

Le Groupe CARTÉGIE : 30 ans d'expérience

Groupe français et indépendant





450
CLIENTS ETI &
GRANDS
COMPTES
UNE OFFRE
GLOBALE









2013
LANCEMENT DU
PROGRAMME DE
CROISSANCE EXTERNE
2017

DERNIERE ACQUISITION




Le Groupe CARTÉGIE : un partenaire global

Nous mobilisons les expertises data et connaissance client pour faire avancer les entreprises.

Nous créons des synergies nouvelles pour mieux adresser vos cibles.


Nous tirons parti d'une data efficiente pour déployer des dispositifs innovants.

POUR UNE DATA INTELLIGENTE, ACTIVE & CRÉATIVE





Un virage technologique Pour mieux exploiter, collecter, interroger, faire parler la data

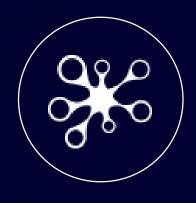


technologique



LA GENESE DU PROJET

Collecte Nouvelles Données B2B









Multiplication
des informations
sur les entreprises,
générées par le boom du
numérique

De nouveaux acteurs, marché de la donnée B2B en pleine mutation (explosion Open Data) BIG DATA :un virage obligatoire pour les acteurs de la donnée Nécessité d'acquérir expertise et expérience dans le domaine du Big Data à travers un accompagnement à forte valeur technologique



SITES E-COMMERCE





Objectifs du projet :

Disposer d'un fichier complet des sites e-commerce en France

OBJECTIFS

- Augmenter la valeur de l'entrepôt BtoB du Groupe CARTÉGIE
- Développer de nouvelles offres toujours plus pertinentes en termes de marketing opérationnel pour nos clients

ETAPES

- Acquérir les informations pour alimenter les traitements de classification
- Stocker et mettre en forme ces informations

Parsing / Cloud

 Définir et développer les méthodes appropriées

Machine Learning





Disposer de la matière première : Crawling de masse





Des règles a priori

- Cibler les sites web B2B
- Limiter la profondeur de recherche dans les sites
- Langue française
- Prioriser les pages à contenus pertinents
- Focus sur le texte (corpus, PDF)

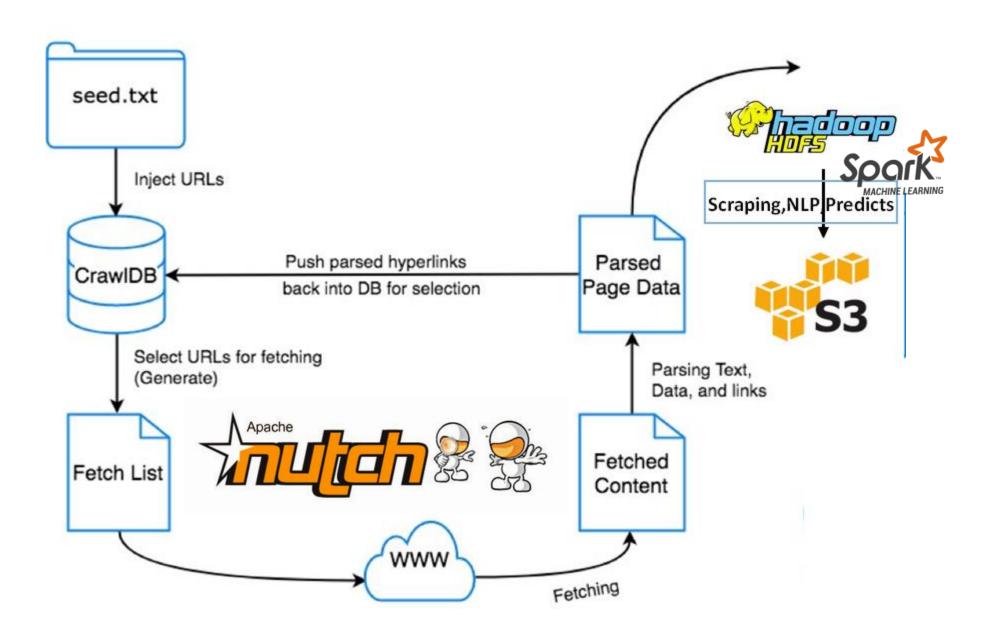






- Crawler open source java
- Map/Reduce Hadoop
- Nombreux paramètres
- Modifié par le BDL :
 - Scoring/ranking adhoc
 - Plugin de détection de langue
 - CrawIDB orientée métier







Résultats

3 045 961 246 URL

100 NŒUDS /
MACHINES SUR AWS
(8GO RAM, 2 CPU, 50GO
SSD)

amazon EC2



737 430 062
PAGES CRAWLÉES
20 TO
TELECHARGÉ
6,8 TO
TEXTE ANALYSÉ






Traiter la donnée collectée sur les sites web Détection des sites e-commerce





A l'issue du crawl et du parsing

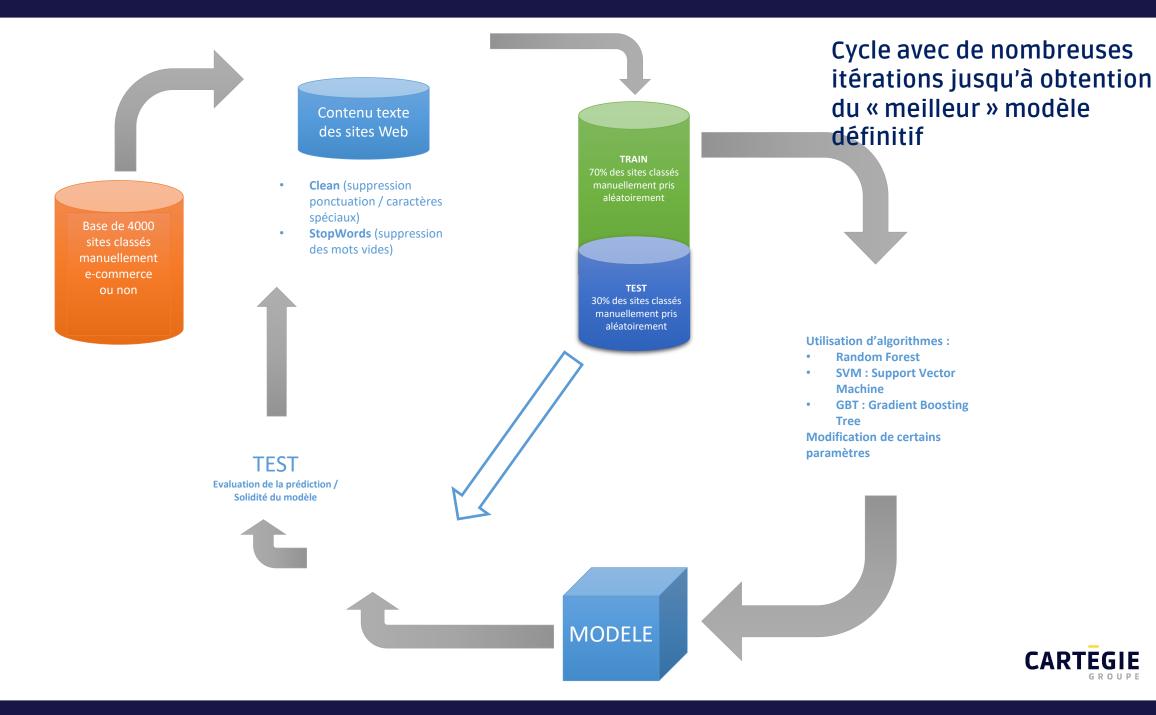



algorithmes de Machine Learning

afin d'identifier automatiquement les sites e-commerce et non e-commerce sur ces 1 million de sites













Contenu texte des sites Web

- Clean (suppression ponctuation / caractères spéciaux)
- StopWords (suppression des mots vides)











Nettoyage des données

```
1 < 'DOCTYPE html>
 2 <html>
 3 <head>
 4 <meta name="generator" content="Oxatis (www.oxatis.com)" />
 5 <meta http-equiv="Content-Type" content="text/html; charset=ISO-8859-1" />
 6 <meta http-equiv="Content-Language" content="fr" />
 7 <title>Decoration Marine saint malo, Maquettes de Bateau, Luminaires, Deco Mer</title>
 8 <meta name="description" content="Boutique en ligne de decoration marine. Entre Mer et Plage 6 224; Saint Malo. Maguettes, Bateaux, Lampes
 9 <meta name="robots" content="index, follow, all" />
10 <meta http-equiv="Pragma" content="no-cache" />
11 <meta http-equiv="Expires" content="-1" />
12 12 12 13 14 15 
15 
16 
17 
18 
19 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 
10 

13 13 13 13 13 13 14 

14 14 Tink rel="StyleSheet" type="Text/css" href="DesignCss/147000/411/style.css">
15 <style type="text/css">IMG.BlackBox { border-color: #000000; }</style>
16 <script type="text/javascript" src="javascript/jquery/jquery-1.6.1.min.js"></script>
17 <script type="text/javascript" src="javascript/jquery/jquery-ui-1.8.12.custom.min.js"></script>
18 <LINK REL="SHORTCUT ICON" HREF="http://www.entremeretplage.oxatis.com/Files/103086/favicon.ico">
19 <meta name="google-site-verification" content="u74h5hm3M9LNZntzJ7wT02Lbv0qmvj0lfstNBx7cHlg" />
      (function(i,s,o,g,r,a,m){i['GoogleAnalyticsObject']=r;i[r]=i[r]||function(){
      (i[r].g=i[r].g||[]).push(arguments)},i[r].l=1*new Date();a=s.createElement(o),
      m=s.getElementsByTagName(o)[0];a.async=1;a.src=g;m.parentNode.insertBefore(a,m)
      }) (window, document, 'script', '//www.google-analytics.com/analytics.js', 'ga');
      ga('create', 'UA-51322511-1', 'entremeretplage.fr');
      ga('send', 'pageview');
29 </script>
```



Nettoyage des données

Données brutes extraites par le crawler : texte d'une page et zoom sur les éléments du menu

www.entremeretplage.fr→1.0 Decoration Marine saint malo, Maquettes de Bateau, Luminaires, Deco Mer OK Votre panier: 0,00 € Accueil Compte Nouveautés Déco Marine Accessoires de bureau Anore et Poulie Animaux marins Art de la table Boites à clés Boites et Coffrets Casque de Scaphandrier Cendriers Crochets et Patères Jeux de société Matelotage Miroirs Hublots Plaques de portes Voiliers et Barques Navigation Barres à roue Boussoles Calendriers perpétuel Cloches de bord Cloches de table Compas pointes séches

www.entremeretplage.fr → 1.0 Decoration Marine saint malo, Maquettes de Bateau, Luminaires, Deco Mer OK

Votre panier : 0,00 € Accueil Compte Nouveautés Déco Marine Accessoires de bureau Ancre et Poulie

Animaux marins Art de la table Boites à clés Boites et Coffrets Casque de Scaphandrier Cendriers Crochets

et Patères Jeux de société Matelotage Miroirs Hublots Plaques de portes Voiliers et Barques Navigation

Barres à roue Boussoles Calendriers perpétuel Cloches de bord Cloches de table Compas pointes séches

Cornes de brume Horloges Longues vue et Téléscopes Loupes Sablier Sextants Sifflets de Bosco Sphère et

Globe Déco maison Art de la table Entretien Figurines Filet de pêche Lampes coquillage Lampes Phares

Matelotage Objets déco Oiseaux mobile Pancartes en bois décoratives. Photophores & Bougeoirs Plaques metal

decoratives Luminaires Appliques Extérieures Lampes coquillage Lampes Phares Lampes à poser

Suspensions Lampes en applique Lampes à pétrole Maquettes Enfants Galions Sous Marin Chalutier

Voiliers Oiseaux & Poissons Mobiles oiseaux Poissons Phares Tous les phares Belgique Calvados

Charente Maritime Côtes d'Armor Finistère ille et Villaine Loire Atlantique Manche Morbihan Nord Pas de

Calais Seine Maritime Somme Vendée Accueil Contact Albums photos Qui sommes nous ? Boutique

Nouveautés Déco Marine Navigation Déco maison Luminaires Maquettes Oiseaux & Poissons Phares Déjà client

Dateau. Le monde des maquetres de Dateau, volliers, vieux greements, Dateaux de peone, liva, volliers historiques, maquettes de prestige, mais aussi Combi surf, Hydravions. Décoration marine. Retouvez nous aussi à Saint Malo 3 rue saint vincent dans notre magasin . Décoration thème mer, décoration marine, maison du bord de mer. Tout un large choix d'articles de décoration. Bienvenue sur notre boutique en ligne de décoration marine. Au fil du temps la boutique viendra s'agrémenter de nouveaux articles. N'hésitez pas à vous inscrire sur l'onglet newsletter ou à revenir nous voir. Bonne visite, Marie et Frédéric. Actualités et nouveautés. Restez informés en nous rejoignant sur Facebook NOUVEAUX ARTICLES : Décoration de la maison, luminaires, maquettes, oiseaux et poissons Pomme de touline pm d:8 Pomme de touline petit modèle. Fabrication artisanal en chanvre naturel 14,00 € Détails Porte clés Pomme de touline Porte clés, Pomme de touline. Fabrication artisanal en chanvre naturel 9,00 € Détails Baderne longue L: 60 cm Baderne lonque, 60 cm env. Fabrication artisanal en chanvre naturel 36,00 € Détails Baderne ronde d: 30 cm env Baderne ronde, d: 30 cm env. Fabrication artisanal en chanvre naturel 29,00 € Détails Bigoudène Bigoudène en céramique. 22,00 € Détails Plaque en metal phare Ar-men AR-MEN Plaque en métal du phare Ar-men 18,00 € Détails Plaque en metal phare Les Poulains LES POULAINS Plaque en métal du phare Les Poulains 18,00 € Détails Lampe en céramique " Oursin " Lampe en céramique " oursin " 48.00 € Détails TOUTE LA BOUTIQUE EN LIGNE, C'EST ICI ! Miroir Hublot Miroir Hublot ouvrant en laiton à fixer. Diamétre 20 cm. Autres dimensions à découvrir. Miroir Hublot 32.00 € Coffret bois Jolie coffret en bois et laiton. Boite à bijoux ou à trésors Autres tailles et formes. Coffret bois 15,00 € Boussole Laiton Boussole en laiton avec chainette. Décoration ancre de marine. Boussole 21,00 € Cloche de bord Cloche de



Nettoyage des données

Exemple de l'utilisation de l'algorithme : Données nettoyées

www.entremeretplage.fr \(\to 1.0 \) WrappedArray (decoration, marine, saint, malo, maquettes, bateau, luminaires, deco, mer, ok, votrepanier, devisemonnaie, accueil, compte, nouveautes, deco, marine, accessoires, bureau, ancre, poulie, animaux, marins, art, table, boites, cles, boites, coffrets, casque, scaphandrier, cendriers, crochets, pateres, jeux, societe, matelotage, miroirs, hublots, plaques, portes, voiliers, barques, navigation, barres, roue, boussoles, calendriers, perpetuel, cloches, bord, cloches, table, compas, pointes, seches, corpes, brume, horloges, longues, vue, telescopes, longues, sabler, sextants, compas, pointes, seches, corpes, brume, horloges, longues, vue, telescopes, longues, sabler, sextants, compas, pointes, seches, corpes, brume, horloges, longues, vue, telescopes, longues, sabler, sextants, compas, pointes, seches, corpes, brume, horloges, longues, vue, telescopes, longues, sabler, sextants, compas, pointes, sextants, compas, pointes, sextants, compas, proposition and compassion an

www.entremeretplage.fr 1.0 WrappedArray(decoration, marine, saint, malo, maquettes, bateau, luminaires, deco, mer, ok, votrepanier, devisemonnaie, accueil, compte, nouveautes, deco, marine, accessoires, bureau, ancre, poulie, animaux, marins, art, table, boites, cles, boites, coffrets, casque, scaphandrier, cendriers, crochets, pateres, jeux, societe, matelotage, miroirs, hublots, plaques, portes, voiliers, barques, navigation, barres, roue, boussoles, calendriers, perpetuel, cloches, bord, cloches, table, compas, pointes, seches, cornes, brume, horloges, longues, vue, telescopes, loupes, sablier, sextants, sifflets, bosco, sphere, globe, deco, maison, art, table, entretien, figurines, filet, peche, lampes, coquillage, lampes, phares, matelotage, objets, deco, oiseaux, mobile, pancartes, bois, decoratives, photophores, bougeoirs, plaques, metal, decoratives, luminaires, appliques, exterieures, lampes, coquillage, lampes, phares, lampes, poser, suspensions, lampes, applique, lampes, petrole, maquettes, enfants, galions, marin, chalutier, voiliers, oiseaux, poissons, mobiles, oiseaux, poissons, phares, phares, belgique, calvados, charente, maritime, cotes, armor, finistere, ille, villaine, loire, atlantique, manche, morbihan, nord, calais, seine, maritime, somme, vendee, accueil, contact, albums, photos, boutique, nouveautes, deco, marine, navigation, deco, maison, luminaires, maquettes, oiseaux,

large, choix, articles, decoration, bienvenue, boutique, decoration, marine, fil, temps, boutique, viendra, agrementer, articles, hesitez, inscrire, onglet, newsletter, revenir, voir, bonne, visite, marie, frederic, actualites, nouveautes, restez, informes, rejoignant, facebook, articles, decoration, maison, luminaires, maquettes, oiseaux, poissons, pomme, touline, pm, pomme, touline, petit, modele, fabrication, artisanal, chanvre, naturel, devisemonnaie, details, porte, cles, pomme, touline, porte, cles, pomme, touline, fabrication, artisanal, chanvre, naturel, devisemonnaie, details, baderne, longue, cm, baderne, longue, cm, env, fabrication, artisanal, chanvre, naturel, devisemonnaie, details, baderne, ronde, cm, env. baderne, ronde, cm. env. fabrication, artisanal, chanvre, naturel, devisemonnaie, details, bigoudene, bigoudene, ceramique, devisemonnaie, details, plaque, metal, phare, ar, men, ar, men, plaque, metal, phare, ar, men, devisemonnaie, details, plaque, metal, phare, poulains, poulains, plaque, metal, phare, poulains, devisemonnaie, details, lampe, ceramique, oursin, lampe, ceramique, oursin, devisemonnaie, details, toute, boutique, miroir, hublot, miroir, hublot, ouvrant, laiton, fixer, diametre, cm, dimensions, decouvrir, miroir, hublot, devisemonnaie, coffret, bois, jolie, coffret, bois, laiton, boite, bijoux, tresors, tailles, formes, coffret, bois, devisemonnaie, boussole, laiton, boussole, laiton, chainette, decoration, ancre, marine, boussole, devisemonnaie, cloche, bord, cloche, bord, laiton, potence, corde, tressee, differents, modeles, disponible, cloche, bord, devisemonnaie, lampe, cargot,



Exemple de l'utilisation de l'algorithme : Données vectorisées

label	Parsetext	Vecteur
0	Array("a", "b", "c")	(3,[0,1,2],[1.0,1.0,1.0])
1	Array("a", "b", "b", "c", "a")	(3,[0,1,2],[2.0,2.0,1.0])



Exemple de l'utilisation de l'algorithme : Données vectorisées



Exemple de l'utilisation de l'algorithme : Données sélectionnées

ID	Features	Ecommerce	SelectedFeatures
7	[0.0, 0.0, 18.0, 1.0]	1.0	[1.0]
8	[0.0, 1.0, 12.0, 0.0]	0.0	[0.0]
9	[1.0, 0.0, 15.0, 0.1]	0.0	[0.1]



Features (fictives):

monsieur voix penser quel arriver maison devant coup beau connaître devenir air mot nuit sentir eau vieux sembler moins tenir

20 mots suffisent pour effectuer la prédiction!





Exemple de l'utilisation de l'algorithme : Données sélectionnées

```
(1.0, [280.0, 22.0, 14.0, 29.0, 20.0, 16.0, 37.0, 16.0, 32.0, 7.0, 6.0, 6.0, 3.0, 2.0, 0.0, 2.0, 1.0, 2.0, 3.0, 4.0])
       (0.0, [104.0, 100.0, 4.0, 9.0, 1.0, 18.0, 47.0, 8.0, 8.0, 3.0, 3.0, 7.0, 9.0, 0.0, 7.0, 7.0, 1.0, 10.0, 0.0, 2.0])
       (0.0, [117.0, 5.0, 3.0, 0.0, 0.0, 55.0, 6.0, 0.0, 8.0, 28.0, 0.0, 8.0, 9.0, 0.0, 0.0, 8.0, 0.0, 1.0, 0.0, 2.0])
       (1.0, [85.0, 66.0, 17.0, 26.0, 501.0, 31.0, 11.0, 23.0, 12.0, 18.0, 14.0, 7.0, 6.0, 0.0, 22.0, 11.0, 5.0, 0.0, 4.0, 2.0])
       (1.0, [994.0, 370.0, 77.0, 174.0, 74.0, 31.0, 10.0, 92.0, 41.0, 45.0, 127.0, 22.0, 8.0, 0.0, 31.0, 33.0, 35.0, 0.0, 4.0, 10.0])
       (1.0, [849.0, 170.0, 171.0, 77.0, 174.0, 26.0, 8.0, 42.0, 15.0, 14.0, 11.0, 29.0, 0.0, 0.0, 0.0, 9.0, 3.0, 0.0, 12.0, 9.0])
       (0.0, [58.0, 0.0, 2.0, 0.0, 0.0, 6.0, 3.0, 0.0, 0.0, 0.0, 2.0, 0.0, 10.0, 0.0, 0.0, 1.0, 0.0, 2.0, 0.0, 1.0])
       (0.0, [209.0, 4.0, 0.0, 0.0, 0.0, 34.0, 4.0, 0.0, 1.0, 0.0, 0.0, 3.0, 4.0, 0.0, 0.0, 0.0, 0.0, 1.0, 0.0, 1.0])\\
       (1.0, [19.0, 17.0, 12.0, 31.0, 5.0, 5.0, 21.0, 7.0, 1.0, 25.0, 1.0, 0.0, 2.0, 0.0, 60.0, 3.0, 4.0, 0.0, 3.0, 1.0])
       (1.0, [939.0, 46.0, 13.0, 12.0, 41.0, 17.0, 56.0, 33.0, 17.0, 11.0, 8.0, 6.0, 25.0, 1.0, 0.0, 7.0, 11.0, 1.0, 5.0, 2.0])
       (1.0, [329.0, 79.0, 58.0, 55.0, 192.0, 19.0, 3.0, 27.0, 3.0, 29.0, 4.0, 3.0, 0.0, 0.0, 1.0, 27.0, 5.0, 0.0, 4.0, 1.0])
       (1.0, [16.0, 22.0, 3.0, 11.0, 30.0, 12.0, 152.0, 0.0, 1.0, 8.0, 31.0, 0.0, 0.0, 0.0, 0.0, 32.0, 0.0, 0.0, 2.0, 2.0])
       (1.0, [1447.0, 122.0, 103.0, 18.0, 2.0, 18.0, 40.0, 46.0, 18.0, 47.0, 14.0, 7.0, 30.0, 0.0, 4.0, 9.0, 3.0, 0.0, 2.0, 5.0])
       (1.0, [80.0, 26.0, 1.0, 3.0, 20.0, 2.0, 0.0, 1.0, 0.0, 0.0, 0.0, 1.0, 0.0, 3.0, 0.0, 0.0, 0.0, 0.0])
       (1.0, [117.0, 40.0, 40.0, 75.0, 40.0, 52.0, 50.0, 89.0, 64.0, 37.0, 9.0, 44.0, 3.0, 0.0, 8.0, 25.0, 8.0, 1.0, 6.0, 8.0])
```



Utilisation d'algorithmes :

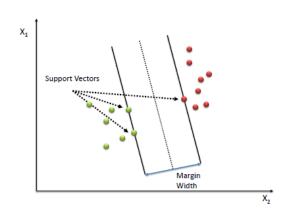
- Random Forest
 SVM : Support Vector Machine
- GBT : Gradient Boosting Tree

Modification de certains paramètres






3 algorithmes utilisés dans cet apprentissage supervisé




SVM

Random Forest




Ensemble Model: example for regression

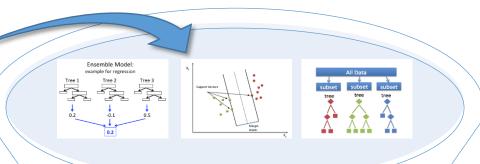


Gradient Boosting Tree





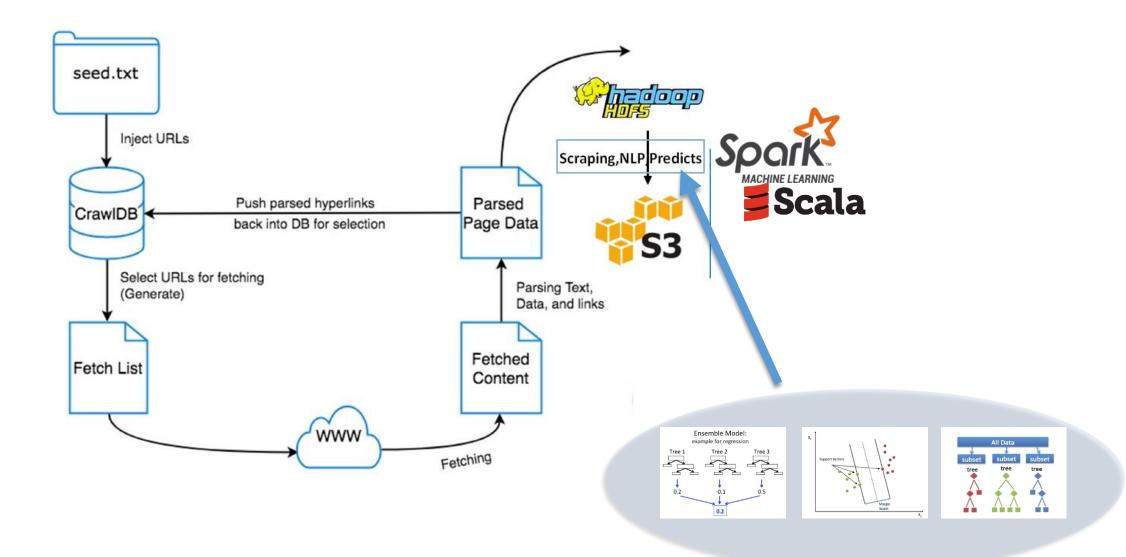




Vote majoritaire ou somme = 3

Prédiction (erreur 7%)







Offre clients

- Base des sites e-commerce avec n° siret : 90 000
- Base des sites e-commerce prédite : 165 000



Merci de votre attention



BORDEAUX (siège social)

3 rue Christian Franceries - Parc Chavailles 2 CS 80011 - 33522 BRUGES CEDEX

PARIS (bureaux commerciaux) 24 rue de Mogador 75009 PARIS **NIORT** (bureaux commerciaux) 7 rue du Docteur Roux 79000 NIORT **STRASBOURG** (bureaux commerciaux)

13 Rue Jacobi Netter 67200 STRASBOURG

Pour nous contacter : 01 44 51 66 99 www.groupe-cartegie.com