

La lutte anti-SPAM. Exemple avec DSPAM

Fabrice Prigent

Université Toulouse 1 Sciences Sociales

Jeudi 7 février 2008

Une situation qui se dégrade

Selon les chiffres de Postini


- 95% de spams en 2006
- 99% en 2007

Des spammeurs plus performants

La présence des ingénieurs chez les spammeurs porte ses fruits

- Utilisation massive des zombies (RBL souvent inutiles),
- Les zombies renvoient les courriers (greylisting moins efficace),
- Les spams images complexifient la détection (utilisation d'outils d'O.C.R.),
- Insertion de textes aléatoires,
- Contournement grâce à l'utilisateur (enlever '*' dans l'url, ou url sans point www misssado com)

Un écosystème qui a fait ses preuves



Pour résumer

- Pirate = Virus = Spam = Scam = Phishing = Argent

Quelques chiffres du SPAM

Les revenus annexes

- 572 dollars : coût moyen d'un vol d'identité bancaire
- 80 000 dollars : pour une faille
- Rock Phish : 200 Millions de dollars de C.A.

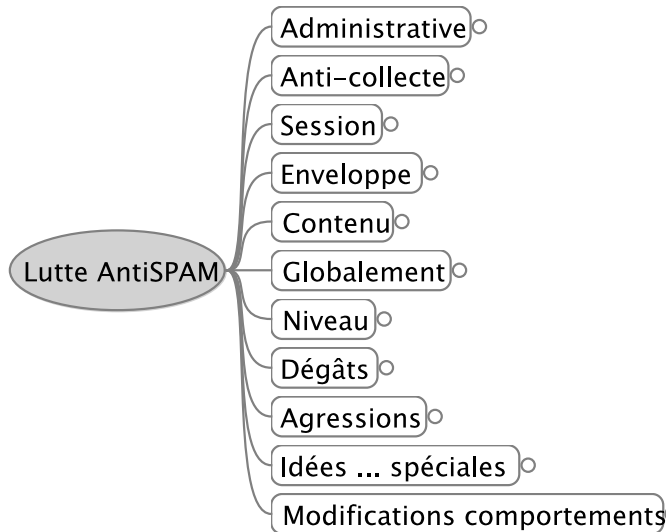
Coût d'une campagne de SPAM

- Location de 10000 machines pour une heure : 50 €
- Base de 20 millions d'email : 250 €

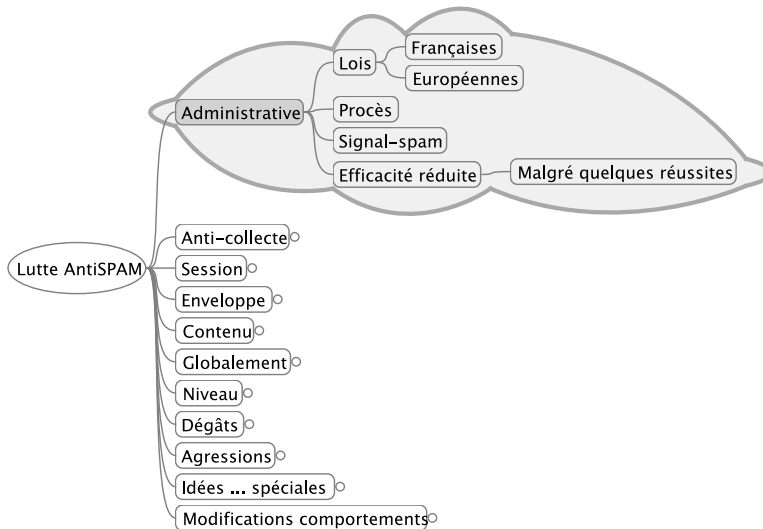
Bénéfice d'une campagne

- Prix d'une montre : 150 €
- Viagra : 100 € les 30 pilules
- Taux de retour estimé : 0.1%
- Campagne "normale" : 1 million de mails

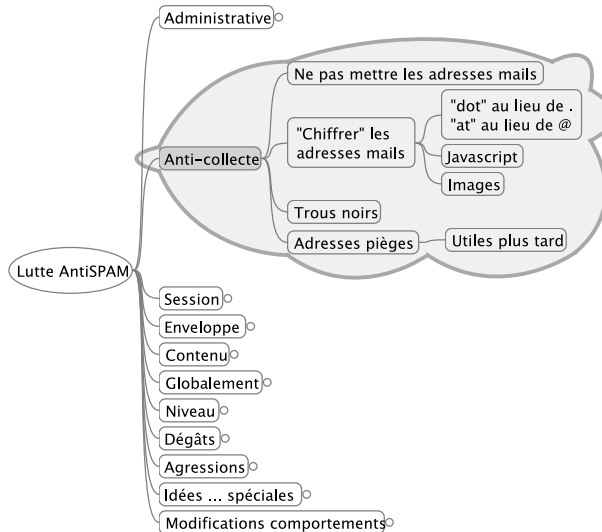
SPAM : où en est la lutte ?



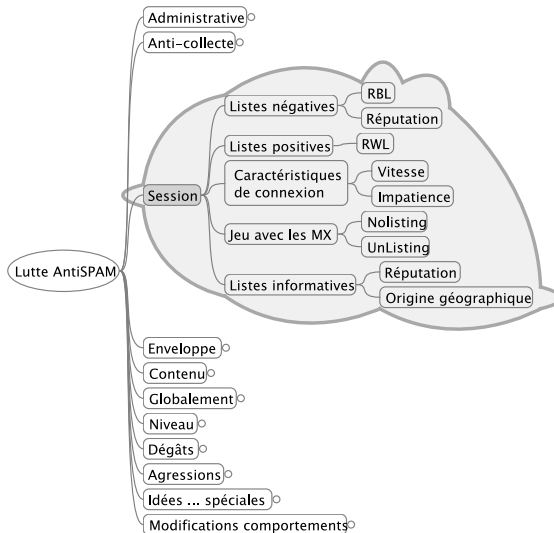
SPAM : Lutte administrative




SPAM : Lutte anti collecte



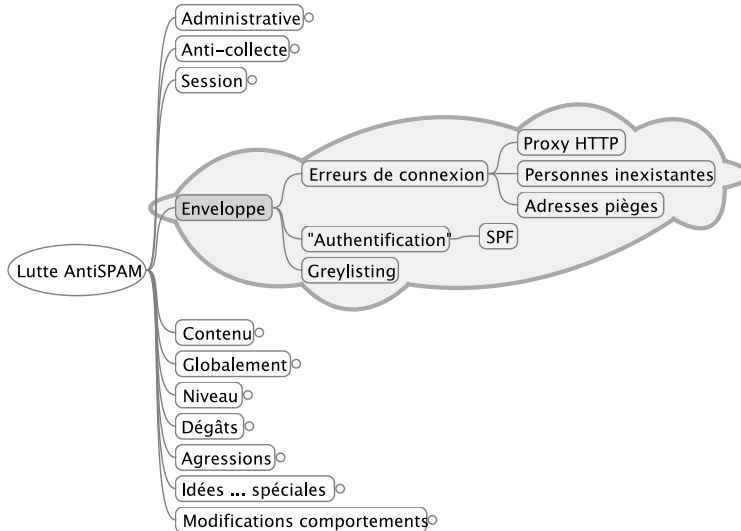
SPAM : Lutte au niveau de la session




SPAM : Lutte au niveau de la session



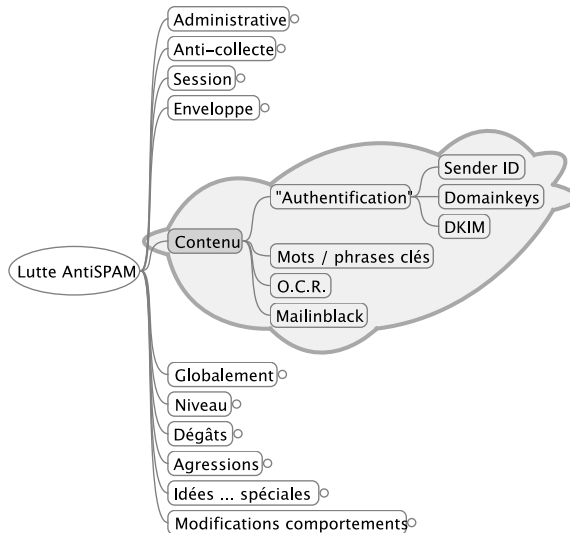
SPAM : Lutte au niveau de l'enveloppe



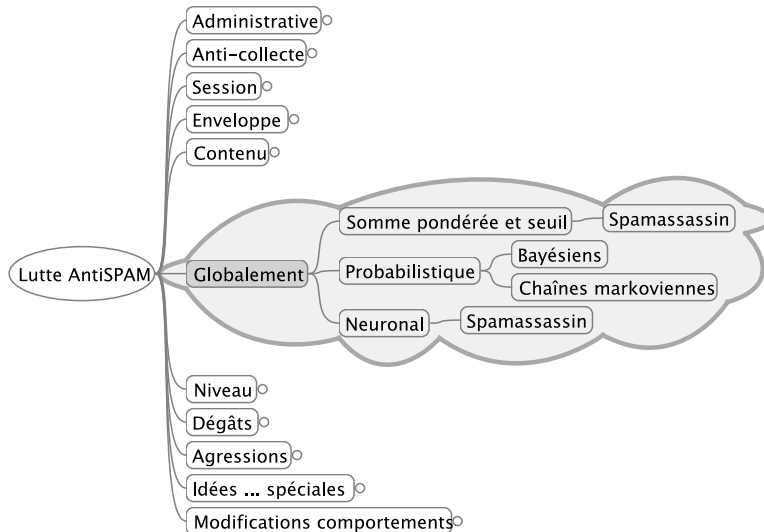
SPAM : retard du greylisting




SPAM : Lutte au niveau du contenu



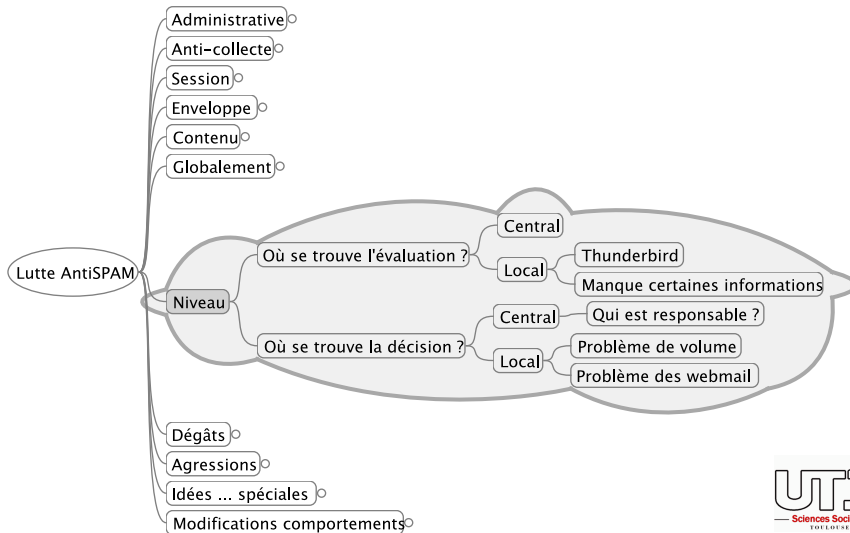
SPAM : Coordination des critères



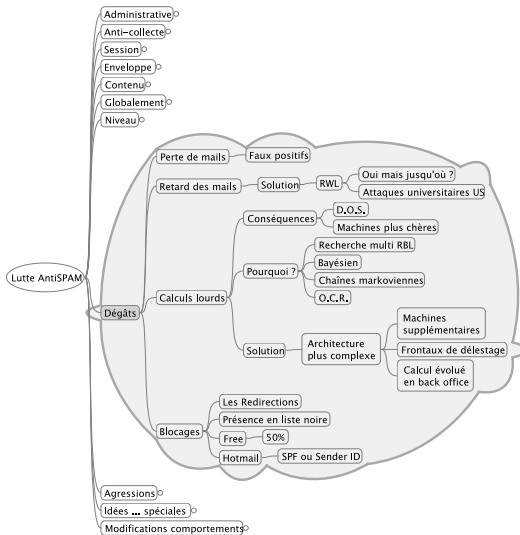
SPAM : Répartition des blocages



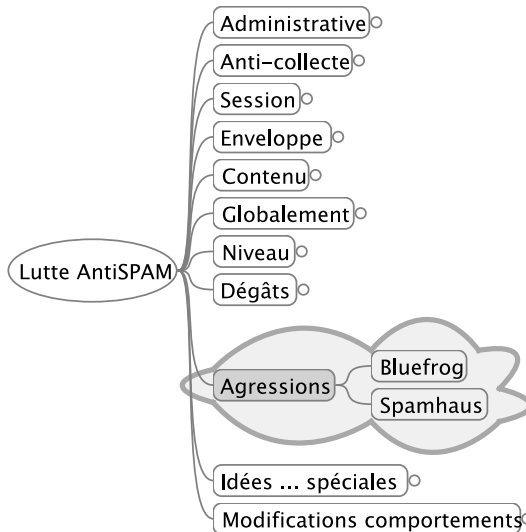
SPAM : Niveau de la lutte



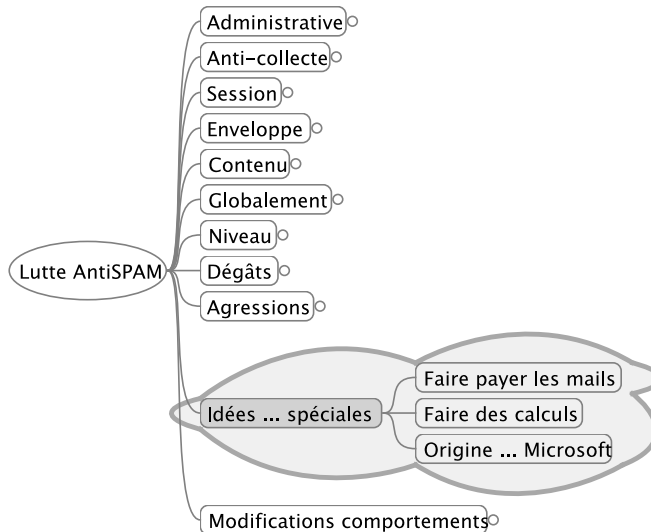
SPAM : Les dégâts de la lutte antispam



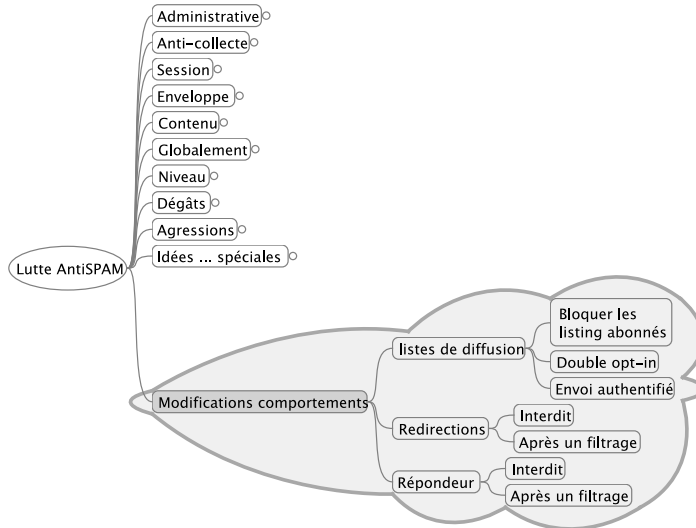
SPAM : Les agressions



SPAM : Quelques idées ... spéciales



SPAM : Les modifications de comportements



Plus de monde touché

Du fait du contournement des protections "initiales", plus de personnes sont touchées.

- Moins habituées,
- Donc moins compétentes,
- Avec de mauvais réflexes (désabonnement, clic sur les virus, etc.),
- Plus disparates (difficulté pour les solutions "globales"),
- Et dont les particularités ne sont pas prises en compte par les logiciels (vocabulaire métier),
- Et acceptant moins les contraintes.

Modifier l'approche

- Diminuer la compétence nécessaire,
- Individualiser la détection avec des dictionnaires spécifiques,
- Individualiser la décision,
- Améliorer la détection, en ne travaillant plus sur les "mots".

DSPAM

DSPAM

- disponible sur <http://dspam.nuclearelephant.com>
- un outil libre
- écrit en C
- dernière version : 3.8.0
- qui étend les capacités traditionnelles des bayésiens

Il est doté de nombreuses particularités qui ont pour but d'améliorer le filtrage des spams, mais surtout d'en faciliter l'accès.

DSPAM : les chaines markoviennes

DSPAM fonctionne, par défaut, par le principe des chaines markoviennes.

En gros, c'est un bayésien qui ne travaille pas avec des mots, mais des suites de mots, par exemple :

Exemples

- X-Test-UT1*RBL+xbi.spamhaus.org
- been+approved
- Received*for+<abuse

Les dictionnaires individuels

DSPAM fonctionne avec des dictionnaires individuels. Ceci va avoir plusieurs conséquences :

- Meilleure adaptation au profil de l'utilisateur,
- Un apprentissage individuel,
- La possibilité de partager entre utilisateurs les dictionnaires
 - Sous forme d'un groupe de partage
 - Sous forme d'un dictionnaire "initial" (tant que le dictionnaire individuel est insuffisant)

Les actions possibles

DSPAM peut faire plusieurs actions quand il détecte un SPAM.
Chaque action est individualisée.

- Ajouter l'en-tête "X-DSPAM-Result" avec la valeur DSPAM ou innocent.
- Ajouter une information dans le sujet.
- Mettre en quarantaine sur le serveur (hors procédé type procmail, ou sieve)

L'interface web

DSPAM fournit une interface web très complète pour

- Modifier le comportement de DSPAM (le paramétrage)
- Corriger les erreurs
- Afficher les performances (faux positifs et faux négatifs)
- Gérer la quarantaine
- Visualiser des graphes

Une version "administrateur" existe.

Web : Performances

Statistical SPAM Protection for



Performance Préférences Alertes Quarantaine (Empty) Analyse Historique Administrative Suite

- Si vous recevez un message dans votre logiciel de messagerie qui n'a pas été détecté par le filtre, veuillez le renvoyer à l'adresse **mail.incorrect@univ-tlse1.fr** afin qu'il soit analysé et repéré comme SPAM.
- Si vous recevez un message dans votre logiciel de messagerie qui a été incorrectement détecté par le filtre comme SPAM, veuillez le renvoyer à l'adresse **mail.correct@univ-tlse1.fr** afin qu'il soit analysé et repéré comme HAM.

Ceci améliorera graduellement la précision du filtre.

Statistiques de performance - Mon Jan 29 7:21:28 2007

Métrique		Formule de calcul
Efficacité globale (depuis la dernière RAZ)	99.889%	(SPAM détectés + messages corrects délivrés) / Nombre total de messages
Identification de SPAM (depuis la dernière RAZ)	99.887%	(Taux de détection de SPAM uniquement)
Spam ratio (sur le nombre total de message)	30.916%	Total de SPAM (Détectés ou pas) / Nombre total de messages

	SPAM	HAMS
Depuis la dernière remise à zéro	51 ratés	117 ratés
	44893 détectés	106206 délivrés
	99.887% détectés	0.110% ratés
Total traités par le filtre	142 ratés	304 ratés
	57150 détectés	127719 délivrés
Depuis un corpus	50 fed	374 fed

[Remise à zéro](#) | [Tweak -1](#)

DSPAM is a registered trademark of Deep Logic, Inc.. Copyright © 2005, Deep Logic, Inc.

Web : Préférences

Statistical SPAM Protection for



Performance **Préférences** Alertes Quarantaine (Empty) Analyse Historique Administrative Suite

Cette page vous permet de configurer la manière dont le filtre gère vos messages.

Entraînement - Configure comment le filtre apprend à gérer les messages.

DSPAM doit apprendre:

- ☐ A chaque nouveau message
- ☒ Seulement quand le filtre se trompe
- ☐ Seulement avec de nouvelles données ou si le filtre se trompe

Quand je corrige DSPAM, Je préfère:

- ☐ Faire suivre mes spams (La signature apparaît dans le message)
- ☒ Rediriger mes spams (La signature apparaît dans les en-têtes des messages)

Sensibilité du filtre **durant** la période d'apprentissage:

Fortement anti-SPAM (Plus en Quarantaine) ☐ ☐ ☐ ☐ ☒ ☐ ☐ ☐ ☐ ☐ Pas très anti-SPAM (Moins en Quarantaine)

Gestion des messages - Configure comme le spam est géré

Quand un SPAM est repéré :

- ☐ Le message est mis en quarantaine
- ☐ Modifie le sujet avec
- ☒ Envoie le message normalement avec un en-tête *X-DSPAM-Result*

Caractéristiques - Réglage du filtre anti-SPAM

- ☒ Autorise la réduction du bruit, ce qui améliore généralement la précision du filtre
- ☒ Autorise la mise en liste blanche des correspondances fréquentes
- ☒ Ajoute les critères de détection dans les en-têtes du message

Web : Quarantaine

Statistical SPAM Protection for



Performance | Preferences | Alertes | **Quarantaine (15)** | Analyse | Historique | Administrative Suite

Les messages ci-dessous n'ont pas été reçus par votre logiciel de courrier électronique car ils ont été repérés comme spam. Cliquez sur la ligne Sujet pour voir le message ou choisissez une option de tri pour modifier l'ordre d'affichage. Utilisez les boîtes à cocher et **Envoyer** pour libérer les messages que vous souhaitez lire ou utilisez **Effacer Tout** pour vider la quarantaine.

Sort by: **Rating** | Date | Subject | From

Note	Date	Expéditeur	Sujet
<input type="checkbox"/> 70%	Jan 29 07:46a	Millie A. Clifton <zic@glmusicals.com>	terms
<input type="checkbox"/> 76%	Jan 29 07:44a	Janet C. Martinez <gby@pomtaserbia.com>	revere
<input type="checkbox"/> 85%	Jan 29 09:17a	"Tivadar Kershaw" <brannumu@jсанco.com>	Re: pigRX
<input type="checkbox"/> 99%	Jan 29 08:17a	"anish mohamad" <anishmohamad@yahoo.co.in>	Obtain the career you have always wanted with the ...
<input type="checkbox"/> 99%	Jan 29 08:30a	Bank of America <noreply@bankofamerica.com>	Security: Your Online Banking Account is Blocked
<input type="checkbox"/> 99%	Jan 29 08:44a	"Marina Farr" <lnwalsjdthock@snail-mail.net>	best prices for impotence drug\$!
<input type="checkbox"/> 99%	Jan 29 07:49a	Central Bank <eebi_cbn@mac.com>	YOUR OVER DUE INHERITANCE FUND
<input type="checkbox"/> 99%	Jan 29 07:47a	"Rene Meiers" <cipesrol@options-st.com>	backlog vacuum
<input type="checkbox"/> 99%	Jan 29 08:17a	"Mark Christie" <SM5HDNCTDAXH@epomail.com>	SPUR-M
<input type="checkbox"/> 100%	Jan 29 08:04a	"Gamble Edmund" <ombp@mallkol.cz>	CropsChoosing which crops to grow depends on many ...
<input type="checkbox"/> 100%	Jan 29 08:17a	"Cyrus G. Rivera" <qu@jsmlet.com>	Do not take a report over the telephone as being t...
<input type="checkbox"/> 100%	Jan 29 07:59a	"cocacola_rep@terra.es" <cocacola_rep@terra.es>	THE COCA COLA COMPANY SEASON PRIZE NOTIFICATION
<input type="checkbox"/> 100%	Jan 29 08:06a	"cocacola_rep@terra.es" <cocacola_rep@terra.es>	THE COCA COLA COMPANY SEASON PRIZE NOTIFICATION

Web : Analyse


Statistical SPAM Protection for




Performance Préférences Alertes Quarantaine (Empty) **Analyse** Historique Administrative Suite

Ces courbes montrent le nombre de messages qui ont été traités.

24 Heures - 161 SPAM, 272 Good



14 Jours - 2465 SPAM, 7066 Good



Web : Historique

Statistical SPAM Protection for



Performance **Préférences** **Alertes** **Quarantaine (Empty)** **Analyse** **Historique** **Administrative Suite**

Les messages qui ont été traités par le filtre sont présentés ci-dessous. Les messages les plus récents sont en premier. Utiliser l'option "Correction" pour corriger les erreurs et envoyer les faux-positifs qui sont encore en quarantaine.

[1 2 3 4 5 6 7 8 >]

Type	Correction	Jour/Heure De	Sujet	Complète	
Whitelisted	<input type="checkbox"/> As Spam	Mon 7:23a	FaultNotifier@univ-tlse1.fr	wifi-177.univ-tlse1.fr[192.168.1.177] P2 notificat...	Auto-Whitel
SPAM	<input type="checkbox"/> As Innocent	Mon 7:21a	"Xavier Penn" <econcom@amfactory.com>	do be mclean	Delivered
SPAM	<input type="checkbox"/> As Innocent	Mon 7:18a	"Morris Bolden" <slscomply@home.co.yu>	Is saltwater or queen	Delivered
SPAM	<input type="checkbox"/> As Innocent	Mon 7:17a	"♦♦Mrs Rachael" <%NOUN.%ADJ@rocketjet...	Go thinner in 2007	Delivered
SPAM	<input type="checkbox"/> As Innocent	Mon 7:17a	"Ernst B. Hanford" <alind@continuumapptech.com&...	Pharmacy we recommend: Christmas discounts.	Delivered
SPAM	<input type="checkbox"/> As Innocent	Mon 7:17a	"Secrequest" <apocalypse_absent@attglobal.net&...	Bad credit? Good credit? No problem We specialize...	Delivered
SPAM	<input type="checkbox"/> As Innocent	Mon 7:17a	"sec-request@ossif.org" <x-ray.theoretical@ocho...	Go Leaner in 2007	Delivered
SPAM	<input type="checkbox"/> As Innocent	Mon 7:17a	"monastic" <hwmkhtfpg@verizon.net>	Your refinance application has been accepted.	Delivered
SPAM	<input type="checkbox"/> As Innocent	Mon 7:17a	"Bryan Henderson" <makingfoynails.com@fomevisa...	She will love you more than any other guy	Delivered
SPAM	<input type="checkbox"/> As Innocent	Mon 7:17a	"Wiggins Victoria" <cudl@cfl.k12.tr>	ultrasound	Delivered
SPAM	<input type="checkbox"/> As Innocent	Mon 7:14a	"Skinner" <fop@loonybin2020.freemove.co.uk>	Poor boy, he thought.	Delivered
Whitelisted	<input type="checkbox"/> As Spam	Mon 7:07a	FaultNotifier@univ-tlse1.fr	wifi-177.univ-tlse1.fr[192.168.1.177] OK notificat...	Auto-Whitel
Whitelisted	<input type="checkbox"/> As Spam	Mon 7:05a	"servepo@univ-tlse1.fr" <servepo@univ-tlse1.fr&...	[servepo] Virus <Non disponible> détecté m...	Auto-Whitel
SPAM	<input type="checkbox"/> As Innocent	Mon 7:04a	"Thomas" <chugh@blattsrehab.com>	Same Viagra, Cialis as in US based pharmacies but ...	Delivered
Whitelisted	<input type="checkbox"/> As Spam	Mon 7:03a	FaultNotifier@univ-tlse1.fr	wifi-177.univ-tlse1.fr[192.168.1.177] P2 notificat...	Auto-Whitel

Web : Statistiques administrateur

Statistical SPAM Protection for **Administrator** (prigent@univ-tlse1.fr)

System Status **User Statistics** **Administration** **Control Center**

The following graphs and tables summarize the processing done by the filter.


Overview

Messages	Today	This Hour
Spam	4842	82
Good	2258	80
Spam Misses	0	0
False Positives	1	0
Inoculations	0	0
Total	7101	162


Status	Current Value
Average message processing time	0.239629 sec.
Average throughput	0.20 messages/sec.
DSPAM instances	3 processes
System uptime	13:27:32 up 132 days, 7:14, 3 users, load average: 0.59, 0.30, 0.22
Mail queue length	414 messages

Web : Graphiques administrateur

24 Hour Activity - 7941 SPAM, 10774 Good, 0 Spam Misses, 1 False Positives, 0 Inoculations



Daily Activity - 101113 SPAM, 345842 Good, 683 Spam Misses, 35 False Positives, 0 Inoculations



Ses prérequis

Si DSPAM peut fonctionner avec un grand nombre de procédés de stockage, il ne donne réellement toute sa puissance qu'avec une base de données MySQL.

- Stockage des paramètres personnels (inaccessibles sinon)
- Travail avec des signatures (pour une correction simplifiée)

Sa position

DSPAM peut se placer en tant que relais

- POP, pour avoir des pointes de charge à 8h30 le matin ;-)
- SMTP, avec création d'une boucle MTA / DSPAM / MTA
- LMTP, le plus efficace

Son fonctionnement

Il est identique à un bayésien standard.

Apprentissage

- Avec un pool de mails (2500 mails et au moins 250 spams)
- Récupération de tokens (parfois des phrases)
- Calcul de la spamicité de ces tokens

Utilisation

- Récupération de tokens
- Evaluation de ces tokens
- Réinjection du mail pour réapprentissage
 - Toujours (TEFT)
 - Sur erreur (TOE)
 - Sans entraînement (unlearn)
 - etc.

Son fonctionnement original

Du fait de sa granularité, il va ajouter certains aspects

- Création d'une signature pour chaque message
- Remplissage avec les tokens du message
- Insertion dans le message de la signature
 - Dans les en-têtes si on corrige en redirigeant le message
 - En fin de message si on corrige en le faisant suivre.
- La zone signature reste jusqu'à effacement (procédure externe)
- La correction peut être faite par interface web.

Les en-têtes ajoutés

Spam

- X-DSPAM-Result : Spam
- X-DSPAM-Processed : Sat Jan 27 14 :41 :50 2007
- X-DSPAM-Confidence : 0.8531
- X-DSPAM-Probability : 1.0000
- X-DSPAM-Signature : 5,45bb569e311183356076796

Ham

- X-DSPAM-Result : Innocent
- X-DSPAM-Processed : Mon Jan 29 09 :36 :43 2007
- X-DSPAM-Confidence : 0.9982
- X-DSPAM-Probability : 0.0000
- X-DSPAM-Signature : 5,45bdb21b311182003211484

Quelques options

DSPAM est doté aussi de quelques options intéressantes

- Lien direct avec ClamAV
- Avertissement sur l'état de la quarantaine
- Possibilité de créer des groupes
 - globaux (classification <1000 hams ou < 250 spams)
 - mixés

La correction

La correction peut être effectuée par deux moyens

- Le renvoi du mail mal classé
 - En redirigeant le message (signature dans une en-tête)
 - Impossible pour Outlook express, Mail de MacOS
 - Ajout d'un plugin pour Thunderbird
 - En faisant suivre (signature en fin de message)
 - Mail changé
 - Signature numérique éventuelle cassée !
- L'utilisation de l'interface web

Les contraintes d'installation

Elles sont nombreuses, car l'outil est extrêmement paramétrable.

- Choix du backend (hashed, MySQL, Oracle, etc)
- Choix des méthodes (bayésien, markovien, etc.)
- Choix des améliorations (élimination du bruit)
- Choix du paramétrage par défaut
- Choix des options laissées aux utilisateurs
- Choix du processus de réapprentissage
 - Création ou non d'une adresse unique
- Constitution de groupe

Les contraintes d'utilisation

Elles sont nombreuses :

- Problème de l'espace utilisé
 - 10 Mo par personne pour les tokens
 - Autant pour les signatures
 - Obligation de nettoyage régulier
- Problème de performances
 - De 0,10 à 2 secondes par mail
 - Optimisation par InnoDB ?

Les autres défauts

- Interface en anglais uniquement
- L'affichage des graphes est consommateur en CPU
- Problème de droits entre dspam et son interface web

A l'UT1

Choix faits

- Utilisation de MySQL, mais "out of the box" (pas d'InnoDB)
- Utilisation des processus par défaut
- Latitude totale pour l'utilisateur
- Utilisation de la réduction de bruit
- TOE (Train on Error) par défaut pour économiser de la place
- Utilisation des virtual users pour créer une adresse unique de redirection
- Limitation de la taille pour analyse des mails
- Création d'une base de départ

Quelques Trucs

Choix faits

- Traque des machines spammeuses
 - Utilisation de l'option "TrackSources spam nonspam"
 - On enlève les MX locaux "LocalMX 127.0.0.1 193.49.48.245 193.49.48.250"
- Enlever les en-tête d'autres outils
 - IgnoreHeader X-Spam-Status
- Mettre dans les en-têtes les critères de choix
 - Preference "showFactors=on"

Efficacité

- Taux de réussite de 99,88% en s'astreignant à la correction
- Tout manquement se paie cash !
- Ré-utilise massivement les méthodes antispam classiques
 - Greylisting (ou plutôt sortie du greylisting)
 - Résultat RBL
 - Résultat Dialup
- Et tout ça sans O.C.R. !
- Avantages fonctionnels
 - Responsabilité individuelle
 - Relativement simple
 - Adaptation à l'utilisateur (mail, web)

Conclusion

DSPAM est un outil

- Extrêmement performant,
- Hautement adaptatif,
- Assez facile d'utilisation,
- Mais qui ne tolère pas l'approximation
 - De l'administrateur
 - De l'utilisateur

Merci de votre attention

Des questions ?