

Generación de Resumen automático de textos

Workshop UPAO 2008

Juan-Manuel Torres

`juan-manuel.torres@univ-avignon.fr`




Plan

- **Introduccion**
 - Definiciones y resumen humano
 - Estructura de los resúmenes
- **Técnicas**
 - Linguísticas
 - Extracción vs abstracción
- **Resumen por extracción**
 - Procesamiento de Lenguaje Natural
- **Sistema Cortex**
 - Algoritmo
 - Pruebas
 - Nuevas tendencias

Un excitante desafío...

Baje 1000 documentos del web, envíelos al sistema de resumen y elija los mejores leyendo **los resúmenes ordenados por pertinencia...**



Les premières images de Phoenix sur Mars.

La sonde américaine Phoenix a atterri sans encombre dimanche sur Mars et a commencé à livrer ses premières images. Phoenix va tenter d'y sonder le sous-sol. C'est la première sonde à atterrir de manière active (en utilisant des rétrofusées) depuis les deux rover Viking, en 1976. La sonde Phoenix s'est posée avec succès sur la planète Mars, cette nuit à 23h38 (heure française). Des problèmes pendant la descente avaient fait échouer la première tentative d'atterrissage d'un tel vaisseau sur Mars en 1999.

Mots clés : mars[10] phoenix[10] sonder[4] atterrir[3] image[3] vie[3] premier[2] encombrer[2] poser[2]
Extrait généré en 2.895 secondes à partir de 184 phrases, 13 articles (moyenne de 14.153 phr/art)

Score	Sentence
0.359	La sonde américaine Phoenix a atterri sans encombre dimanche sur Mars et a commencé à livrer ses premières images.
0.276	Phoenix va tenter d'y sonder le sous-sol.
0.235	C'est la première sonde à atterrir de manière active (en utilisant des rétrofusées) depuis les deux rover Viking, en 1976.
0.206	La sonde Phoenix s'est posée avec succès sur la planète Mars, cette nuit à 23h38 (heure française).
0.176	Des problèmes pendant la descente avaient fait échouer la première tentative d'atterrissage d'un tel vaisseau sur Mars en 1999.
0.171	Les premières images envoyées par Phoenix montrent que l'appareil a déplié ses panneaux solaires, comme prévu, après que la poussière soit retombée.
0.169	Traces de vie?
0.168	Sur les onze précédentes tentatives de poser des sondes spatiales sur Mars, seules cinq ont réussi.
0.166	Les scientifiques qui contrôlaient le voyage de la sonde spatiale au siège du laboratoire, à Pasadena, près de Los Angeles, se sont félicités de la survie de Phoenix Lander qui a renvoyé des signaux depuis Mars ; et donc ses premières photos.
0.162	La Nasa a utilisé pour réaliser Phoenix des composants conçus pour la sonde Mars Surveyor dont le programme avait été annulé en 2001 suite à l'échec de la mission Mars Polar Lander.
0.161	Lancée le 4 août 2007 sur une fusée Delta 2 de Floride (sud est), Phoenix est la première sonde à s'être posée dans la région arctique de la planète rouge pour y creuser le permafrost.
0.160	« Phoenix est aussi dotée d'instruments qui, en analysant la composition du permafrost martien, sont capables de détecter des molécules de carbone et d'hydrogène, des éléments nécessaires à la vie. La sonde pourra ainsi découvrir d'autres composants chimiques et déterminer ainsi si une forme de vie primitive a été ou est encore possible sur Mars », a déclaré Peter Smith.
	Interrogé sur le processus d'atterrissage de Phoenix Mars Lander, un autre responsable Michael A. Gross l'a qualifié de "six minutes

Titulos – Noticias – Flujo RSS

Actualité et informations sur Wikio - Mozilla Firefox

Fichier Édition Affichage Historique Marque-pages Outils ?

http://www.wikio.fr/

RECHERCHE Dernières nouvelles http://www.univ-avi...

Wikio votre portail d'info

Actualités Blogs Shopping Vidéos Live

Recherche Actualités

Informations en continu de 67191 médias et blogs

connexion inscription

Développement durable par Tetra Pak + Nouvelle Page

Actualités

317 votez Tapie : pas le "réceptacle" du chèque
Le Figaro (s'abonner) | depuis 4 heures | Politique

194 votez Peillon pour une alliance PS-MoDem
Le Figaro (s'abonner) | depuis 1 heure | Politique

181 votez Talibans : un des soldats français a bien été tué à l'arme blanche
Le Point.fr (s'abonner) | depuis 3 heures | International

7 votez Pakistan: le veuf de Benazir va être désigné président par les parlementaires
20 minutes (s'abonner) | depuis 4 heures | International

43 votez Pour prévenir le cancer de l'utérus ... il faut boire du café !
Universal Press Agency (s'abonner) | depuis 49 minutes | Santé

148 votez McCain invite les Américains à combattre à ses côtés pour changer Washington
Corsematin.com (s'abonner) | depuis 2 heures | International

27 votez Britney Spears fera l'ouverture des MTV VMA
Actualité de Stars (s'abonner) | depuis 1 heure | Culture

3 votez Rebsamen appelle le PS à bâtir "une majorité large"
NouvelObs.com (s'abonner) | depuis 1 heure | Politique

72 votez Tennis - US Open - Federer se voit en finale
Sport24 (s'abonner) | depuis 1 heure | Sport

2 votez CORRECTION - Le chômage au plus haut depuis décembre 2003 aux USA en août
Challenges.fr (s'abonner) | depuis 22 minutes | Société

> voir toute l'actualité du jour

Shopping

Produit Star
Roomba 560
★★★★★
319,90 € à 399,00 €

Top Produits

1. HTC Touch Diamond
2. Nikon D700
3. Nikon D90
4. Acer Aspire One A150-Bb1
5. MSI Wind U100-014

Top Buzz

1. Palm Treo Pro
2. Nikon D90
3. HTC S740
4. Nokia N85
5. Nokia N79

Nouveaux Produits

1. Sony TA-DA6400ES
2. Yamaha RX-V3900
3. Mitac MISTATION
4. Panasonic SC-H7
5. NEC MultiSync EA221WM

> voir tout le shopping

Participer

proposez votre site
publier un article en direct
contributeurs les plus actifs
dernières contributions

Vidéos

A l'aube d'un nouveau buzz initié par les blogs ? Laurent Lemoine - Nettoie ton vinyle
> voir la vidéo

Rachida Dati enceinte : José Maria Aznar le papa ?
> voir la vidéo

Spore : comment allez vous créer l'univers ?
> voir la vidéo

Google Chrome à télécharger sur Numerama
> voir la vidéo

Clash Lily Allen-Elton John, la vidéo!!!
> voir la vidéo

> voir le top des vidéos

Blogs

3 votez Segolene Royal dans les choux avec certitude...
TRITZ du Monde 3 (s'abonner) | depuis 6 heures | Politique

3 votez Dans le c... l'iPhone
Le Journal du Geek (s'abonner) | depuis 15 heures | High-Tech

4 votez Weneo Pass, La SNCF va tester la Clé USB de paiement sans contact
Nowhere Else 2.0 (s'abonner) | hier | High-Tech

Explorer

Afrique Alstom Auto Bangkok Blogosphère Bourse Brésil Caen Chine Cinéma Culture
Dick Cheney Droit Economie Emploi Environnement Europe Festival de
Berlin Football France François Fillon High-Tech Informatique
International Internet iPhone nano Jeux olympiques Jeux vidéo
Justice Loisirs Marina Petrella Météo Michael Phelps Musique
Nicolas Sarkozy Pékin 2008 People Podcast Politique Santé
Science Secret Story Société Spanair Sport Tableau des médailles
Téléchargement Télévision Tennis Univers Web 2.0

Resume automatique - Recherche Google - Mozilla Firefox

Fichier Edition Affichage Aller à Marque-pages Outils ?

http://www.google.fr/search?hs=jv5&hl=fr&client=firefox-a&rls=org.mozilla%3Afr%3Aofficial&q=Resume+automatique&btnG=Rechercher&meta=

TALN Nautitia Gestion des... Web Term Documen... SENSUS demo System Quirk UNED Group in Natu... Departamento de In... Program 1 SELFHTML: CGI/Perl... UNIVERSIA-MIT-OP...

Web Images Groupes Annuaire Actualités plus »

Google

Recherche avancée
Préférences

Rechercher dans : ☒ Web ☐ Pages francophones ☐ Pages : France

Web Résultats 1 - 10 sur un total d'environ 1 250 000 pour Resume automatique. (0,25 secondes)

Pertinence Mining - Traitement de l'information textuelle
... ne nécessite aucune inscription et ne sert que de DEMO de sensibilisation au couplage de deux technologies : **Résumé automatique** + Moteur de recherche ...
www.pertinence.net/ - 15k - [En cache](#) - [Pages similaires](#)

RALI: Résumé automatique
Les activités du RALI dans le domaine du **résumé automatique** s'articulent autour de trois projets principaux: SumUM pour les articles scientifiques ...
rali.iro.umontreal.ca/Resume/index.fr.html - 7k - [En cache](#) - [Pages similaires](#)

Résumé automatique de textes
Le **résumé automatique** de textes : solutions et perspectives, J. Minel, - Narrative Summarization, I. Mani, - **Résumé** de textes juridiques par identification ...
www.atala.org/article.php3?id_article=24 - 18k - [En cache](#) - [Pages similaires](#)

Le résumé automatique des textes scientifiques et techni
Le **résumé** de texte **automatique** s'inscrit dans le cadre de l'ingénierie
To produce the RAFI system (**Résumé Automatique** à Fragments Inc
www.atala.org/article.php3?id_article=208 - 21k - [En cache](#) - [Pages similaires](#)
[[Autres résultats, domaine www.atala.org](#)]

Appel à participation : Filtrage et resume automatique de l ...
Évaluation, rectification et pertinence du **résumé automatique** de texte pour une utilisation en réseau, Abderrafih LEHMAM. ...
www.lri.fr/Services/Archives-majordomo/interactif/msg00030.html - 16k - [En cache](#) - [Pages similaires](#)

NetEconomie :: Pertinence.net veut démocratiser le résumé automatique
Pertinence.net veut démocratiser le **résumé automatique**. vedette La Jeune pousse
Pertinence.net propose un service en ligne de **résumé automatique** des ...
www.neteconomie.com/perl/navig.pl?neteconomie/infos/article/20011004152944 - 25k - 14 sep 2005 - [En cache](#) - [Pages similaires](#)

sujet stage résumé automatique
Résumé automatique par filtrage sélectif Contexte La tâche de **résumé** est avant tout une tâche de compréhension de texte : dans une première étape il s'agit ...
www.limsi.fr/Individu/mhp/stageDEA/NH-05.html - 3k - 13 sep 2005 - [En cache](#) - [Pages similaires](#)

Outils Froids - Resume Automatique
Outils de **résumé automatique**. De La Cartographie Pour Pertinence Mining · Fourre Tout Numero Quatre · Pertinence **Resume** Les Resultats De Google ...
www.outilsfroids.net/texts/ResumeAutomatique.shtml - 19k - [En cache](#) - [Pages similaires](#)

GFII - Séminaire "Le résumé automatique : état de l'art technique ...
MINEL Jean-Luc, Filtrage sémantique : du **résumé automatique** à la fouille de ...
Pertinence Summarizer : un outil de **résumé automatique** au service de la ...
www.gfi.fr/ressources/6040513/ressources.htm - 7k - [En cache](#) - [Pages similaires](#)

Terminé

Démarrer 3 Explorateur ... 3 OpenOffice.o... 9 Firefox ~/Projets/Versio... PERL - Microsoft ... Courrier entrant ... Microsoft PowerP... 09:37 a.m.

Busqueda de informacion

The Minimum Number of Errors in the N -Parity and its Solution with an Incremental Neural Network

J. MANUEL TORRES-MORENO^{1*}, JULIO C. AGUILAR²,
and MIRTA B. GORDON³

¹École Polytechnique de Montréal, Département de Génie informatique, CP 6079 Succ.
Centre-ville, H3C3A7 Montréal (Québec) Canada. e-mail: juan-manuel.torres@polymtl.ca

²Laboratorio Nacional de Informática Avanzada (LANIA), Rébsamen 80-91090 Xalapa,
México

³Laboratoire Leibniz – IMAG (CNRS), 46, Avenue Félix Viallet, 38031 Grenoble Cedex,
France

Abstract. The N -dimensional parity problem is frequently a difficult classification task for Neural Networks. We found an expression for the minimum number of errors v_f as function of N for this problem, performed by a perceptron. We verified this quantity experimentally for $N = 1, \dots, 15$ using an optimal train perceptron. With a constructive approach we solved the full N -dimensional parity problem using a minimal feedforward neural network with a single hidden layer of $h = N$ units.

Key words. classification tasks, minimerror, monoplan, parity problem, perceptrons, supervised learning

1. Introduction

The Neural Networks Community has studied the N -dimensional parity problem for a long time. In their celebrated book, Minsky and Papert [1] elegantly demonstrated that perceptrons are unable to solve non linearly separable problems, such as the parity of 2 inputs (or their equivalent one, the or-exclusive problem, XOR). The capacity of a simple perceptron is limited, since it is unable to solve problems that are linearly separable [6, 7]. The problem still becomes difficult in small dimensions: $N \leq 5$ and it is increased exponentially in function of the number of available patterns. This problem has been attacked by several methods such as Gradient Backpropagation (BP) and its variations. These methods have difficulties even in small dimensions due to the problem of the local minima in those in which the minimization of the cost function may fall. An alternative approach is to use Incremental Neural Networks methods that add units while learning errors exist, following a suitable heuristic, as we show it in Section 4.

Articulos científicos, Reportes...

The N -dimensional parity problem can be formulated as a supervised learning problem with a learning set of P patterns with N binary inputs $\xi_i = \pm 1$, $i = 1, \dots, N$, and a binary output $\tau = \pm 1$:

$$C = \{(\xi^{\mu}, \tau^{\mu}) \mid \mu = 1, \dots, P\} \quad (1)$$

Parity is difficult because a linear function is used, and the problem is not linearly separable. The problem has been studied for the last 40 years, but it is a highly non-linear problem. It is difficult to discriminate between the positive and the negative patterns.

one, $\tau = -1$. The problem is considered exhaustive learning, because all the $P = 2^N$ different patterns examples must be learned. The N -parity's problem becomes quickly complicated due to the neighboring states in input's space (its Hamming distances are $d_H = 1$) with opposite outputs. A solution with binary poids perceptrons has been should in [22].

The input's space for the N -dimensional parity and the separating hyperplanes w are represented for values of $N = 2, 3, 4$, in Figures 1(a), 1(b) and 2.

2. Finding the Minimum Number of Errors

Following a constructive approach, an incremental Neural Network adds hidden units one to one, until it is capable of eliminating learning errors. In N -dimensional parity, the problem is quite difficult for the first unit because it should find the




Figure 1. N -dimensional parity: (a) $N=2$, (b) $N=3$.



Produits et services en ligne pour le traitement de l'information

PERTINENCE MINING
82, avenue Jean Jaurès
94400 Vitry-sur-Seine, FRANCE
Tél/Fax: +33 (0)1 43 91 45 90
e-mail: contact@pertinence.net



PERTINENCE MINING

SARL

Siret : 442 064 028 00016

Site web : <http://www.pertinence.net> ou <http://www.pertinence-mining.com>

FICHE DESCRIPTIVE : PERTINENCE SUMMARIZER

OFFRE :

- Version monoposte,
- Version serveur,
- API Web Service,
- API Java

www.pertinence.com

Mead Demo

1. Add Documents

Add a file from your computer

Add your own text

Add a URL

Add a directory of files

2. Submit files for summarization

Compression rate

Terminé

2 Interpréte... 4 Explorateur... MICAI2007_EN... let2-g5-torres... 4 OpenOffice... Licence et Mast... Demo of Mea... Annuaire - Moz... FLORIAN-BELG... 12:15

MEAD
tangra.si.umich.edu/clair/md/demo.cgi



www.copernic.com


LIA YACHS Resumenes de Quimica Organica

<http://daniel.iut.univ-metz.fr/yachs>

The screenshot displays the yachs2 web application running in a Mozilla Firefox browser. The browser's address bar shows the URL <http://daniel.iut.univ-metz.fr/~florian/>. The page header includes navigation links: [Tutorial Video \(new\)](#), [What's Inside ?](#), and [Contact](#). The main content area features a large, repeating pattern of chemical structures in the background. Overlaid on this pattern is the text "Welcome to yachs2" and a button labeled "Upload a file | Copy & Paste". The footer of the application includes the "YachS2" logo, the "LABORATOIRE INFORMATIQUE D'AVIGNON" logo (Université d'Avignon et des Pays de Vaucluse), and a copyright notice: "Copyright © 2008 Florian Boudin". The browser's taskbar at the bottom shows several open applications, including "Démarrer", "OTM'08 Federated...", "yachs2 (ver. 2.0....)", "VERSION_DEFINIT...", "RA", "Courrier entrant - ...", "pres_UCE_ressour...", "UCE-V3.doc - Ope...", "00-Intro - OpenOff...", and a system clock showing "16:15".

Mapas graficos — orientacion

Route:



Use Subject to [License / Copyright](#)

Origin:

Culver City, CA



Destination:

Marina del Rey, CA



GUIAS Cine / télé... — decisiones

2:30am

VC2 – 76

The Jackal

Movie: Bruce Willis excels as "The Jackal," a cunning assassin who uses many disguises in this 1997 thriller. Richard Gere and Sidney Poitier costar as players from different sides of the law who unite to stop him.

3:00am

KCOP – 13

The Untouchables

Movie: Eliot Ness (Kevin Costner) and "The Untouchables" take on Robert De Niro's flamboyant Al Capone in the pulse-pounding 1987 adaptation of the popular TV series. Sean Connery won an Oscar as the Irish beat cop who shows Ness "the Chicago way." Brian De Palma directed the feature; David Mamet wrote the script. And yes, film majors, the scene at Union Station was lifted directly from the


3:05am

STARZ – 25

Grosse Pointe Blank

Movie: A razor-sharp script and a fine turn by John Cusack as a troubled hit man mark 1997's "Grosse Pointe Blank," a dark comedy in which the assassin encounters his old flame (Minnie Driver of "Good Will Hunting") at a high-school reunion. Cusack's sister Joan ("In and Out") is hilarious as the killer's devoted assistant, and Alan Arkin makes the most of his small role as Cusack's terrified the

El GRAN problema...



¿Qué es un resumen ?

« Transformación reducida de un texto fuente hacia un resumen por compresión del contenido por medio de una selección y/o generalización de lo que es importante en el texto fuente »

Karen Sparck Jones

- ***Representación abreviada y precisa del contenido de un documento***


Preguntas

- ¿ Qué **tipo** de resúmen buscan las personas ?
- ¿ Cuál debe ser el **grado de sofisticación** de los sistemas de resúmen ?
 - ¿ Los métodos estadísticos son suficientes ?
 - ¿ Necesidad de métodos simbólicos profundos para “comprender” ?
- ¿ Cómo **medir la calidad** de un resúmen ?

Características del resumen

- **Indicativo / Informativo**
 - Indicativo : indica la naturaleza del texto
 - Informativo : Intenta substituir al texto
- **Extracto o Resumen**
 - **Extracto** : frases extraídos del texto
 - **Resumen** : reformula, comprime el texto
- **Tamaño**
 - Tasa de compresión = $|Resumen| / |Texto|$

¿ Cómo hacen los humanos para producir resúmenes... ?



¿ Quién hace resúmenes ?

- **Autor**
- **Experto**
 - Actualizado en el dominio de los documentos a analizar
- **Profesional en resúmenes**
 - Analiza los documentos y la redacción de los resúmenes
 - Experto en **esta** disciplina
 - Normas de producción de resúmenes

Resumen profesional

WebSPIRS - Netscape

Records: 1 to 1 of 1
Search: **distributed breadth first search**

Print Save E-mail Back to Search

<HPrevious NextH> Change Display Go To: 1

☐ **Record 1 of 1 in Library and Information Science Abstracts (1969-2002/10)**
TI: Efficient **distributed breadth-first search** algorithm.
AU: [Makki-S-A-M](#)
SO: [Computer-Communications](#). 19 (8) Jul 96, p.628-36. refs..
PY: 1996
IS: 0140-3664
AB: Presents a more efficient **Distributed Breadth-First Search** algorithm for an asynchronous communication network. Presents a model and gives an overview of related research. Analyzes the complexity of the algorithm, and gives some examples of performance on typical networks. SE
CP: (c)1999 Reed Business Information Ltd.
[Check for holdings →](#)
[View Complete Record](#)


Logout
HELP
Databases
Searches
Suggest
Index
Thesaurus
Database Information
☒ Show Marked Records
Important Message
About WebSPIRS

Document: Done

Cremmins'82-'96: operaciones de edición

Operaciones de edición utilizadas

- Revisión local : contenido en una frase
- Revisión global : contenido a través de las frases



Tiempo de generación del resumen

**Cremmins recomienda entre 12-20 min
para resumir un artículo científico
típico...**

**¡Un tiempo mucho menor del necesario
para realmente *comprenderlo* !**

Endres-Niggemeyer et al. (1995, 1998)

- Los resumidores no leen ***jamás el documento completo***
- **Estructura** del documento
 - Formato
 - Disposición
 - Esquemas
- Nivel de **discurso** : de qué habla el documento

Resumidores profesionales

- Producen buenos resúmenes (***savoir-faire***)
- **Indicaciones** de agencias
- **Normas** internacionales
- **Selección** de la información
 - Títulos/Encabezados/Leyendas
 - Introducción/Conclusión
 - Objetivo, metodología, resultados
 - ...
- **Redacción** del resumen
 - Re-utilización de frases
 - Transformación y aplicación de patrones de redacción


Transformaciones

- Re-expresión de conceptos
- Eliminación
 - Estructuras
 - Frases
 - Texto entre paréntesis
- Expansión de abreviaturas
- Abreviaturas
- Pegar, Separar
- **Ninguna**


Observaciones

- **70% de las frases son copiadas literalmente**
(Lin & Hovy 2003)
- ¿ La gente **sabe escribir** correctamente y **sintetizar** ideas ?
- Los resúmenes del autor ¿ son **pertinentes** ?
- Los resúmenes profesionales ¿ son **realmente** pertinentes ?

¿ Cómo hacen los sistemas automáticos para producir resúmenes... ?




Esquema basico



El método del buen alumno

Compréhension + génération



- Necesita conocimientos del dominio (temática)
- Necesita conocimientos de la lengua en la cual se genera el resumen...

Resúmen por comprension : FRUMP

a small earthquake shook several Southern Illinois counties Monday night, the National Earthquake Information Service in Golden, Colo., reported. Spokesman Don Finley said the quake measured 3.2 on the Richter scale, "probably not enough to do any damage or cause any injuries." The quake occurred iabout 7:48 p.m. CST and was centered about 30 miles east of Mount Vernon, Finlay said. It was felt in Richland, Clay, Jasper, Effington, and Marion Counties.

There was an earthquake in Illinois with a 3.2 richter scale. (RESUME) ↵

FRUMP

- Estructura de base : *sketchy-scripts*
adaptación de scripts de Shank & Abelson
(1977)
- Scripts contienen información importante de
un evento
- 50 sketchy-scripts producidos manualmente
Interpretación de un texto : lectura rápida
(skimming)


FRUMP : los contras ...

- 50 scripts son muy **pocos** para interpretar el mundo
- Conocimientos ***codificados manualmente***
- ¿ Cómo aprender scripts de nuevos temas ?

Ciudad del Vaticano. La noticia de la muerte del Papa sacude el mundo. Murió el martes pasado de forma misteriosa... (TEXTO)

Sismo en el Vaticano : un muerto. (RESUMEN)

El método del alumno flojo



Identificar frases importantes:


- Por su posición
- Por su frecuencia de palabras
- Por sus conectores retóricos
- Por su similitud con otras frases
- ...

Resumen por extracción de frases

- + Simple a programar
- + Robusto
- + Rápido
- ¿ Cómo descubrir qué tipo de información lingüística/semántica es relevante para el contenido ?
- ¿ Coherencia ?
- ¿ Cohesión ?

Enfoque de la RI (Luhn'58-59)

- Extracto = frases significativas
- Una frase significativa contiene palabras significativas (palabras-claves)
- Palabras significativas entre A y B



(Luhn, 59)

Tabla de frecuencias

theater	3.0
pretenderlo	
codazzi	2.0
preteto	1.0
tierreno	1.0
azliun	1.0
cviles	1.0
contemporaneas	1.0
prosirio	9.0
política	1.0
civiltá	1.0
linfoma	3.0
...	
el	52447

$$w_{ij} = \text{tf}_{ij} \cdot \log_2 \frac{N}{n}$$


No. DE FRASES = 60644

idf (el) = $\log(60644/52447)$ = 0.063

idf (prosirio) = $\log(60644/9)$ = 3.82

Problemas : cohesión

- Extractos de frase por frase pueden ser **incoherentes** y difíciles a leer



- Solución: adicionar frases necesarias para producir un pasaje adecuado
- ¿ existen partes sobre-representadas ?
- ¿ hay partes que se olvidaron ?

Problemas : cohesión

La cadena de supermercados Metro anunció que los negocios van muy bien. El mes pasado las ventas aumentaron 10% y se estudia la creacion de nuevos puestos. Por otro lado, la compania de supermercados Carrefour anunció perdidas de 30% al ultimo trimestre. El directorio se reunio hoy para decidir la posibilidad de reducir su personal. (CORPUS)

La cadena de supermercados Metro anunció que los negocios van muy bien. El directorio se reunio hoy para decidir la posibilidad de reducir su personal.

(EXTRACT)

Dificultad de la evaluación

- NO EXISTE UN ÚNICO RESUMEN válido para un texto
- Lenguaje natural producido por una máquina
- Personas juzgando incrementa el coste
- Resumir conlleva compresión (reducción de tamaño).
Es necesario evaluar resúmenes de distintos tamaños
- Legibilidad (puede no tener relación con la calidad del resumen)
- En relación con las expectativas de la tarea

Evaluacion

- Intrínsecos
 - Calidad (por personas - No siempre acuerdo)
 - Legibilidad, comprensión, acrónimos, anáforas, integridad de la estructura, gramaticalidad, estilo impersonal, ...
 - Informatividad
 - Información preserva respecto al texto original (varias compresiones)
 - Información contiene respeto a un **resumen ideal**

ROUGE

(Lin, ROUGE DUC-NIST, 2004)



ROUGE-2 : Intersección de bigramas
ROUGE-SU4 : Intersección de bigramas separados por un hueco de hasta 4 palabras

Universidad Privada Antenor Orrego

ROUGE-2 : Universidad Privada, Privada Antenor,
Antenor Orrego

ROUGE-SU4 : Universidad Privada, Universidad Antenor,
Universidad Orrego, Privada Antenor,
Privada Orrego, Antenor Orrego

Y ahora, un sistema real...



CORTEX es Otro Resumidor de TEXtos

Juan-Manuel Torres-Moreno

juan-manuel.torres@univ-avignon.fr

LIA/Université d'Avignon

Sistema CORTEX

Tres niveles : (Torres, Meunier, Velazquez, 2002-2004)

- 1. Módulos de transformación :** Segmentacion, Filtrado, lematización, sinónimos, anáforas, ...
- 2. Módulos de extracción :** Métricas, algoritmo de decisión, resumen personalizado ...
- 3. Módulos de generación de resúmenes:** Identificación de conceptos, generación por templates, ...

Una cadena de funciones



LATAO : **L**ecture et **A**nalysé de **T**extes **A**ssistés par **O**rdinateur (Lectura y Analisis de Textos Asistido por Computadora)

Unidades de información

« *La plume de ma tante* »


3-gramas

Palabras


{la, plume, de, ma, tante}

{la_, a_p, _pl, plu, lum, umm, mme, me_, e_d,
de ,de, e_m, ma_, a_t, _ta, tan, ant, nte}


Unidades de segmentación




La vectorización de un texto (1)




La vectorización de un texto (2)



La vectorización de un texto (3)



La vectorización de un texto (4)



Matrices término-segmento

Frecuencia γ

$$\gamma = \begin{bmatrix} \gamma_1^1 & \gamma_2^1 & \gamma_3^1 & \dots & \gamma_i^1 & \dots & \gamma_{N_L}^1 \\ \gamma_1^2 & \gamma_2^2 & \gamma_3^2 & \dots & \gamma_i^2 & \dots & \gamma_{N_L}^2 \\ \gamma_1^3 & \gamma_2^3 & \gamma_3^3 & \dots & \gamma_i^3 & \dots & \gamma_{N_L}^3 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ \gamma_1^\mu & \gamma_2^\mu & \gamma_3^\mu & \dots & \gamma_i^\mu & \dots & \gamma_{N_L}^\mu \\ \vdots & \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ \gamma_1^{N_P} & \gamma_2^{N_P} & \gamma_3^{N_P} & \dots & \gamma_i^{N_P} & \dots & \gamma_{N_L}^{N_P} \end{bmatrix}, \quad \gamma_i^\mu \in \{0, 1, 2, \dots\} \quad (2)$$


Binaria ξ

$$\xi_i^\mu = \left\{ \begin{array}{ll} 1 & \text{si } \gamma_i^\mu \neq 0 \\ 0 & \text{si } \gamma_i^\mu = 0 \end{array} \right\}$$

« Huella digital » de un texto


- ¿ Cómo utilizar la información que contienen las matrices del texto?
- ¿ Se pueden visualizar las características propias de un texto ?

Matriz Termino-Segmento




¿ Identificación de estilos ?


Riqueza
del léxico



Modelo vectorial



Modelo vectorial



Ejemplo

- Texto « Puce»
 - Invasión de “puces” (pulgas) y de “poux” (piojos) : Puce Bio
- Pequeño comunicado en Internet

Invasion de puces et de poux - Microsoft Internet Explorer

File Edit View Favorites Tools Help

Back Forward Stop Home Search Favorites Media Print Link Copy Paste Address http://www.admin.ch/cp/f/1997Sep10.064053.8237@idz.bfi.admin.ch.html Go

Google Search Web Search Site PageRank Page Info Up Highlight

 **CONFOEDERATIO HELVETICA**
Les autorités fédérales de la Confédération suisse

Page d'accueil
Courrier
Recherche

[Archives des communiqués](#)
[septembre 1997](#)

[deutsch](#)
[italiano](#)

Invasion de puces et de poux

Communiqué aux agences de presse du 9 septembre 1997

Avenches: Invasion de puces et de poux à l'école de recrues d'infanterie d'exploration et de transmission 213

Les cantonnements de la compagnie IV de l'école de recrues d'infanterie d'exploration et de transmission 213, stationnée à Avenches, sont envahis par les puces et les poux. Des piqûres de puces ont été relevées sur plus d'un tiers des militaires. On a aussi retrouvé des cadavres de poux sur 3 militaires. Des mesures d'urgence ont été prises en conséquence.

Des piqûres de puces ont été diagnostiquées sur plus d'un tiers des 155 hommes de la compagnie IV de l'école de recrues d'infanterie d'exploration et de transmission 213. Des cadavres de poux, mais aucun oeuf, ont également été décelés sur 3 militaires. Ces insectes sont transmis par contact personnel. La cause de cette invasion n'est pas claire; ces insectes semblent toutefois avoir essaimé à partir du local de garde.

Le médecin de troupe a donné immédiatement les soins nécessaires aux militaires concernés et il a ordonné les mesures d'hygiène qui s'imposaient. Des produits spéciaux ont été remis pour les soins corporels. Tout le matériel personnel de la compagnie a été emballé hermétiquement et apporté à l'arsenal cantonal de Fribourg. La troupe sera déplacée dans un complexe industriel. Une section d'hygiène de l'école de recrues d'hôpital 268, stationnée à Moudon, va désinfecter tous ces cantonnements. On estime qu'avec ces mesures sanitaires appropriées la troupe pourra réintégrer ses cantonnements vendredi au plus tard.

Renseignements complémentaires: Colonel EMG Peter Meier, commandant de l'école de recrues d'infanterie d'exploration et de transmission 213 Téléphone 026-350 82 00

Resumen autor

Corpus del texto

Done Internet

Start Voyages-sn... Invasion ... 3 1/2 Floppy ... poster arco2001_p... Microsoft P... EN 20:27

Invasion de puces et de poux - Microsoft Internet Explorer

File Edit View Favorites Tools Help

Back Forward Stop Home Search Favorites Media Print Link E-mail

Address http://www.admin.ch/cp/f/1997Sep10.064053.8237@idz.bfi.admin.ch.html Go

Google Search Web Search Site PageRank Up Highlight

 **CONFOEDERATIO HELVETICA**
Les autorités fédérales de la Confédération suisse

[Archives des communiqués septembre 1997](#)

Page d'accueil
Courrier
Recherche

[deutsch](#)
[italiano](#)

Invasion de puces et de poux

Communiqué aux agences de presse du 9 septembre 1997

Avenches: Invasion de puces et de poux à l'école de recrues d'infanterie d'exploration et de transmission 213

Les cantonnements de la compagnie IV de l'école de recrues d'infanterie d'exploration et de transmission 213, stationnée à Avenches, sont envahis par les puces et les poux. Des piqûres de puces ont été relevées sur plus d'un tiers des militaires. On a aussi retrouvé des cadavres de poux sur 3 militaires. Des mesures d'urgence ont été prises en conséquence.

Des piqûres de puces ont été diagnostiquées sur plus d'un tiers des 155 hommes de la compagnie IV de l'école de recrues d'infanterie d'exploration et de transmission 213. Des cadavres de poux, mais aucun oeuf, ont également été décelés sur 3 militaires. Ces insectes sont transmis par contact personnel. La cause de cette invasion n'est pas claire; ces insectes semblent toutefois avoir essaimé à partir du local de garde.

Le médecin de troupe a donné immédiatement les soins nécessaires aux militaires concernés et il a ordonné les mesures d'hygiène qui s'imposaient. Des produits spéciaux ont été remis pour les soins corporels. Tout le matériel personnel de la compagnie a été emballé hermétiquement et apporté à l'arsenal cantonal de Fribourg. La troupe sera déplacée dans un complexe industriel. Une section d'hygiène de l'école de recrues d'hôpital 268, stationnée à Moudon, va désinfecter tous ces cantonnements. On estime qu'avec ces mesures sanitaires appropriées la troupe pourra réintégrer ses cantonnements vendredi au plus tard.

Renseignements complémentaires: Colonel EMG Peter Meier, commandant de l'école de recrues d'infanterie d'exploration et de transmission 213 Téléphone 026-350 82 00

Resumen autor


Resumen Cortex

El regimiento de la compania IV de la escuela de infanteria y de transmision 213 de Avenches, fue invadido por pulgas y piojos. Una seccion de higiene de la escuela del hospital 268 de Moudon, va a desinfectar los cuarteles


Done Internet

Start Voyages-sn... Invasion ... 3 1/2 Floppy ... poster arco2001_p... Microsoft P... 20:27


CORTEX: una maquina de resúmenes




Cortex : *O*tro *R*esumidor de *TEX*tos



Cortex : tecnologia



Cortex : tecnología



Pre-procesamiento

- Segmentación
- Filtrado
- Lematización
- Generación de matrices

**Medio simple de acercarse a la
semántica**

Segmentación

- **Por frases**

- Marcadores . : ? !

- **Por párrafos**

- n frases
 - **Identificación del párrafo**

Filtrado

- Texto entre paréntesis (bla blabla bla, bla)
- Números / cifras
- Palabras funcionales
 - Artículos, conjunciones, pronombres...
- Verbos funcionales
 - SER, ESTAR TENER, DEBER,...
- Expresiones
 - Es decir, entonces, a lo mejor, ...

Filtrar palabras funcionales

Palabras muertas del vocabulario

- ¿Cuáles ?
 - Palabras muy frecuentes (artículos, coordinación, pronombres ...) : **de, la, l', le, à, les, et, des, d', en, un , du, une, ...**
- ¿ Las palabras-funcionales son realmente inútiles ?
 - Utiles : clasificar textos
 - Utiles : reconocimiento de la palabra
 - Inútiles : indexación de documentos
 - **Inútiles : resumen por extracción**

Lematizacion

- **Cantar, cantemos, canten, cantaban, cantantes, cantó, cantarían, cantador, canción, cancionero,...**

⇒ CANTAR

- **Reducir el espacio vectorial**
- **Diccionarios**
 - ~ 200 000 formas en francés
 - ~ 500 000 formas en español

Vectorizacion


Las casas azules de mis tias.

Una de mis tias se llama Lulu.

Me gusta mucho su casa.

El azul es mi color !

Yo tengo unos zapatos azules nuevos.




casa	azul	tia	llamar	lulu	gustar	nuevo	zapato	color
TF	TF	TF	0	0	0	0	0	0
0	0	TF	TF	TF	0	0	0	0
TF	0	0	0	0	TF	0	0	0
0	TF	0	0	0	0	0	0	TF
0	TF	0	0	0	0	TF	TF	0

- Modelo vectorial (bag-of-words)
- Palabras filtradas, normalizadas y lematizadas



Métricas

- **Frecuenciales**
 - Frecuencia
 - Probabilidades
 - $TF*IDF$
- **Informacionales**
 - Entropía
 - Interacción
- **Hamming**
 - Peso, longitud, distancia
- **Títulos**
 - Títulos, sub-títulos...
- **Posición**
- **Otras**

CORTEX : estructura



Ejemplo


		Palabras 								
		a	b	c	d	a	b	c	d	
Frases 		$i=1$	$i=2$	$i=3$	$i=4$		$i=1$	$i=2$	$i=3$	$i=4$
	$\mu=1$	1	1	0	0	$\mu=1$	1	1	0	0
	$\mu=2$	1	10	1	0	$\mu=2$	1	1	1	0
	$\mu=3$	1	0	1	2	$\mu=3$	1	0	1	1
Matriz frecuencias						Matriz binaria				

Matrices huecas

BIBLE.TXT : 99.27% está vacío (CORAN tambien!)

- **801920** palabras en total / 50019 frases
- 8195 palabras diferentes / 49993 frases
- **5777** palabras ($f > 2$) / 45250 frases
- Tiempos en G5 Mac OSX
 - **Segmentación en 8 segundos**
 - **Resumen en 5 minutos**


Matrices huecas



Frecuencia de las palabras


- Palabras **pertinentes** de la frase
- Más palabras importantes tiene la frase → más posibilidades de retenerla
- Más larga es la frase → más palabras pertinentes → más posibilidades de retenerla
- **Resúmenes constituidos generalmente de frases largas**

Cálculo de la Frecuencia F


		Palabras					
Frases		$i=1$	$i=2$	$i=3$	$i=4$		
	$\mu=1$	1	1			F	
	$\mu=2$	1	10	1		2	
	$\mu=3$	1		1	2	12	
						4	
							
						$\Sigma = T = 18$	
		p	3/18	11/18	2/18	2/18	

Interacción de frases *I*

- Cortex es un sistema que crea redes de palabras
 - Palabras de la misma familia
 - Presencia de estas palabras en otras frases del texto



Cálculo de *Interacciones*



Frecuencias y rareza

- La frase X contiene la misma palabra 10 veces
- Esa palabra no está en ninguna otra frase
- La frase X puede ser seleccionada por su alta frecuencia ($F = 10$)
- Esto es grave: esta palabra podría no ser importante

Frecuencias y rareza

- Sea otra palabra que aparece solo 1 vez en la frase X , pero que está en otras frases (una vez en cada frase)
- Además esta palabra se encuentra en el título (**tema principal**)
- Consecuencia : la métrica F escogerá la frase X en lugar de otras frases que contienen por lo menos una palabra del título

Frecuencias y rareza

Tener una frecuencia $F=10$ es *positivo*, pero
¿ realmente la frase X merece tener una
alta ponderación ?

¿ Qué hacer ?

- **Re-ponderar** la frecuencia de las palabras
por su rareza

Calculo Frecuencia x rareza

*Rareza palabra 1 = 3; Rareza palabra 2 = 1;
Rareza palabra 3 = 1; Rareza palabra 4 = 1*

Frases		$i=1$	$i=2$	$i=3$	$i=4$			
	$\mu=1$	1				F		$F \times Rareza$
	$\mu=2$	1	10			1	$1 \times 3 = 3$	
	$\mu=3$	5		1	1	$1 + 10 = 11$	$1 \times 3 + 10 \times 1 = 13$	
						$5 + 1 + 1 = 7$	$5 \times 3 + 1 \times 1 + 1 \times 1 = 17$	
		3	1	1	1			

Rareza 

Entropía

- **Entropía** : medida que depende de la probabilidad p_i de una palabra
- Derivada de la teoría de la información
- Entre mas elevada sea p_i de las palabras seran mas favorizadas las frases que las contienen

$$E^\mu = - \sum_{\substack{i=0 \\ \xi_i^\mu \neq 0}}^{N_L-1} p_i \log_2 p_i$$

Cálculo de *Entropía*

		Palabras				
		$i=1$	$i=2$	$i=3$	$i=4$	F
Frases	$\mu=1$	1	1			
	$\mu=2$	1	1	1		0.67
	$\mu=3$	1		1	1	
p		3/18	11/18	2/18	2/18	

$$\begin{aligned}
 E &= - [p(1) \log p(1) + p(2) \log p(2) + p(3) \log p(3)] \\
 &= 0.129 + 0.30 + 0.244 = \mathbf{0.67}
 \end{aligned}$$

Matriz de Hamming H

Un autor varia el vocabulario: utiliza **sinónimos**

Idea : Bonificar la frase donde solo **una** de 2 palabras está presente

La matriz de Hamming trata de evaluar hasta qué punto 2 palabras son utilizadas individualmente:

- Localizar los sinónimos pertinentes

Cálculo : *Matriz de Hamming*

	1	$i=2$	$i=3$	4
1	1	1	0	0
2	1	1	1	0
3	1	0	1	1

Palabras

	$i=1$	$i=2$	$i=3$	$i=4$
$i=1$	X	1	1	2
$i=2$		X	2	3
$i=3$			X	1

Palabras

H

$\left. \begin{array}{l} \text{Palabra 3} = 0\ 1\ 1 \\ \text{Palabra 2} = 1\ 1\ 0 \end{array} \right\}$

$$H(2,3) = 2$$


Título

- Los textos tienen un título
- **Bonificar** frases que hablen del tema en el título
- Comparar palabra a palabra **frase y título**
- **Producto escalar**: la frase y el título son vectores de dimension N

$$\cos(\alpha) = \left(\frac{\langle \gamma, \text{Titre} \rangle}{|\gamma| \cdot |\text{Titre}|} \right)$$


$$\Theta^\mu = \arccos(\cos(\alpha))$$

Título : calculo de angulos




Posición de la frase

- Modeliza contenido semántico según su posición
- Modelo de artículos periodísticos



Otras métricas (plug in)

- Longitud de frases
- Diferencia de entropía condicional entre frases



- Entidades nombradas
- N-gramas
- Otras medidas de distancia

Normalización de las métricas

- Desviaciones importantes entre las métricas
- Normalization entre $[0,1]$

$$\|\lambda_\mu\| = \frac{\lambda_\mu - m}{M - m}$$

Algoritmo de decisión

- Compilar las métricas para dar una nota final a cada frase
- Idea : calcular una **media sofisticada**
 - Tendencia positiva $\lambda > 0,5$
 - Tendencia negativa $\lambda < 0,5$
 - $\lambda = 0,5$ es ignorado

➤ **Convergencia**

➤ **Amplificación**

Generación del resumen

Post-procesamiento superficial


- A partir de la selección de frases pertinentes
- Tamaño definido por el usuario (%)
- Presentación
 - XML
 - Texto


Pruebas

- 14 Personas (nivel universitario) : escoger los segmentos que les parecieran pertinentes
- CORTEX
- Autoresumen MS-Word
- Summarizer Minds New Mexico State University
`messene.nmsu.edu/minds`
- Pertinence `www.pertinence.net`
- Copernic `www.copernic.com`

Análisis del texto « PUCES »

- Artificialmente ambiguo
 - Dos temas : « puces INFO » + « puces BIO »
- $N = 279$ palabras
- $P = 30$ frases
- Frases segmentadas por « : », « . », « ? », « ! »
- Extracto
 - 25% del tamaño = 8 segmentos







PUCES

*Et si l'ordinateur pouvait fonctionner un jour, sans électricité ou presque? La démarche de chercheurs américains de l'université de Notre Dame, dans l'Indiana, montre que l'on peut manipuler des électrons pour construire des circuits élémentaires avec des quantités d'énergie infimes. Leurs expériences, relatées dans l'édition du 9 avril du magazine Science, ouvrent la voie à des composants capables de fonctionner à des fréquences 10 à 100 fois plus élevées que celles des **puces** actuelles qui sont bridées par des problèmes de dissipation de chaleur. Les travaux de l'équipe dirigée par Greg Snider portent sur le puits quantique, un piège infinitésimal dans lequel un électron peut être enfermé. Les scientifiques ont créé ...*


Les cantonnements de la compagnie IV de l'école de recrues d'infanterie d'exploration et de transmission 213, stationnée à Avenches, sont envahis par les **puces** et les poux. Des piqûres de **puces** ont été relevées sur plus d'un tiers des militaires. On a aussi retrouvé des cadavres de poux sur 3 militaires. Des mesures d'urgence ont été prises en conséquence. Des piqûres de **puces** ont été diagnostiquées sur plus d'un tiers des 155 hommes de la compagnie IV de l'école de recrues d'infanterie d'exploration et de transmission 213. Des cadavres de poux, mais aucun oeuf, ont également été décelés sur 3 militaires. Ces insectes sont transmis par contact personnel. La cause de cette invasion n'est pas claire; ces insectes semblent toutefois avoir essaimé à partir du local de garde. Le médecin de troupe a donné...




Texto PUCES.TXT




Segmentacion PUCES.XML




Filtrado PUCES-FIL.XML




Lematizac[i]on PUCES-LEM.XML




```
<?xml version="1.0" encoding="UTF-8" ?>
- <Texte Langue="Fra" Titre="informatique puce">
  <Phrase Indice="0">ordinateur fonctionner jour  lectricit </Phrase>
  <Phrase Indice="1">d marche chercheur am ricain universit  notre_dame indiana montrer
    manipuler  lectron construire circuit  l mentaire quantit   nergie infime</Phrase>
  <Phrase Indice="2">exp rience relater  diter avril magazine science ouvrir_voie composant
    capable fonctionner fr quence  lever puce actuel brid  probl me dissipation
    chaleur</Phrase>
  <Phrase Indice="3">travailler  quiper diriger greg snider porter puits_quantique pi ger
    infinit simal  lectron enfermer</Phrase>
  <Phrase Indice="4">scientifique cr er cellule carrer former puits_quantique introduire pair
     lectron</Phrase>
  <Phrase Indice="5">forcer r pulsion provoquer d placer  lectron trouver  quilibrer trouver
    placer extr mit  diagonal cellule</Phrase>
  <Phrase Indice="6">repr senter  tat indiquer</Phrase>
  <Phrase Indice="7">cellule repr senter bit quantit  informer manipuler ordinateur</Phrase>
  <Phrase Indice="8">d placer  lectron effet forcer ext rieur provoquer automatique d placer
     lectron mani re retrouver  quilibrer basculer cellule  tat</Phrase>
  <Phrase Indice="9">utiliser cellule unique prouver</Phrase>
  <Phrase Indice="10">chercheur am ricain r ussir assembler provoquer besoin d placer
     lectron fournir  nergie</Phrase>
  <Phrase Indice="11">transistor passer  tat  tat possible prix d placer  lectron g n rer
    important flux chaleur</Phrase>
  <Phrase Indice="12">regrouper cellule  l mentaire chercheur mis_au_point circuit baptiser
```



Selección de los segmentos por las personas



Selección de segmentos pertinentes por CORTEX





PUCES

**Segmentos 5 y 15 no
seleccionados**


**Selección de segmentos
por Minds**

Selección *desequilibrada* de segmentos por *Word*



**Segmentos importantes
no seleccionados**

Resultados : resúmen genérico



Inglés, francés y
español

**Textos
compuestos**

Rappel moyen Rouge (Lin, 04)

Evaluation multi-documentos

NIST – DUC 2005-06


45 temas / 25 grupos de documentos en inglés
Generar resúmenes de 250 palabras que responden a las preguntas del tema

Dos estrategias adicionales:

Éliminación de la redundancia

Diversificar el contenido

Resultados : resúmen guiado por tema



Conclusión

- Algoritmo poderoso de resumen de textos
- Métricas independientes, modulares (plug in)
- Algoritmo de decision
- Independiente del tamaño del texto
- Independiente del tema
- Multilingüe[†]
- Extractos equilibrados
- Extractos genéricos o personalizados
- Rapido

Perspectivas

Pre-tratamiento fino

- Modulo lingüístico

Post-tratamiento fino

- Modulo lingüístico
- Generación de texto

Mejora de los condensados :

- Aprendizaje supervisado
- Redes de neuronas
- Cálculo del erreur
- **Compresion de frases**

Compresion automatica de frases

Texto

- Trujillo, la bella capital de Libertad, goza, segun veo, de un clima verdaderamente excepcional.
- Por ese hecho, los inteligentes estudiantes de la UPAO, son recompensados en sus enormes esfuerzos.
- Esperemos entonces que les ha gustado este curso tan interesante !

Resumen por compresion

- *Trujillo capital de Libertad goza de un clima excepcional*
- *Los estudiantes de la UPAO son recompensados en sus esfuerzos*
- *Esperemos que les ha gustado este curso!*


Tasa de compresion palabras : $26/40 = 66 \%$

Lecturas

- American National Standards for Writing Abstracts. ANSI Inc., USA.
- Balpe J., Lelu A., Papy F., and Saleh I. (1996). Techniques avancées pour l'hypertexte. Éditions Hermès, Paris.
- Deerwester S., Dumais D., Furnas T., Launder G., and Harshman T. (1990). Indexing by latent semantic analysis. *Journal of the Amer. Soc for Infor. Science*, 6(41):391-407.
- Huot F. (2000). Copernic summarizer ou la tentation de l'impossible. *Québec Micro*, 6.12(12):61-64.
- Leloup C. (1997). Moteurs d'indexation et de Recherche. Eyrolles.
- Meunier J.-G. and Nault G. (1997). Approche connexioniste au problème de l'extraction de connaissances terminologiques à partir de textes. In *Les Techniques d'intelligence artificielle appliquées aux Technologies de l'Information*, pages 62--76. Les Cahiers scientifiques ACFAS 90.
- Morris A., Kasper G., and Adams D. (1999). The effects and limitations of automated text condensing on reading comprehension performance. In *Advances in automatic text summarization*, pp 305-323. The MIT Press, U.S.A.
- Saggion H. and Lapalme G. (2000). Concept identification and presentation in the context of technical text summarization. In *Automatic Summarization Workshop*, pages 1--10, Seattle. ANLP/NAACL.
- Salton G. (1971). *The SMART Retrieval System - Experiments un Automatic Document Processing*. Englewood Cliffs.
- Salton G. and McGill M. (1983). *Introduction to Modern Information Retrieval*. McGraw-Hill.
- Seffah A. and Meunier J.-G. (1996). Aladin: an integrated object-oriented environment for computer assisted text analysis. *Cahiers de recherche 96.1*, LANCI-UQAM.
- Torres-Moreno, J.M, Velázquez-Morales, P. et Meunier, J.G., *Condensés de textes par des méthodes numériques*. JADT 2002, Vol. (2):723-734, A. Morin & P. Sébillot éditeurs, IRISA/INRIA, France 2002.
- Torres-Moreno, J.M, Velázquez-Morales, P. et Meunier, J.G., *Cortex : un algorithme pour la condensation automatique des textes*. ARCo 2001, Lyon, pp 365 + vol 2. ISC-Lyon, pp 65-5, Décembre 2001.
- Torres-Moreno J.-M., Velazquez-Morales P., and Meunier J. (9-11 Mars 2000). Classphères : un réseau incrémental pour l'apprentissage non supervisé appliqué à la classification de textes. In *JADT 2000*, pages 365--372, Lausanne. EPFL M. Rajman & J.-C. Chappelier éditeurs.

Merci! C'est fini!

Avez-vous des questions?
¿Tienen preguntas?



Juan-Manuel Torres

`juan-manuel.torres@univ-avignon.fr`

Laboratoire Informatique d'Avignon (France)

