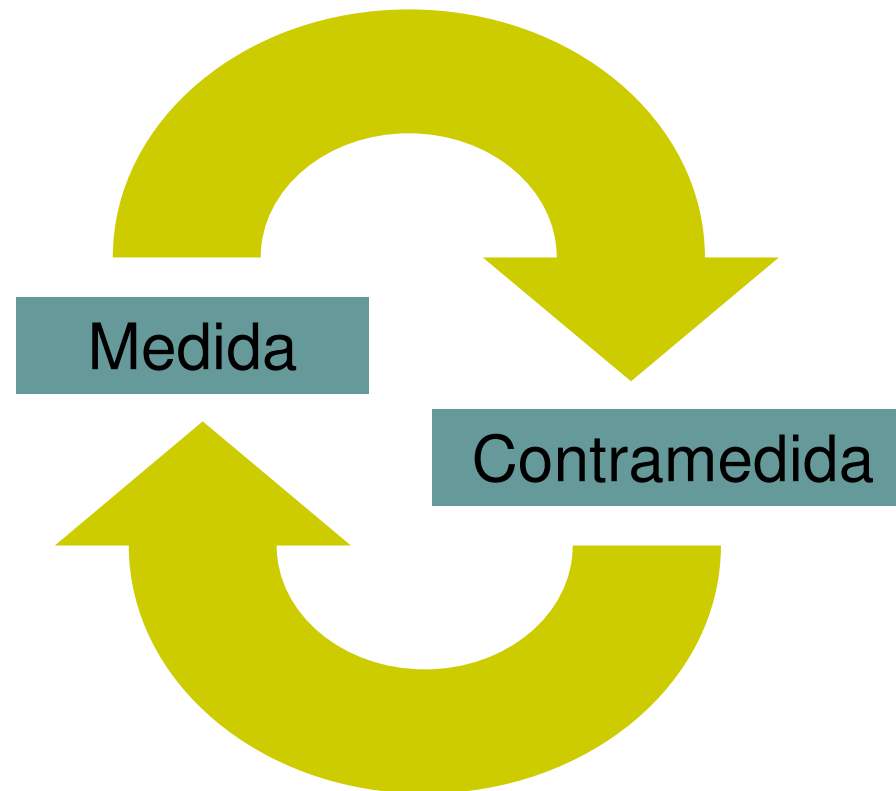


- Análisis comparativo de costes
  - Los costes dependen de la tarea
  - Los costes son asimétricos en todas las tareas
  - Los costes pueden ser variables y dependientes del entorno operativo
- La distribución también es variable
- Impacto ***crítico*** en el método de evaluación


# Clasificación de Texto con Adversario



- Problema de la espada y el escudo o *carrera armamentística*




# Clasificación de Texto con Adversario




- Formalización en teoría de juegos [Dalvi04]
  - Interacción filtro – adversario = juego de la clasificación con adversario
  - En ciertos casos, se puede alcanzar un equilibrio de Nash
    - Problema no tratable en general
    - Versión reducida
      - Un movimiento por oponente = un cambio en el filtro/mensaje
      - Cada adversario conoce los parámetros del oponente
      - Cada adversario realiza su movimiento óptimo

# Clasificación de Texto con Adversario



- Formalización en teoría de juegos [Dalvi04]
  - Clasificador y adversario sensibles al coste
    - Costes conocidos (escenarios 10/100/1000)
  - Clasificador bayesiano ingenuo
  - Estrategias para el clasificador y el adversario
  - Aplicación a filtrado de correo basura
    - Ataques: agregar palabras/longitud, sinónimos
    - Medida de utilidad
    - Se aumenta la utilidad (menos errores más costosos)
    - No se llega a equilibrio en juego repetido

# Clasificación de Texto con Adversario



- Ingeniería inversa de clasificadores de adversario [Lowd05]
  - Condiciones más realistas, e.g.
    - Desconocimiento de parámetros del clasificador
    - Prueba iterativa con mensajes legítimos y spam
  - Método de aprendizaje ***para el adversario***
    - Evaluación con correo basura
    - Ataques de léxico (agregar/eliminar palabras)
    - Reducción en el número de pruebas a realizar para violar el filtro

# Clasificación de Texto con Adversario



- Conclusiones
  - No se han testado otros problemas aparte del correo basura
  - Existe un marco teórico muy preliminar
    - No ha sido desarrollado en lo sucesivo
    - No existen evidencias de su utilización práctica
    - Los costes y distribuciones siguen siendo variables y desconocidos

# Índice



1. Introducción
2. Categorización de Texto
3. Clasificación de Texto con Adversario
4. **Filtrado de correo basura**
5. Filtrado de contenidos Web
6. Detección de Spam Web
7. Algunas conclusiones
8. Demostraciones



# Filtrado de correo basura

- Motivación
  - Más del 85% del correo es basura
  - Problemas y pérdidas para
    - Usuarios (tiempo, coste de conexión, desconfianza)
    - Empresas (productividad, inversiones extraordinarias, falsos positivos de clientes, etc.)
    - Proveedores (infraestructura extra, pérdida de imagen)



# Filtrado de correo basura

- Medidas de control
  - Legales => internacionalidad
  - Económicas => difícil implementación
  - Tecnológicas
    - Múltiples métodos de detección y filtrado

Listas negras y blancas  
Franqueo de Turing  
Direcciones prescindibles  
Tarros de miel  
Firma de correo/servidor

Franqueo computacional  
CAPTCHAs  
Filtrado colaborativo  
Reputación  
Análisis heurístico

**LA CLAVE ES LA INTEGRACIÓN DE TÉCNICAS**



# Filtrado de correo basura

- Filtros bayesianos
  - Análisis del contenido basado en aprendizaje
    - Aprendizaje = adaptación a cambios del adversario
    - Efectividad = se ha alcanzado el 99%
    - Simplicidad de implementación
  - Resistencia “criptográfica”
  - Tecnología de Categorización de Texto



# Filtrado de correo basura

- Representación de los mensajes
  - Múltiples experimentos con
    - Tokenización = separación en cadenas/atributos
    - Reducción = paso a minúsculas, stemming, stoplist
    - Valores/Pesos = binarios, TF, TF.IDF
  - Hasta las decisiones más simples (e.g. separadores) pueden tener impacto dramático



# Filtrado de correo basura

- Tokenización de Graham [Graham02,03]
  - Separador /= caracteres alfanuméricos, guiones, apóstrofes, símbolos de exclamación y símbolos de dólar
  - Secuencias de números y comentarios HTML ignorados
  - Mayúsculas y minúsculas, no stemming/stoplist
  - Puntos y comas entre dígitos = parte de tokens (IPs, precios)
  - Rangos de precios (\$20-25) se separan (\$20 y \$25)
  - Se marcan términos en algunos campos especiales (From, To, Subject, Return-Path) y en URLs (Subject\*gratis)



# Filtrado de correo basura

- Tokens encadenados [Zdziarski04]
  - Bigramas tradicionales
  - Adicionales a los tokens individuales
  - Mejora de estadísticas

<i>Términos</i>	$P(spam/w_1)$	$P(spam/w_2)$	$P(spam/w_1 * w_2)$
$w_1=FONT, w_2= face$	0,457338	0,550659	0,208403
$w_1=color, w_2=#000000$	0,328253	0,579449	0,968415
$w_1=that, w_2= sent$	0,423327	0,404286	0,010099



# Filtrado de correo basura

- Sparse Binary Polynomial Hash (SBPH), [Yerazunis03/04]
  - Sólo bigramas separados por otros tokens
    - “Tu puedes conseguir porno gratis”
      - “Tú gratis”
      - “puedes gratis”
      - “conseguir gratis”
      - “porno gratis”
  - Junto con Regla en Cadena Bayesiana => 99,9%



# Filtrado de correo basura

- Reducción de la dimensionalidad
  - Lo habitual es no hacerla
  - Selección de atributos
    - Ganancia de Información
  - Extracción de atributos
    - Indexación Semántica Latente



# Filtrado de correo basura

- Algoritmos de aprendizaje
  - Clasificadores lineales (Rocchio, Winnow)
  - Clasificadores probabilísticos (Bayes Ingenuo)
  - Inducción de árboles de decisión (C4.5)
  - Generadores de reglas (Ripper)
  - Support Vector Machines
  - Redes Neuronales (perceptrón)
  - Aprendizaje perezoso (K-Nearest Neighbors)
  - Comités (Boosting)



# Filtrado de correo basura

- Filtro bayesiano de Graham

## PROBABILIDADES DE TOKENS

ST = veces que T aparece en spam  
S = # mensajes spam  
LT = # veces que T aparece en legítimo  
L = # mensajes legítimos

$$P(T) = \frac{\frac{ST}{S}}{\frac{2 \cdot LT}{L} + \frac{ST}{S}}$$

## PROBABILIDAD MENSAJE

$$P(S) = \frac{\prod_{T \in TM} P(T)}{\prod_{T \in TM} P(T) + \prod_{T \in TM} (1 - P(T))}$$

TM = 15 tokens más  
extremos  
(lejanos de 0,5)



# Filtrado de correo basura

- Compresión [Bratko06]
  - Regla de asignación

$$\text{class}(m) = \underset{c=S,L}{\text{argmin}} \{ |C(c | m)| \}$$

- Aproximación

$$|C(c | m)| \approx |C(c.m)| - |C(c)|$$

- Algoritmos = Dinamic Markov Compression,  
Prediction by Partial Matching



# Filtrado de correo basura

- Resultados de compresión
  - Extraordinariamente efectiva
  - Superior a bayesianos y SVMs
  - Extremadamente resistente a la ingeniería inversa
  - Trivial de implementar

***At TREC 2005, arguably the best-performing system was based on adaptive data compression methods***



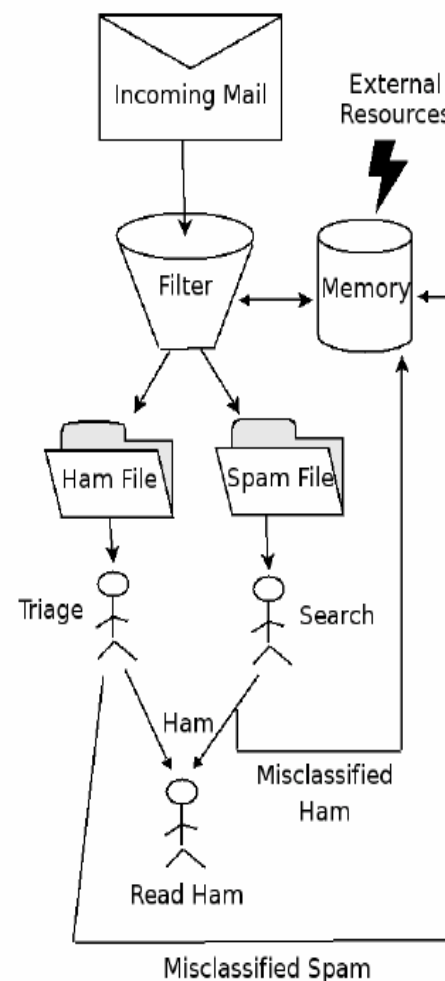
# Filtrado de correo basura

- Evaluación (TREC Spam Track)
  - Aproximación a condiciones más realistas
    - Protocolo interactivo
    - Métricas independientes del coste y distribución
    - Colecciones públicas
  - Resultados más sólidos que los previos



# Filtrado de correo basura

- Operativa TREC
  - *TREC Spam Filter Evaluation Toolkit*
    - initialize
    - classify *message*
    - train ham *message*
    - train spam *message*
    - finalize






# Filtrado de correo basura

- Análisis ROC/AUC (TREC05)

ROC






# Filtrado de correo basura

- Curva de aprendizaje (TREC05)

ROC Learning Curve






# Filtrado de correo basura

- Ataques
  - *Ataques de tokenización*
    - “viagra” => “v i a g r a” “viagra” => “via<!-->gra”
  - *Ataques de ofuscación*
    - “viagra” => “\ / 1 ^ G 4 / \”
  - *Ataques estadísticos*
    - + tokens positivos, - tokens negativos “viagra”
  - *Ataques de ocultación*
    - imágenes, PDF, URLs

# Índice



1. Introducción
2. Categorización de Texto
3. Clasificación de Texto con Adversario
4. Filtrado de correo basura
5. **Filtrado de contenidos Web**
6. Detección de Spam Web
7. Algunas conclusiones
8. Demostraciones

# Filtrado de contenidos Web



- Motivación
  - Contenidos inapropiados según público/lugar
    - Público infantil => pornografía, racismo, anorexia
    - Puesto de trabajo => deportes, casinos, empleo
  - Considerables riesgos para los menores
  - Importantes pérdidas de productividad
  - Adicciones y dependencias




# Filtrado de contenidos Web

- Medidas de control
  - Legales => limitadas por internacionalidad
  - Tecnológicas
    - Listas blancas y negras
    - Palabras clave
    - Análisis inteligente (basado en contenido con aprendizaje)
      - Análisis textual (Categorización de Texto)
      - Análisis de imagen (pornografía, violencia/sectas)

**LA CLAVE ES LA INTEGRACIÓN**

# Filtrado de contenidos Web



- Análisis del contenido textual con aprendizaje
  - Categorización de Texto
    - Representación
    - Reducción de la dimensionalidad
    - Aprendizaje
    - Evaluación

# Filtrado de contenidos Web



- Representación y reducción dimensionalidad
  - HTML => estructura = secciones
  - Tokenización => palabras = secuencias de caracteres alfanuméricos
  - Stemming, stoplist, Part Of Speech
  - Ngramas
  - Pesos binarios, TF, TF.IDF
  - Filtrado por Ganancia de Información



# Filtrado de contenidos Web


- Aprendizaje
  - Clasificador bayesiano ingenuo
  - Árboles de decisión como C4.5
  - Algoritmos basados en reglas como PART
  - Aprendizaje perezoso como kNN
  - Redes neuronales
  - Support Vector Machines
  - Aprendizaje sensible al coste

# Filtrado de contenidos Web



- Evaluación
  - Carencia de colecciones estándar / competiciones
  - Evaluación por lotes
  - Medidas de Recuperación de Información / Aprendizaje Automático
    - Excepción => análisis ROC en [Gomez03]

# Índice



1. Introducción
2. Categorización de Texto
3. Clasificación de Texto con Adversario
4. Filtrado de correo basura
5. Filtrado de contenidos Web
6. **Detección de Spam Web**
7. Algunas conclusiones
8. Demostraciones



# Detección de Spam Web

- Motivación
  - Motores de búsqueda = modelo de negocio basado en publicidad
  - Impacto Web = rentabilidad
    - Search Engine Optimization
  - Fraude en buscadores (*spam Web*)
    - Ranking inmerecido => pérdida de calidad = usuarios
  - Fraude de clicks (*click fraud*)
    - Clicks falsos en anuncios => impacto económico



# Detección de Spam Web

- Tipos de spam Web [Gyongyi05],
  - Spam de términos = palabras clave
  - Spam de enlaces = estructuras de enlaces contra métricas de calidad (e.g. PageRank)
  - Ocultación = colores, estructuras, redirecciones
- Existen métodos específicos para cada tipo



# Detección de Spam Web

- **Análisis del contenido**
  - Genéricamente = CT orientada al género
    - Atributos estilísticos, no temáticos
  - Trabajos adaptados al tipo de spam
    - Spam de comentarios de blog
    - Blogs spam (splogs)
    - Spam de etiquetas (tags)



# Detección de Spam Web

- Distintos ejemplos de atributos
  - Tomados del correo basura
  - Modelos del lenguaje = palabras
  - Consultas populares (extrínsecos)
  - Longitud de oraciones, aparición de palabras frecuentes (stoplist), etiquetas sintácticas
  - Número de palabras en la página y en el título, longitud media de las palabras, cantidad de texto presente en los hiperenlaces, fracción de contenido visible, etc.

# Detección de Spam Web



- Clasificadores
  - Bayesianos
  - Compresión
  - Árboles de decisión
  - Support Vector Machines
  - Regresión Logística



# Detección de Spam Web

- Evaluación
  - Competiciones
    - Web Spam Challenge
    - ECML/PKDD 2008 Discovery Challenge
  - Colecciones públicas
  - Evaluación por lotes
  - Métricas similares a correo spam
    - ROC, AUC, curva de aprendizaje



# Detección de Spam Web

- Web Spam Challenge 2007/I => triunfó comprensión sobre atributos de contenido
- Web Spam Challenge 2007/II => triunfó combinación de contenido + enlaces
- Más cerca de la estandarización que el filtrado Web
  - Más interés económico

# Índice



1. Introducción
2. Categorización de Texto
3. Clasificación de Texto con Adversario
4. Filtrado de correo basura
5. Filtrado de contenidos Web
6. Detección de Spam Web
7. **Algunas conclusiones**
8. **Demostraciones**



# Algunas conclusiones


- Clasificación de texto con adversario = CT con oponente
  - No existe un análisis teórico general multitarea
  - Cada tarea puede tener sus propios costes
- Filtrado de correo basura
  - Tarea de referencia
  - Resultados excelentes (compresión)
  - ***Y sin embargo, el correo basura sigue creciendo ...***



# Algunas conclusiones

- Filtrado de contenidos Web
  - Poco estandarizada
  - Buenos resultados pero sin buenas prácticas
- Detección de spam Web
  - Reciente pero muy atractiva
  - Resultados intermedios por su complejidad
    - El análisis del contenido es importante pero funciona mejor combinar con enlaces

# Índice



1. Introducción
2. Categorización de Texto
3. Clasificación de Texto con Adversario
4. Filtrado de correo basura
5. Filtrado de contenidos Web
6. Detección de Spam Web
7. Algunas conclusiones
8. **Demostraciones**



# Demostraciones

- Herramienta
  - WEKA (*Waikato Environment for Knowledge Analysis*)
  - Herramienta de minería de datos de propósito general
    - Capacidad para análisis de texto
  - Empleada en múltiples experimentos
  - <http://www.cs.waikato.ac.nz/ml/weka/>



# Categorización de texto

- Colección Reuters-21578
  - Noticias periodísticas económicas en inglés
  - Categorías económicas en inglés
  - Multiclase con solapamiento
  - 1504 (13 clases – 11 a 608 ejemplares)
- Representación
  - Minúsculas, stemming, stoplist, pesos binarios



# Filtrado de spam SMS

- Proyecto FISME
  - 1324 (322 spam)
- Representación simplista
  - WEKA – StringToWordVector
- Representación avanzada
  - Palabras, minúsculas, bigramas, trigramas, bigramas de palabras



# Filtrado de pornografía

- Proyecto TEFILA
  - 5992 (996 porno)
  - Español, extraídas del ODP
- Representación
  - Stemming, stoplist, pesos binarios, ganancia de información



# Web Spam

- Web Spam Challenge 2007/I
- <http://webspam.lip6.fr/>
- 77,9M páginas, 11400 hosts
- 6552 hosts analizados
  - Normal - 4,046 - 61.75%
  - Spam - 1,447 - 22.08%
  - Borderline - 709 - 10.82%
  - Could not be classified - 350 - 5.34%

# Web Spam



- Atributos basados en contenido
  - Número de palabras en la página, título, longitud media de las palabras
  - Fracción palabras en *anchor text* sobre total
  - Tasa de compresión bzip
  - Precisión y cobertura sobre el corpus
  - Precisión y cobertura sobre consultas
  - Probabilidad de independencia de trigramas
  - Entropía de trigramas