



**HAL**  
open science

## Proceedings of The First Day on Geographic Information System GISDAY

Nassim Dennouni, Hadj Henni Mhamed, Loukam Mourad, Mezzoudj Fréha,  
Tahar Abbas Mounir, Bechar Rachid, Benzaamia Imadeddine, Laraba  
Lounissa Naas, Bousahba Nassima, Adjoudj Réda, et al.

► **To cite this version:**

Nassim Dennouni, Hadj Henni Mhamed, Loukam Mourad, Mezzoudj Fréha, Tahar Abbas Mounir, et al.. Proceedings of The First Day on Geographic Information System GISDAY. THE FIRST DAY ON GIS, 2019. hal-04363540

**HAL Id: hal-04363540**

**<https://univ-rennes.hal.science/hal-04363540>**

Submitted on 26 Dec 2023

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons Attribution - NonCommercial 4.0 International License

Minister of Higher Education and Scientific Research  
Hassiba BENBOUALI University of Chlef  
The Faculty of Exact Sciences and Informatics  
Computer science department

## The First day on Geographic Information Systems

18<sup>th</sup> December 2019, Oulad Fares, Chlef

# GISDAY'2019 proceedings



<https://sites.google.com/view/uhbcgisday/>



# **The First day on Geographic Information Systems**

## **GISDAY 2019, 18<sup>th</sup> December 2019,**

### ***Hassiba Benbouali University of Chlef, Algeria***

#### **OVERVIEW**

GISDAY'2019 aims to promote the use of GIS in order to sensitize the university community to the certain impact of geographical data on the world around us. This day is also an opportunity to present research work related to all areas of GIS. The program of this scientific event includes tutorials on current topics and papers on research work as well as posters on the status of end-of-studies projects for future masters.

The event is open to all topics on GIS, but a preference is given to current topics (new technologies, innovative products ...). The list of themes (non-exhaustive): Artificial Intelligence, Web Technologies and Services, Natural Language Processing, Image Processing, Distributed Computing, Business Intelligence, Computer Security ...

#### **SCIENTIFIC COMMITEE**

ADJOU DJ REDA, SBA University (Algeria)  
ARIDJ Mohamed, Chlef University (Algeria)  
BECHAR Rachid, Chlef University (Algeria)  
BEDARD Yvan, Université Laval (Canada)  
BELLATRECHE Ladjel LIAS Laboratory (France)  
BELKREDIM Fatima Zohra, Chlef University (Algeria)  
BOUKERCHE Azzedine, University of Ottawa (Canada)  
BOUKLI HACENE Sofiane, SBA University (Algeria)  
BENABBOU Amel, ENSTA-BRETAGNE (France)  
DJERRIRI Khelifa Centre des Techniques Spatiales (Algeria)  
FEHAM Mohammed, Tlemcen University (Algeria)  
GUEMIDI Lahcene Chlef University (Algeria)  
KADRI Benamer, Tlemcen University (Algeria)  
KHOLLADI Mohamed-Khireddine, El-Oued University (Algeria)  
LEHIRECHE Ahmed, SBA University (Algeria)  
LOUKAM Mourad, Chlef University (Algeria)  
MEGUENNI Bouhadjar Centre des Techniques Spatiales (Algeria)

NAHNOUH Chakib, Chlef University (Algeria)  
IBRI Sarah, Chlef University (Algeria)  
SENOUCI Sidi Mohamed, Bourgogne University (France)  
SENOUCI Mohamed, Oran University (Algeria)  
SLAMA Zohra, SBA University (Algeria)  
TAHAR ABBAS Mounir, Chlef University (Algeria)  
TAHRAOUI Amin, Chlef University (Algeria)  
TOUATI Fatah, Centre des Techniques Spatiales (Algeria)  
ZEGOUR Djamel-Eddine, ESI (Algeria)

## **ORGANIZING COMMITTEE**

### **Chairman**

Pr. CHOUKRI A., Rector of University Hassiba BENBOUALI Chlef

### **Co-Chairman**

Dr. BOUJAMAA A., Dean of Exact Sciences and Informatic Faculty

### **President of the Organizing Committee:**

Dr. DENNOUNI Nassim, University Hassiba Ben Bouali Chlef

### **Coordinators:**

ALLALI Abdelmadjid

ARIDJ Mohamed

BOUKERCHE TAALIBI Toufik

BECHAR Rachid

HADJ HENNI Mhamed

KROLKRAL Narimane Wafaa

LOUKAM Mourad

MEZZOUDJ Fréha

SLIMANI Ahmed

TAHAR ABBAS Mounir

TAHRAOUI Amin

## **CONTACTS**

**Adresse :** Computer science department, The Faculty of Exact Sciences and Informatics,  
Hassiba BENBOUALI University of Chlef

**Email :** [uhbcgisday2019@gmail.com](mailto:uhbcgisday2019@gmail.com)

**Web site :** <https://sites.google.com/view/uhbcgisday>

# CONTENTS

## GISDAY PRESENTATIONS

Les Systèmes d'information géographique et l'aide à la décision.....	4
Vers l'extraction d'informations spatiales à partir de textes en Arabe standard .....	10
Reconnaissance Automatique de la parole et Modélisation du Langage Naturel .....	16
Positioning System for Emergency Situation Based on RSSI Measurements for WSN.....	22
A smart home IoT system based on machine learning .....	31
Traitement d'Images et les Systèmes d'Information Géographique .....	34
SIG et la recommandation contextuelle des POI .....	39

## GISDAY POSTER ABSTRACTS

Fusion des données dans l'imagerie satellitaire .....	49
Machine learning and deep learning for face recognition .....	50
Towards Author Profiling from Modern Standard Arabic Texts .....	51
Une approche de migration des machines virtuelles pour la gestion des contrats SLA dans le Cloud Computing .....	53
Distributed data clustering using ensemble techniques.....	54
Système immunitaire artificiel hybride pour la classification de données.....	55

## GISDAY POSTERS

1. Fusion des données dans l'imagerie satellitaire.
2. Machine learning and deep learning for face recognition.
3. Towards Author Profiling from Modern Standard Arabic Texts.
4. Une approche de migration des machines virtuelles pour la gestion des contrats SLA dans le Cloud Computing.
5. Distributed data clustering using ensemble techniques.
6. Simulation d'algorithmes d'ordonnancement pour la QoS.
7. Adaptation d'une solution NoSQL orientée graphe à partir d'une base de données relationnelle.
8. Système immunitaire artificiel hybride pour la classification de données.
9. Prédiction du temps de transcoding vidéo pour l'équilibrage de charge dans le cloud.
10. Un système de navigation à base de la logique floue : Application sur un système multi robots.
11. Une approche dirigée par les modèles pour l'intégration du BIG-DATA.
12. Reconnaissance Biométrique par Fusion Multimodale du Visage et de l'Iris.
13. Développement d'algorithme d'évitement d'obstacle dynamique dans un réseau de capteur sans fil.
14. Authentification et identification d'individus par reconnaissance de caractéristiques biométriques liées aux visages.
15. Construction des entiers naturels et leur Impact en Informatique.

# Les Systèmes d'information géographique et l'aide à la décision

**Nassim DENNOUNI, Mhamed HADJ HENNI**

Computer science department, Faculty of exact sciences and Informatics,  
Hassiba Benbouali University of Chlef, Algeria

**n.dennouni@univ-chlef.dz, md.hadjhenni@univ-chlef.dz**

## **Résumé :**

De nos jours, la majorité des applications informatiques utilisent la géolocalisation des objets, des personnes et des événements. Plusieurs secteurs comme l'aménagement du territoire, le transport, la santé, l'éducation,... font appel à ce genre d'application et souhaitent regrouper leurs points d'Intérêt (POI) sur le même référentiel. Pour répondre à cet objectif, les Systèmes d'Information Géographique (SIG) peuvent superposer plusieurs couches thématiques sur la même carte afin de permettre aux décideurs de faire des analyses spatiales à travers des requêtes géométriques et sémantiques. Dans cet article, nous expliquons comment utiliser les technologies existantes pour bien monter un projet de SIG au niveau de la wilaya de Chlef. Pour cette raison, nous abordons (1) les difficultés rencontrées lors de la collecte des données géographiques et leurs intégrations dans les SIG, (2) les défis à surmonter pour le recensement des différents besoins par secteurs/acteurs et (3) l'apport des analyses en ligne (OLAP) pour les décideurs.

**Mots clés :** *SIG, POI, OLAP, analyse spatiale, aide à la décision, OpenStreetMap.*

## **Introduction**

Un SIG est un système d'information conçu pour recueillir, stocker, traiter, analyser, gérer et présenter tous les types de données spatiales et géographiques. Les applications liées aux SIG sont des outils qui permettent aux utilisateurs de créer des requêtes interactives, d'analyser l'information spatiale, de modifier et d'éditer des données en utilisant des cartes. Pour ces raisons, les SIG sont étroitement liés à des domaines comme l'aménagement du territoire, la gestion des infrastructures réseaux, le transport et la logistique, l'assurance, les télécommunications, l'ingénierie, la planification, l'éducation, la recherche, etc. En effet, les SIG permettent d'identifier et de représenter des objets et des événements qui illustrent notre environnement (coordonnées GPS, latitude et longitude, adresse, altitude, temps, ...) en réunissant ces dimensions autour d'un même référentiel [1].

Selon l'économiste français, Michel Didier (1990), « les SIG sont des ensembles de données repérés dans l'espace structurés de façon à pouvoir en extraire des synthèses utiles à la décision ». Ce type de synthèses déduites à partir d'applications spatiales peut renforcer le développement économique à l'échelle d'un pays dans des domaines comme l'agriculture, la pêche, la gestion des ressources en eau, la prévention des risques majeurs, l'urbanisme, la mise en œuvre des nouveaux sites industriels ...[2].

Dans cet article, nous donnons un bref aperçu sur l'évolution des SIG, ensuite nous expliquons le concept de l'analyse spatiale et ses opérateurs géométriques. Dans les sections 4 et 5, nous abordons l'apport des SIG pour l'aide à la décision ainsi que les technologies qui peuvent être utilisées autour des projets d'analyse en ligne. Enfin, nous proposons l'architecture et l'infrastructure réseau pour la réalisation d'un projet de SIG-OLAP pour la wilaya de Chlef qui devra faciliter la prise de décision.

## I. Évolution des SIG

En 1854, John Snow a analysé une épidémie de choléra à Londres en utilisant des points pour représenter les emplacements de certains cas individuels sur une carte. Ceci était l'une des premières réussites de l'utilisation d'un SIG. En effet, la carte de John Snow était unique car elle décrivait une situation permettant d'analyser des groupes de phénomènes géolocalisés et interdépendants [2].

Dans les années 1960, le domaine des SIG a débuté avec l'émergence des ordinateurs et des premiers concepts de géographie quantitative. Les premiers travaux comprenaient d'importantes recherches menées par la communauté universitaire. En 1963, une première version du SIG qui repose sur un système d'approche par couches pour la cartographie est mise au point par le Système géographique canadien (SIGC) [3].

Du milieu des années 1970 au début des années 1980, les SIG sont utilisés dans l'armée, le cadastre, les recensements et les services topographiques. Cette époque marque l'explosion du marché des SIG, avec une multiplication des fournisseurs. Progressivement, l'usage de l'information géographique (cartographie sur Internet, calcul d'itinéraires routiers, utilisation d'outils embarqués liés au GPS dès 1985...) se généralise dans les entreprises et dans la société civile [3].

Depuis 1990, les SIG ont connu une phase de croissance quasiment dans toutes les professions. Plusieurs facteurs expliquent cette démocratisation : des ordinateurs plus rapides à coût modéré, une offre très diversifiée de logiciels, un accès facilité aux données et l'intégration de la télédétection comme outil des SIG [3].

## II. Les SIG et l'analyse spatiale

La projection cartographique est un ensemble de techniques géodésiques permettant de représenter la surface de la terre sur une carte. Plusieurs types de projection existent comme la projection cylindrique, conique et azimutale.

Grâce à l'utilisation de ces projections, les SIG permettent la superposition de deux types de couches de données la première sous forme de carte et la deuxième sous forme d'image. Cependant, l'image à superposer doit être géoréférencée à l'aide de l'opération de calage d'une image raster par des points de repères géographiques.

Pour atteindre cet objectif de superposition de couches, les SIG peuvent utiliser deux opérations ; (1) la rasterisation qui correspond à la conversion d'une image vectorielle en matrice de pixels et (2) la vectorisation qui convertie d'une matrice de pixels en vecteurs géographiques individualisés.




Fig. 1. Exemple de superposition de couches thématiques.

Les données alphanumériques des SIG sont regroupées dans des tables formées de lignes et de colonnes. Chaque ligne correspond à une entité géographique (point, ligne, polygone) et chaque colonne contient des informations concernant un champ donné (par exemple, nom,

population, etc...). La figure 1 illustre un exemple de superpositions de trois couches thématiques : la première couche concerne des Point Of Interest (POI) dans une zone donnée comme les restaurants, les hôtels, les monuments historiques,... (des objets ponctuels), la deuxième couche regroupe les rivières de cette zone (des objets linéaires) et la troisième couche montre les limites administratives des quartiers de cette même zone (des objets surfaciques). Les SIG permettent l'interrogation des bases de données géoréférencées à l'aide de requêtes comme par exemple tous les POI situés à plus de 10 km de la position actuelle d'un visiteur.

L'analyse spatiale permet de décrire une disposition particulière de certains objets, leurs organisation spatiale, leurs répartitions dans l'espace. Elle fait appel à deux catégories d'opérateurs spatiaux : (1) les opérateurs métriques qui analysent une ou plusieurs entités géographiques en fonction de leurs distances (longueur d'une ligne, périmètre d'un polygone, superficie d'une aire) et (2) les opérateurs topologiques qui utilisent les relations spatiales topologiques (contient, se croise,...) entre les entités géographiques [4]. Ce type d'analyse spatiale permet de traiter des problèmes comme (1) la recherche du plus court chemin entre deux lieux A et B dans un SIG route [5], (2) le choix du meilleur emplacement pour un magasin, (3) le calcul du nombre de personnes touchés par une épidémie, ...

### **III. SIG et l'aide à la décision**

Les SIG permettent de visualiser des données géolocalisées sous forme de couches thématiques et cela peut réduire la complexité de la réalité terrain. Cette dernière peut être facilement appréhendée grâce aux analyses spatiales comme la recherche du meilleur chemin, la détermination des zones touchées par des séismes, le calcul des indemnités pour les assurés,... Ces types d'analyses peuvent être utilisés par les SIG pour faciliter l'observation des phénomènes tel que la désertification, la pollution, les épidémies, ...

En outre, les SIG peuvent prédire les risques naturels comme les feux de forêt, les inondations,... et permettent le suivi du niveau moyen des mers par des missions spatiales comme Topex/Poseidon et Jason1 [6] ou autre.

Au niveau de la wilaya de Chlef, les SIG sont des applications à recommander dans les domaines de l'agriculture et de la pêche, des ressources en eau, des risques majeurs, de l'urbanisme et de la mise en œuvre des nouveaux sites industriels. En effet, les SIG permettent de faire la prévision du rendement agricole et la gestion des sites aquacoles à partir de l'exploitation des images satellitaires. En outre, les SIG peuvent gérer des aménagements forestiers et faire le suivi des catastrophes naturelles comme les feux de forêts et les inondations. Par ailleurs, les SIG contribuent aussi à la gestion du patrimoine foncier industriel de la wilaya de Chlef grâce à leurs outils d'analyse spatiale et de cartographie [7].

### **IV. Les technologies autour des SIG**

Les SIG sont intimement liés aux nouvelles technologies et contribuent à leurs évolutions. Par exemple, les smartphones permettent aux utilisateurs des SIG de s'affranchir des contraintes de localisation et de temps car ils peuvent prendre des décisions immédiates sur le terrain et cela présente un avantage pour l'enrichissement plateformes collaborative grand public [8]. En effet, l'accès à ces plateformes devient plus simple grâce à l'émergence d'ontologies partagées et l'avènement des formats ouverts et des standards d'échange [9]. En outre, les masses importantes des données des SIG sont stockées dans des structures post relationnels comme les Big Data. D'après notre expérience, la problématique majeure liée à cette technologie réside dans les contraintes d'analyse de ce type de structure de données par les décideurs. Actuellement, la puissance algorithmique de l'IA apporte une nouvelle dimension dans la fouille des données spatio-temporelles manipulées par les différents usages des SIG car elle permet de les explorer, d'identifier des corrélations et de faire des recommandations acceptables aux différents utilisateurs.



Après la maîtrise de la 3D, l'humain ajoute la dimension du temps. Cette dimension permet de projeter un territoire dans l'espace et le temps. Dans ce contexte, les SIG peuvent utiliser la réalité augmentée qui offrent à leurs utilisateurs la possibilité d'y voir les futurs aménagements et d'y visualiser les services disponibles par POI.

Enfin, la tendance actuelle des SIG est l'intégration de l'IoT (Internet Of things) au sein des plateformes collaboratives afin de collecter et d'exploiter les données générées par les différentes applications de ce type [8].

## V. Comment monter un projet SIG-OLAP pour la wilaya de Chlef ?

La wilaya de Chlef est une zone à caractère agricole, son emplacement stratégique entre la capitale Alger et la grande ville d'Oran lui permet d'être un pôle économique d'excellence. Les seuls SIG existants au niveau de cette wilaya sont développés de façon indépendante par des secteurs comme l'industrie, l'agriculture, la pêche et le tourisme. Cependant, ces SIG ne permettent pas aux décideurs de la wilaya d'avoir une vue globale sur tous les secteurs économiques en vue d'une prise de décision stratégique. Pour atteindre cet objectif, nous mettons en place un projet de SIG couplé à un système d'analyse en ligne de type OLAP pour la wilaya de Chlef. Notre équipe de projet a commencé par définir les besoins d'analyse des différents secteurs de la wilaya de Chlef (tourisme, agriculture, protection civile, urbanisme,...). Ensuite, nous avons choisis les outils SIG adéquats pour permettre la centralisation des données au niveau des décideurs (Wali, SG, directeur,...). Cette phase de collecte des données à partir des SIG existants nécessite le développement d'une méthodologie qui permet l'intégration de la masse importante des données issues de sources hétérogènes tout en définissant les modalités de partage. Ces dernières doivent respecter le cadre juridique lié à la protection aux données géographiques (OpenStreetMap, Google maps, ...). Les prestataires s'occupent de l'actualisation des données géométriques (objets ponctuels, linéaires et surfaciques) et les acteurs des secteurs économiques prennent en charge la mise à jour des données des différentes BD qui les concernent. La centralisation de ces données SIG implique l'utilisation d'un même référentiel géographique pour l'ensemble des données à intégrer dans l'entrepôt des données géographiques (DataWarehouse). Cet entrepôt peut être divisé en plusieurs DataMarts selon les besoins d'analyse des décideurs. La figure 2 présente notre proposition d'architecture du projet SIG- OLAP Chlef qui résume l'ensemble des acteurs qui peuvent intervenir dans un projet d'analyse SIG au niveau de la wilaya de Chlef.

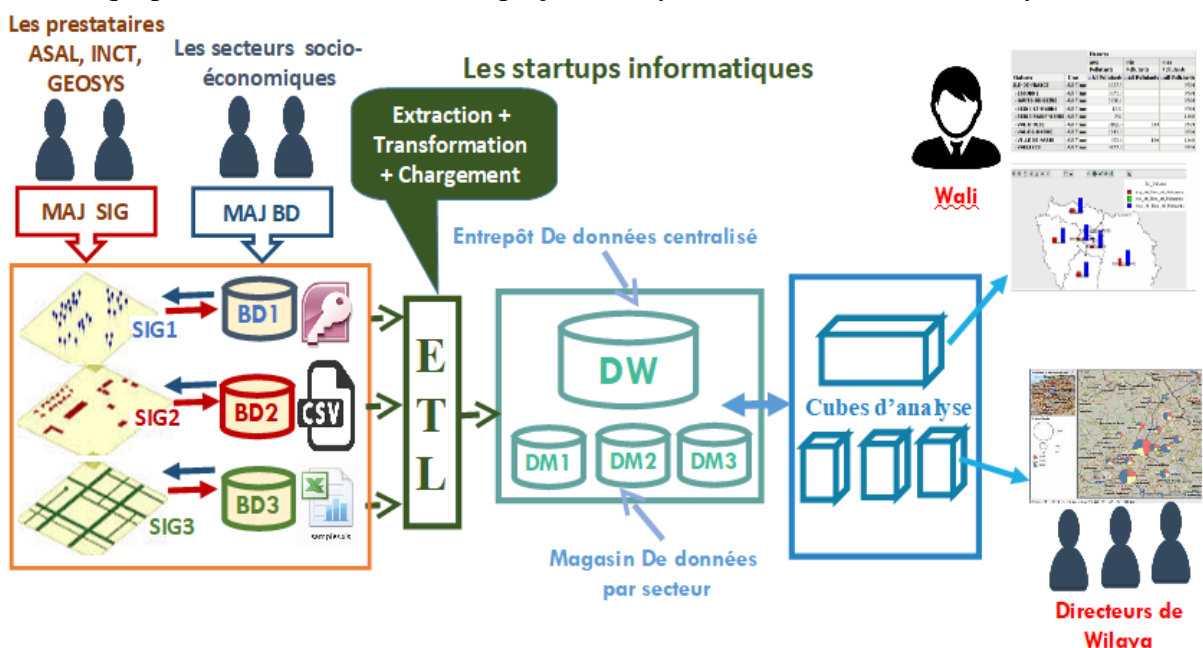


Fig. 2. Proposition d'une maquette du projet SIG-OLAP Chlef.

Pour mieux gérer ce projet SIG- OLAP de Chlef, l'équipe projet doit préparer quatre dossiers : (1) le dossier d'analyse des besoins par direction de wilaya (tourisme, forêts ...), (2) le dossier de conception qui permet la modélisation des fonctionnalités qui correspondent aux principaux besoins d'analyse de tous les secteurs de la wilaya souhaitant utiliser un SIG, (3) le dossier de réalisation qui contient le rapport d'étude technique du cadastre, les cahiers des charges par commune/secteur et la proposition de planning de réalisation et (4) le dossier de mise en production d'application SIG-OLAP et de ses procédures d'exploitation.

Après avoir préparé ces quatre dossiers, la démarche à suivre par le chef de projet commence d'abord par exploiter le travail de numérisation déjà réalisé par le service de cadastre ensuite le défi majeur du projet consiste à mettre en place des BD géographiques par secteur et par commune de la wilaya. Une des solution qui peuvent répondre aux besoins des directeurs, des employés par direction et des citoyen est le déploiement d'une application SIG multithématique basée sur une technologie web (Intranet/Extranet) destinée à l'analyse en ligne de type OLAP comme c'est indiqué dans la figure 3 .

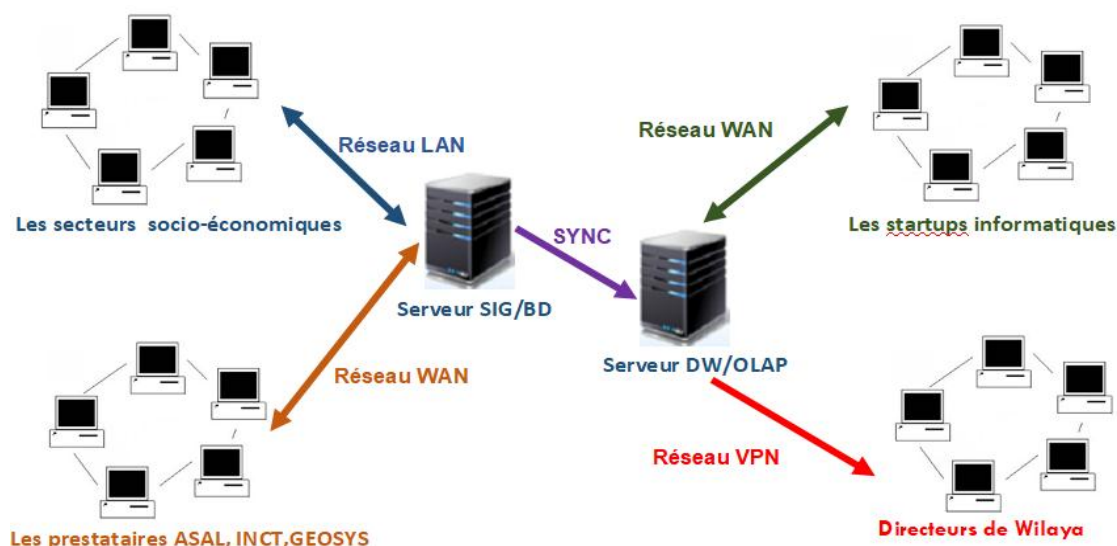


Fig. 3. L'infrastructure réseau du projet SIG Chlef à réaliser.

Ce type d'application doit être soutenu par la mise en place de tableau de bord pour l'analyse des données des SIG de tous les secteurs et toutes les communes par les décideurs de la wilaya de Chlef. Cependant, le SIG doit évoluer avec le temps en autorisant des opérations de mise à jour issues de campagnes de relevés GPS pour assurer l'enrichissement des SIG.

En juin 2018, Google a décidé de réduire la limite du nombre de requêtes gratuites par jour mais aussi d'obliger les utilisateurs à fournir leur numéro de carte de crédit pour faire des tests ou du développement en utilisant l'API de Google Maps. Pour cette raison, l'utilisation d'OpenStreetMap peut être considérée comme une vraie alternative à ce problème car elle représente une carte du monde entier publiée gratuitement sous une licence de contenu libre. D'autre part, Google Maps ne donne pas accès aux données utilisées pour créer les cartes à l'inverse d'OpenStreetMap qui permet un accès complet à la base de données de création [10]. Dans ce contexte des nouvelles technologies, le développement des usages de SIG par secteur nécessite forcément la formation des agents par commune à l'aide d'animation de workshop national par des organismes comme l'ASAL<sup>1</sup>, le CTS<sup>2</sup>, INCT<sup>3</sup>,...

<sup>1</sup> Agence Spatiale Algérienne

<sup>2</sup> Centre des Techniques Spatiales

<sup>3</sup> Institut National de Cartographie et de Télédétection

En outre, la création des startups dans le domaine des SIG au niveau de l'incubateur de l'université présente une bonne initiative pour faire face aux défis que peuvent poser les SIG du futur.

## **Conclusion**

Les SIG présentent un grand intérêt au développement d'un pays dans différents domaines à travers la facilitation de la prise de décision. Pour cette raison, nous nous sommes intéressés dans le cadre de cet article aux solutions techniques qui permettent la mise en place de SIG centralisé destiné à l'analyse décisionnelle au niveau de la wilaya de Chlef. Nous avons expliqué que plusieurs acteurs peuvent travailler dans ce type de projet d'où la nécessité de proposer une architecture basée sur une infrastructure réseau permettant d'assurer la sécurité des différents accès. Par exemple, les acteurs des secteurs socio-économiques disposent de leurs propres interfaces pour faire les mises à jours des données sémantiques (adresses, propriétaires, ...) au niveau de leurs SIG respectifs. En utilisant une autre interface, les prestataires de cartographie actualisent les données géométriques dans le cas où il y a des changements majeurs dans les couches thématiques à étudier. Enfin, plusieurs start-up peuvent créer des analyses des entrepôts de données destinées aux différents décideurs grâce à leurs propres interfaces de développement.

## **ACKNOWLEDGMENT**

Ce projet est supporté par le ministère algérien de l'enseignement supérieur et de la recherche scientifique.

## **REFERENCES**

- [1] Le Tourneau, Cécile. « Un système d'information géographique ». *Bulletin des bibliothèques de France (BBF)*, 2000, n° 6, p. 77-81. Disponible en ligne : <<http://bbf.enssib.fr/consulter/bbf-2000-06-0077-003>>. ISSN 1292-8399.
- [2] Système d'information géographique. Wikipédia, l'encyclopédie libre. Page consultée le 24/10/2019.
- [3] Annie SPRATT, « Les SIG à travers les âges », 2018.
- [4] Boris MERICKSKAY, « SIG et analyse spatiale : les géotraitements », université de RENNE, 2015
- [5] Nassim DENNOUNI, Ahmed LEHIRECHE, « Mise en œuvre d'un SIG », 2007.
- [6] Nassim DENNOUNI, Ahmed LEHIRECHE, « Conception et expérimentation des cubes OLAP pour l'analyse d'un entrepôt de données d'altimétrie spatiale » 2009.
- [7] Rony GAL, « Les tendances du SIG », 2018.
- [8] Nassim DENNOUNI, Ahmed LEHIRECHE, « Towards a spatiotemporal model for the interworking of the GIS » The third edition of the International Conference on Web and Information, 16-19 juin, Marrakech, Maroc.
- [9] Recommandations de la journée d'étude Wilaya de Chlef – Agence Spatiale Algérienne Tenue le 27 février 2019 à Chlef (<https://asal.dz/?p=902>) consultée le 25 octobre 2019
- [10] [https://wiki.openstreetmap.org/wiki/FR:À\\_propos\\_d'OpenStreetMap](https://wiki.openstreetmap.org/wiki/FR:À_propos_d'OpenStreetMap)

# Vers l'extraction d'informations spatiales à partir de textes en Arabe standard

**Mourad LOUKAM**

*LMA Laboratory, Faculty of exact sciences and Informatics,  
Hassiba Benbouali University of Chlef, Algeria.  
m.loukam@univ-chlef.dz*

## Résumé

L'extraction d'informations spatiales à partir de données textuelles est un axe de recherche important dans le domaine du Traitement Automatique du Langage Naturel (TALN). Elle ouvre des jonctions très intéressantes entre ce domaine et plusieurs applications, comme : la recherche d'informations, les systèmes d'informations géographiques, l'aménagement du territoire, et plus récemment les villes intelligentes. Nous présentons dans ce papier notre projet d'extraction de concepts à partir de textes en Arabe standard. L'extraction d'informations spatiales fait partie de nos objectifs.

**Mots clés :** *Text-mining, Extraction d'informations spatiales, Arabe standard moderne, Entités spatiales, Relations spatiales.*

## Introduction

L'extraction d'informations spatiales à partir de données textuelles suscite depuis plusieurs années un intérêt grandissant dans le domaine du Traitement Automatique des Langues Naturelles (TALN). Cela s'explique par les multiples connexions qu'elle ouvre avec plusieurs autres domaines, comme : la recherche d'informations, les systèmes d'informations géographiques, l'aménagement du territoire, et plus récemment les villes intelligentes (smart cities).

Avec l'avènement de l'internet et des réseaux sociaux, les grandes masses de données textuelles que véhiculent ces supports, se sont révélées de précieuses ressources pour l'extraction de connaissances dans de nombreux domaines (notamment le business intelligence, l'analyse de sentiments, l'author profiling, etc.). Dans ce contexte, de nombreux travaux propres à l'analyse de l'information spatiale s'appuient sur l'exploitation de ces données textuelles à partir d'un ou plusieurs types de sources (articles de presse, documents techniques, revues, romans, etc.) [1-2]. Ces données textuelles sont éventuellement combinés à d'autres types de données, par exemple les images satellites [3] et les données GPS [4].

Rappelons que l'information géographique est définie comme la composition de trois informations : spatiale, temporelle et thématique. L'idée principale est que la combinaison de ces trois informations permet de décrire un évènement qui se déroule ou s'est déroulé dans un lieu donné, à un moment donné [2-5]. Parmi ces trois composantes de l'information géographique, nous nous intéressons dans cet article au traitement de l'information spatiale.

Nous travaillons sur un projet d'extraction de concepts à partir de textes en Arabe standard moderne. Ce projet, initié en 2018, est supporté par le Ministère algérien de l'enseignement supérieur et de la recherche scientifique. Les concepts recherchés à partir des données

textuelles sont de différentes catégories : termes clés, entités nommées, informations spatiales, relations de causalité, etc. Nous nous limiterons, dans ce papier, à l'extraction d'informations spatiales.

## I. Extraction d'informations spatiales en arabe standard

Pour introduire la problématique de l'extraction d'informations spatiales à partir de données textuelles en Arabe standard, nous donnons les exemples suivants.

Texte 1 :

أوضح الوزير خلال الزيارة الميدانية التي قادته إلى ولاية تيبازة إن قانون المالية الجديد سيسمح للمتعاملين بالاستفادة من قروض من دون فوائد على الاستثمارات الخاصة بتربية المائيات والصيد البحري.

*Le Ministre a précisé lors de sa visite qui l'a menée à la wilaya de Tipaza que la nouvelle loi de finances permettra aux opérateurs de bénéficier de crédits sans intérêts sur les investissements dans le domaine de l'aquaculture et de la pêche marine.*

Texte 2 :

أكد مراسلنا أن الحادث وقع عند المدخل الشرقي للمدينة.

*Notre correspondant a affirmé que l'accident a eu lieu à l'entrée est de la ville.*

Texte 3 :

بعد إشرافه على الإفتتاح الرسمي للسنة الجامعية الجديدة بجامعة المدينة ، دشن الوزير القطب الجامعي بالعفرون. و في الظهيرة استقبل سفير جمهورية التشيك بمقر الوزارة

*Après avoir présidé l'ouverture officielle de la nouvelle année universitaire à l'Université de Médéa, le Ministre a inauguré le campus d'El Afroun, et dans l'après-midi il a reçu l'ambassadeur de la république tchèque au siège du Ministère.* Ces trois textes sont représentatifs de quelques catégories d'informations spatiales qu'on peut trouver dans les documents textuels.

Dans le texte 1, l'information spatiale fait référence à une entité spatiale, qui est en même temps une entité nommée : « la wilaya de Tipaza ».

Dans le texte 2, l'information spatiale est composée d'une entité spatiale « la ville » et d'une relation spatiale « entrée Est ».

Dans le texte 3, nous avons un exemple d'extraction de plusieurs entités spatiales qui forme un parcours. Le problème ici est la détection d'un itinéraire dans un récit.

Le but recherché de l'extraction d'informations spatiales est de faire une modélisation des entités et des relations spatiales qu'elles invoquent, aux fins d'alimenter un système d'informations géographiques, ou en général un système de géo-gouvernance (Fig. 1).




Fig. 1. Objectifs de l'extraction d'informations spatiales à partir de données textuelles.

## II. Extraction d'entités spatiales

Généralement, dans les travaux prenant les données textuelles comme ressources, les informations spatiales sont exprimées en entités spatiales (ES) et relations spatiales (RS).

On peut dire que le concept d'entité spatiale (ES) est un cas particulier d'entité nommée. Rappelons que l'entité nommée (EN) est un concept introduit dans les années 90 ; il est défini comme un mot ou un groupe de mots désignant une personne, une organisation ou entreprise, un lieu, une date ou encore une expression numérique.

Les ES sont de différentes catégories, et un vocabulaire diversifié existe pour les identifier. On peut citer en autres :

- **des concepts topographiques, par exemple :** « واد وهران » (« *Oued d'Oran* »), « طريق المطار » (« *route de l'aéroport* »), etc.
- **des lieux géographiques, par exemple :** « الجزائر العاصمة » (« *Alger* »), « البريد المركزي » (« *Grande poste* »), etc.

Les travaux d'extraction des ES (ou EN de type lieu/location) à partir des données textuelles peuvent être classés en trois principales approches : des méthodes à base de règles, des méthodes à base d'apprentissage et des méthodes hybrides [6].

### A. Méthodes à base de règles

Les méthodes à base de règles se basent sur l'utilisation de règles morpho-syntaxiques en combinant, éventuellement, des ressources externes comme des dictionnaires (de villes, de lieux, etc.). Parmi ces approches, nous pouvons citer les travaux suivants :

Wakao et al. [7] ont décrit un système d'extraction d'information (LaSIE « Large Scale Information Extraction ») dans lequel quatre catégories d'EN sont reconnues (organisation, personne, nom de lieu et expression temporelle). LaSIE utilise un étiquetage morpho-syntaxique du texte et une grammaire locale axée sur les noms propres. Les auteurs affirment que leur approche a une performance de plus de 90% (en précision et rappel) sur un corpus de 30 textes en Anglais.

Stern and Sagot [8] ont décrit un système de reconnaissance d'EN, dénommé NP. Il opère en deux étapes :

Une pour la détection et le typage, et l'autre pour la désambiguïsation et la résolution des EN. Une grammaire indépendante du contexte comprenant 130 règles a été développée pour détecter et typer des EN. Ensuite, des heuristiques de désambiguïsation fondées sur des informations quantitatives et qualitatives ont été appliquées afin de réduire l'ambiguïté. Le système NP a atteint un score de F-mesure de 77% sur un corpus de l'AFP.

Maurel et al. [9] ont présenté le système CasEN dédié au traitement des textes en français. Le processus de traitement de CasEN utilise des ressources lexicales et des grammaires locales (transducteurs), exécutées dans un ordre précis.

D'une manière générale, les approches à base de règles permettent d'obtenir une bonne performance (en termes de précision et de rappel). Cependant, leur inconvénient est le coût élevé de la constitution des règles par des experts humains, et aussi ces approches sont dépendantes de la langue utilisée.

## ***B. Méthodes à base d'apprentissage***

Les méthodes à base d'apprentissage (supervisés ou non-supervisés) utilisent des modèles de classification afin d'identifier les EN. Les méthodes supervisées reposent sur l'utilisation d'un ensemble de données étiquetées (par des experts) pour apprendre un modèle qui sera par la suite utilisé pour déduire la classe d'appartenance de nouvelles données non étiquetées. Parmi les travaux utilisant l'apprentissage supervisé pour extraire les EN de type lieu (location), nous pouvons citer :

TABLE I QUELQUES TRAVAUX UTILISANT L'APPRENTISSAGE SUPERVISE POUR L'EXTRACTION DES ENTITES NOMMEES

<b><i>Auteurs</i></b>	<b><i>Année</i></b>	<b><i>Méthode</i></b>
Shabat et al.[10]	2014	Support Vector Machine
Morwal et al. [11]	2013	Hidden Markov Models
Ahmed et al. [12]	2015	Maximal Entropy
Konkol et al.[13]	2013	Conditional Random Fields

Les méthodes basées sur l'apprentissage supervisé donnent généralement de bons résultats (en termes de précision et de rappel). Cependant, leur inconvénient majeur réside dans le fait qu'elles exigent la disponibilité de larges ensembles de données d'apprentissage. C'est pourquoi, les approches non-supervisées et semi-supervisées peuvent s'avérer une alternative intéressante.

Les méthodes d'apprentissage non-supervisé utilisées dans les systèmes d'Extraction d'Information cherchent à apprendre directement à partir de textes bruts ou se fondent sur une petite base d'exemples dans le cas d'apprentissage semi-supervisé [2]. Parmi les travaux appartenant à ces approches, nous pouvons citer :

Lie et al. [14] ont proposé une approche semi-supervisée pour extraire des EN de type lieu (location) à partir de données textuelles provenant du web. L'approche se base sur l'utilisation d'une infime partie des données comme base d'apprentissage. Les auteurs affirment que leur solution a une performance très proche de celle que donnent des approches utilisant un vrai large ensemble de données (on a à peine 4% de f-score en moins).

Généralement, les méthodes à apprentissage non supervisé ou semi-supervisé ont une performance inférieure à celles à apprentissage supervisé, mais cette « perte » peut être acceptable eu regard à l'important avantage qu'elles procurent : elles n'exigent pas de grands ensembles d'apprentissage.

## ***C. Méthodes hybrides***

Les approches hybrides combinent les méthodes à base de règles et les méthodes d'apprentissage.

Par exemple, Shaalan et al. [15] ont proposé une méthode hybride pour la reconnaissance des EN de la langue arabe. Les auteurs affirment que la performance de leur solution (en terme de f-score) atteint 90% pour les EN de type lieu (location).

### III. Extraction de relations spatiales

Une relation spatiale est un indicateur spatial qui fait référence aux relations entre les entités spatiales [2]. En langue arabe, ces indicateurs sont généralement un adverbe de lieu (« ظرف مكان »), comme dans les exemples suivants :

وقع الحادث عند المدخل الشرقي للمدينة

*L'accident a eu lieu à l'entrée est de la ville*

تحلق الطائرة الآن فوق العاصمة

*En ce moment, l'avion survole la capitale*

تتجه العاصفة غربا

*La tempête se dirige vers l'ouest*

تقع مدينة الشلف في منتصف الطريق بين الجزائر العاصمة وهران

*La ville de Chlef se trouve à mi-chemin entre la capitale Alger et Oran.*

L'extraction de relations spatiales a été étudiée dans plusieurs travaux. Nous citons, entre autres :

Nguyen et al. [5] qui ont proposé une méthode basée sur une approche lexico-syntaxique. La méthode s'appuie sur l'identification des relations n-aires pour l'enrichissement d'une ontologie géographique à partir de l'analyse automatique d'un corpus textuel. À partir de ces relations et d'un lexique de termes géographiques, des relations spatio-temporelles sont identifiées. L'idée proposée est de traiter l'ensemble des phrases qui comportent une relation n-aire afin d'identifier un verbe de déplacement ainsi que les entités spatiales et temporelles. Dans ce cas, une relation spatio-temporelle entre ces entités est alors constituée [2].

### Conclusion

Dans ce papier, nous avons présenté notre projet d'extraction d'informations spatiales à partir de textes en Arabe standard. L'objectif est de modéliser les entités et les relations spatiales constituées afin d'alimenter un système de géo-gouvernance à partir de données textuelles.

Un important travail doit être entrepris pour faire une étude des phénomènes linguistiques présents dans les textes relatifs aux entités et aux relations spatiales. Ensuite un choix des meilleures méthodes possibles doit être fait pour réaliser l'implémentation. A la fin, une évaluation doit être menée pour tester la performance de la solution proposée.

### ACKNOWLEDGMENT

Ce projet est supporté par le Ministère algérien de l'enseignement supérieur et de la recherche scientifique.

### REFERENCES

- [1] Sallaberry, C. (2014). Recherche d'information géographique dans des corpus textuels. ISTE Group.



- [2] Zenasni, S.(2018). Extraction d'information spatiale à partir de données textuelles non-standards. Thèse de Doctorat. Université de Montpellier, 2018.
- [3] Salas, H. A., Kergosien, E., Roche, M., and Teisseire, M. (2014). Animitex project : Image analysis based on textual information. In SIMBig : Symposium on Information Management and Big Data, pages 49–52.J. Clerk Maxwell, A Treatise on Electricity and Magnetism, 3rd ed., vol. 2. Oxford: Clarendon, 1892, pp.68–73.
- [4] Rikitianskii, A., Harvey, M., and Crestani, F. (2014). A personalised recommendation system for context-aware suggestions. In ECIR, pages 63–74.
- [5] Nguyen, V. T. (2012). Méthode d'extraction d'informations géographiques à des fins d'enrichissement d'une ontologie de domaine. Thèse de Doctorat. Université de Pau.
- [6] Wu, Y. C., Fan, T. K., Lee, Y. S., & Yen, S. J. (2006, April). Extracting named entities using support vector machines. In International Workshop on Knowledge Discovery in Life Science Literature (pp. 91-103). Springer, Berlin, Heidelberg.
- [7] Wakao, T., Gaizauskas, R., & Wilks, Y. (1996, August). Evaluation of an algorithm for the recognition and classification of proper names. In Proceedings of the 16th conference on Computational linguistics-Volume 1 (pp. 418-423). Association for Computational Linguistics.
- [8] Stern, R., & Sagot, B. (2010, July). Détection et résolution d'entités nommées dans des dépêches d'agence.
- [9] Maurel, D., Friburger, N., Antoine, J. Y., Eshkol, I., & Nouvel, D. (2011). Cascades de transducteurs autour de la reconnaissance des entités nommées. *Traitement automatique des langues*, 52(1), 69-96.
- [10] Shabat, H., Omar, N., & Rahem, K. (2014, December). Named entity recognition in crime using machine learning approach. In Asia Information Retrieval Symposium (pp. 280-288). Springer, Cham.
- [11] Morwal, S., & Jahan, N. (2013). Named entity recognition using Hidden Markov Model (HMM): an experimental result on Hindi, Urdu and Marathi languages. *Int. J. Adv. Res. Comput. Sci. Softw. Eng*, 3(4).
- [12] Ahmed, I., & Sathyaraj, R. (2015). Named entity recognition by using maximum entropy. *International Journal of Database Theory and Application*, 8(2), 43-50.
- [13] Konkol, M., & Konopík, M. (2013, September). CRF-based Czech named entity recognizer and consolidation of Czech NER research. In International Conference on Text, Speech and Dialogue (pp. 153-160). Springer, Berlin, Heidelberg.
- [14] Lie H., Nayak R., Wyeth G. (2017) Spatial Information Recognition in Web Documents Using a Semi-supervised Machine Learning Method. In: Bouguettaya A. et al. (eds) Web Information Systems Engineering – WISE 2017. WISE 2017. Lecture Notes in Computer Science, vol 10569. Springer, Cham.
- [15] Shaalan, K., & Oudah, M. (2014). A hybrid approach to Arabic named entity recognition. *Journal of Information Science*, 40(1), 67-87.

# Reconnaissance Automatique de la parole et Modélisation du Langage Naturel

Fréha MEZZOUDJ

Computer science department, Faculty of exact sciences and Informatics,  
Hassiba Benbouali University of Chlef, Algeria.  
f.mezzoudj@univ-chlef.dz

## Résumé

La parole est un moyen incontournable de communication entre les humains. La reconnaissance Automatique de la Parole (PAR), qui facilite la communication entre les humains et les machines est basée sur plusieurs modules : partie acoustique et partie linguistique. L'amélioration d'un système de RAP est relative à l'amélioration de ses composantes. Dans ce papier, des techniques de sélection de données textuelles sont exploitées dans le but d'obtenir une meilleure modélisation du langage. Des résultats encourageants sont obtenus sur les modèles n-grams utilisés.

**Mots clés :** *Modèle de langage, Sélection des données, Données textuelles, Entropie croisée, Différence de moyenne quadratique des probabilités, perplexité, RAP, SIG*

## Introduction

Depuis longtemps, la parole est le moyen principal de communication entre les humains. Les recherches en Intelligence Artificielle consistent à reproduire les capacités d'un être humain à reconnaître le flux de la parole produite par un autre être humain. Cette tâche ne peut être effectuée par un seul et simple système informatique mais elle est plutôt subdivisée en plusieurs sous-problèmes relatifs au type d'information à extraire et à reconnaître. En général, le terme Traitement Automatique de la Parole, englobe plusieurs thèmes qui peuvent utiliser des techniques similaires et peuvent même être utilisé simultanément dans une même application comme: la reconnaissance automatique de la parole, le traitement et la reconnaissance des langues et des dialectes d'une langue, le codage et la compression de la parole, la synthèse de la parole, la reconnaissance et la vérification du locuteur, l'identification de la langue, la détermination de l'état émotionnel d'un locuteur, la compréhension de la parole, etc.

La reconnaissance automatique de la parole (RAP) (*Automatic Speech Recognition*) est particulièrement le processus par lequel un ordinateur transforme ou transcrit un signal acoustique de parole en texte ou en action, ce qui facilitera la communication entre les humains et la machine. Ce domaine est étroitement lié à d'autres disciplines tel que : la linguistique, la phonologie, la phonétique, le traitement du langage naturel, le traitement du signal, l'intelligence artificielle, l'apprentissage automatique, l'apprentissage profond, la reconnaissance des formes, etc. Aussi, la RAP se caractérise par un développement avancé d'applications pratiques pluridisciplinaires allant de la dictée vocale à la téléphonie et en passant par plusieurs applications de dialogue homme-machine qui touche différents secteurs.

Les techniques de reconnaissance vocale peuvent être exploités et appliqués avec succès pour atténuer des problématiques relatives aux systèmes de télédétection et de géomatique, aux systèmes d'information géographique, etc. l'avantage de l'utilisation de la parole comme

modalité d'interaction, est qu'elle est intuitive, naturelle et facile pour l'utilisation. la combinaison d'un module de reconnaissance vocale et/ou de synthèse de parole a un système d'information géographique (SIG) rend l'utilisation de ce dernier plus souple et assistée pour les malvoyants et d'autres catégories d'utilisateurs a handicap physique. Des requêtes vocales introduites au SIG peuvent être transcrite textuellement traite puis retourner vers les utilisateurs sous formes d'audio.

Historiquement, les premiers systèmes de RAP permettaient de reconnaître des mots isolés. Une des manières utilisées est de procéder par comparaison du le signal observé par une réalisation de référence de chaque mot. Il faut choisir la réalisation la plus proche du signal correspond en se basant sur les propriétés spectrales des phonèmes ou des mots dans le temps. Par la suite la RAP se préoccupait de la parole continue. Cette tâche nécessitait l'analyse du message audio dans son ensemble. Les premières études concernant la parole continue traitaient de la parole lue avec des conditions contrôlées telles que : parole lue et stable, enregistrements contrôlés de quelques dizaine de mots prononcés de manière stable par un locuteur sélectionné, grammaire rigoureuse, pas de perturbation du signal, etc.

## **I. Modules d'un système de RAP**

En général, un système de RAP continue à grand vocabulaire est constitué grossièrement de plusieurs modules : des modèles acoustiques, des modèles de langage, un vocabulaire et un module de recherche spécifique. Ce système transcrit le signal acoustique en génère en sortie la suite de mots la plus probable. Cette suite de mots est issue du parcours d'un graphe de mots généré par un algorithme de recherche qui permet de trouver les N-meilleures séquences de mots en fonction de leurs scores acoustique et linguistique.

### *A. Modèles Acoustiques*

Actuellement, la communauté de la RAP est passée à l'exploitation de milliers d'heures de parole spontanée et/ou conversationnelle de locuteurs connus ou inconnus dans des conditions variées, enregistrée lors des émissions de radios et/ou de télévisions, des conversations, des réunions, etc. Dans ces cas, la parole est souvent bruitée ou avec du fond musical, le matériel d'acquisition peut être différent d'un locuteur à un autre, il peut y avoir plusieurs locuteurs qui parlent en même temps, etc.

Le signal de la parole présente différents types de variabilité. La variabilité intra-locuteur dû au mode d'élocution (accent régional, physiologie du locuteur, style de parole, vitesse de la parole, âge du locuteur et son état émotionnel, etc. La variabilité interlocuteurs dû aux différences entre locuteurs du même sexe ou de sexe différent. Tandis que, la variabilité dû au moyen d'acquisition du signal (type de microphone ou téléphone), de la qualité de la transmission du signal (courte ou longue distance) ou aux différences entre environnements acoustiques (présence de bruits, de musique, etc.). Ces problèmes relatifs à la variabilité de la parole caractérisent le domaine de la RAP continue spontanée et conversationnelle de difficile jusqu'à l'heure actuelle, malgré les niveaux de modélisation et d'implémentation élevés existant. Pour couvrir ces variabilités dans un système de RAP, il est nécessaire de traiter une grande quantité de données phonétiques pour entraîner des modèles acoustiques complets. Ces modèles peuvent être à base de modèles de Markov ou de réseaux de neurones, etc.

### *B. Modèles de Langage*

Aussi, beaucoup d'efforts ont été consacrés au développement des systèmes de RAP robustes au cours des dernières décennies en se focalisant sur la modélisation du langage qui est une tâche importante dans le domaine du traitement du langage naturel (Natural Language Processing). Ces modèles de langage prédominent les méthodes à base des grammaires qui échouent en cas tâches à grand vocabulaire. Il est rentable de créer des modèles de langage

statistiques ou encore des modèles de langage neuronaux à base de perceptrons multicouches, de réseaux de neurones récurrent, de réseaux de neurones profonds, etc.

En général, la qualité d'un système de RAP continue à grand vocabulaire (Large Vocabulary Continuous Speech Recognition - LVCSR) est relative à la qualité de ses modules : les modèles acoustiques, les modèles de langage, le vocabulaire, le module de recherche spécifique et surtout les données acoustiques et/ou textuelles utilisées pour l'apprentissage du système. De ce fait, la sélection des données d'apprentissage peut être un enjeu pour l'amélioration de la reconnaissance.

De nombreux travaux ont été effectués et différentes méthodes d'élagage, d'optimisation et d'adaptation sont proposées pour améliorer les différents modules des systèmes de RAP, visant à améliorer leurs qualités [1, 2, 3, 4, 5, 6] :

(1) Amélioration au niveau des modèles acoustiques, en appliquant des adaptations sur les caractéristiques audio ou sur les modèles acoustiques eux même, ou en sélectionnant les données audio les plus pertinents pour l'apprentissage de modèles.

(2) Amélioration au niveau des modèles de langage, en appliquant des adaptations, ou des sélections de données textuelles pertinentes, etc.

Dans le cadre de ce travail, c'est sur cette dernière approche que nous focalisant nos efforts en essayant d'explorer et optimiser les modèles de langage dédiés à la RAP, afin d'améliorer le système de RAP dédié à la transcription des émissions radiophoniques et télévisées en langue Française. .

## II. Stratégies de sélection de données, expérimentations et résultats

### A. Données utilisées et toolkit

Les bases de données utilisées lors de ces expérimentations sont extraites de données radiophoniques avec parole Française spontanée utilisé dans la campagne ETAPE [7]. Des transcriptions manuelle qui sont couteuse sont considéré comme des données claires et proche à la tâche de reconnaissance visée *Tr*.

Aussi, deux corpus généraux sont exploités durant ces expérimentations : Web data et Gigaword. Le Webdata est corpus libre collecté sur le web parmi des sites de journaux et TV, noté *Web*. Tandis que le Gigaword [8] deuxième édition noté *Gw* est grand et riche corpus Français distribué par l'organisation « Linguistic Data Consortium », (<https://catalog.ldc.upenn.edu/LDC2009T28>). Les Tables 1 et 2 présentent les statistiques des données utilisées *Tr*, *Web* et *Gw*.

TABLE 1 : DONNEES D'APPRENTISSAGE DE MODELES DE LANGAGE

Données d'Apprentissage	#Fichiers	#Phrases	#Mots
Transcription (Tr)	74	5 437 203	113 986 727
Webdata (Web)	293	16 590 162	334 057 000
Gigaword (Gw)	637	28 699 758	783 380 463

TABLE 2 : DONNEES DE VALIDATION ET TEST

Validation and test Data	#Files	#Sentences	#Words
Validation (DevLM)	1	20 091	276 770
Test (TestLM)	1	7 551	85 191

L'outil utilisé pour la modélisation du langage dans les différentes étapes est SRILM toolkit [9, 10] via la technique de lissage de Kneser-Ney [5]. La longueur des n-gram est de trois (3). Une interpolation linéaire est utilisé pour rassemblé les modèles de langage construits avec les données proches de la tâche de reconnaissance et des Modèles de langage appris sur des données généraux (in-domain and out-domain).

### B. Sélection des données Web data

Les données de transcription ( $Tr$ ) sont proche à la tâche reconnaissance de la parole spontanée donc ils sont utilisés comme in- domain pour la modélisation du langage. A ce niveau, différentes stratégies de sélection sont exploitées sur le corpus *Web*: sélection aléatoire (*random selection*) notée *random*, à base de Différence entropie croisée (noté  $dXent$ ) et enfin une technique à base de la moyenne de différence quadratique (*Mean square difference probability*) notée *MSDP*. A chaque fois, les modèles de langage entraînés sur  $Tr$  data et ceux entraînés sur les phrases sélectionnées depuis le *Web* data sont interpolés et comparés au modèle de langage complet de base.

Les techniques de sélection s'expliquent via les équations 6, 7. Le *Tiny Web* est le modèle de langage appris sur une portion de données sélection du *Web Data* et  $H$  est l'entropie croisée du Modèle de langage:

$$dXent(s) = H_{(LM-Tr)}(s) - H_{ML-TinyWeb}(s) \quad (6)$$

$$MSDP(s) = \frac{1}{2} (\log P_{(LM-Tr)}(s) - \log P_{ML-TinyWeb}(s))^2 \quad (7)$$

Les perplexités obtenues après les sélections appliquées sur les données du Web sont illustrées sur la figure 1




Fig. 1. Perplexités des Modèles de Langage en utilisant les données *Web* sélectionnées par les trois techniques Aléatoire,  $dXent$  et *MSDP*.

Des résultats intéressants sont obtenus avec approximativement 60% des données disponibles.

### C. Data Selection on Gigaword data

Des expérimentations similaires sont effectuées sur le corpus *Gigaword* comme out-domain data ( $Gw$ ), avec les mêmes techniques, par respect aux équations 8 et 9 :

$$dXent(s) = H_{(LM-Tr)}(s) - H_{ML-TinyGw}(s) \quad (8)$$

$$MSDP(s) = \frac{1}{2} (\log P_{(LM-Tr)}(s) - \log P_{(LM-TinyGw)}(s))^2 \quad (9)$$

Les perplexités obtenues après les sélections appliquées sur les données du  $Gw$  sont illustrées sur la figure 2. Selon les résultats obtenus et en comparant les figures 1 et 2, il est clair que les données du Web sont simples à traiter et proches de la tâche de reconnaissance. Tandis que les données du *Gigaword* ( $Gw$ ) sont plus difficiles à sélectionner.




Fig. 2. Perplexités des Modèles de Langage en utilisant les données  $Gw$  sélectionnées par les trois techniques Aléatoire,  $dXent$  et  $MSDP$ .

## Conclusion

Dans ce papier, les résultats obtenus montrent l'importance des modèles de langage comme étant composantes linguistiques du système de la RAP et la possibilité de leur amélioration via différentes techniques de sélection des données textuelles. Ces techniques peuvent être exploitées dans le futur pour des systèmes de Reconnaissance de Parole destinés à collaborer avec des Systèmes d'Information Géographiques.

Comme perspectives, l'entraînement d'un système de parole sur des données ou des entités nommées géographique (emplacement, villes, adresses, etc.) sélectionnées parmi des données hors-domaine peut être bénéfique pour un SIG. La combinaison d'un module de reconnaissance vocale orienté géomatique à un Système d'Information Géographique (SIG) contribue à une bonne assistance ciblée pour les malvoyants et d'autres catégories d'utilisateurs à handicap physique.

## REFERENCES

- [1] J. T. Goodman, Joshua T. A bit of progress in language modeling. *Computer Speech & Language*, 2001, vol. 15, no 4, p. 403-434.
- [2] H. Schwenk, A. Rousseau, and M. Attik : Large, pruned or continuous space language models on a gpu for statistical machine translation. In *Proceedings of the NAACL-HLT 2012 Workshop: Will We Ever Really Replace the N-gram Model? On the Future of Language Modeling for HLT*. Association for Computational Linguistics.2012. pp.11-19.
- [3] F. Mezzoud and A. Benyettou, “An empirical study of statistical language models: n-gram language models vs. neural network language models”, *Int. J. Innovative Computing and Applications*, Vol. 9, No. 3, (in press).
- [5] S. F. Chen, J. Goodman, “An Empirical Study of Smoothing Techniques for Language Modeling”, *Computer Speech and Language*, 1999, pp.359-394.
- [4] F. Mezzoudj, M. Loukam and A. Benyettou, “On an empirical study of smoothing techniques for a tiny language model”, in *Proceedings of IPAC 15, ACM*, 23–25 November, Batna, Algeria, 2015, pp.67–80.
- [5] R. C. Moore and W. Lewis: “Intelligent selection of language model training data”. In *Proceedings of the ACL 2010 Conference Short Papers*. Association for Computational Linguistics, 2010, pp. 220-224.
- [6] F. Mezzoudj, D. Langlois, D. Jouvét, and A. Benyettou. “Textual data selection for language modelling in the scope of automatic speech recognition”. In *Procedia Computer Science* (2018). 10-APR-2018. pp. 55-64. DOI information: 10.1016/j.procs.2018.03.008
- [7] G. Gravier, G. Adda, N. Paulson, M. Carré, A. Giraudel and O. Galibert. “The ETAPE corpus for the evaluation of speech-based TV content processing in the French language”. In *LREC-Eighth international conference on Language Resources and Evaluation*, 2012.
- [8] A. Mendona, G. David, and D. Denise, “French gigaword second edition,” Web Download: <https://catalog ldc.upenn.edu/LDC2011T10>, 2009.
- [9] A. Stolcke, “SRILM - an extensible language modeling toolkit”, *Proceedings of ICSLP*, vol. 2, Denver, USA, 2002, pp. 901-904.
- [10] A. Stolcke, J. Zheng, W. Wang and V. Abrash: “Srilm at sixteen:Update and outlook”. In *Proceedings of IEEE Automatic Speech Recognition and Understanding Workshop*. 5. 2011.

# Positioning System for Emergency Situation Based on RSSI Measurements for WSN

Mounir TAHAR ABBES

Computer science department, Faculty of exact sciences and Informatics,  
Hassiba Benbouali University of Chlef, Algeria.  
mtaharabbes@yahoo.fr

## Abstract

In this paper, we present a technique for indoor localization that uses the results of the trilateration method and RSSI signal strength to know what is expected in specific locations. Indoor positioning in systems confronts particular problems of precision. This study aims to implement a technical solution that can precisely and efficiently give the position of a target and facilitate the localization of mobile nodes deployed in a given zone.

The main objective of this work is to estimate the position of the node with precision. This work was conducted on the basis of the combination of two concepts: trilateration method and RSSI measurement in different positions. The study of a set of simulations indicates that the estimation of the node position; using RSSI level; does not differ from mathematical calculations used by trilateration method. Besides; the network performance is not affected significantly. This is the major concern of our work; mainly in emergency situations; as it gives the right position of individuals to the rescuers.

**Keywords :** WSN, Trilateration, RSSI, indoors localization, Emergency.

## Introduction

Over the past years, wireless technologies have released innovative opportunities in the field of telecommunications and computer networks. Due to progress in technology, the Wireless Sensor Networks (WSN) has emerged. Wireless Sensor Network will keep playing an essential role in humans' life. They have many roles; among which: monitoring a zone, taking regular measurements, and sending and delivering alarms to some nodes of the network, namely nodes' collectors. In addition to that; they can be deployed quickly in sensitive areas. Many applications of WSN are currently being used and developed in different domains; such as defense, security, and health.

The WSN localization system aims at detecting the location of a target by using a network of wireless sensors. Many localization applications have, recently, been used in different domains, such as sports, for tracking athletes; emergencies, for localizing survivors rapidly and accurately; and in surveillance, for monitoring spaces and tracking intruders. [1].

This research aims at improving the localization system for emergencies due to disaster scenarios, such as earthquakes, floods and fires. In these cases; terminals are meant to provide their exact position within an appropriate lapse of time to the rescuers. The idea is based on the adaptation of a localization technique in order to improve the quality of the localization data. *This solution is involved in one layer in OSI model, which is Mac layer.*

The rest of this paper is organized as follows. Section 1 introduces this research work. Section 2 describes the localization technique in WSN network. Section 3 presents the proposed solution. Section 4 presents the simulation parameters to be implemented in Glomosim. Section 5 discusses the results collected from the environment of simulation. Finally, Section 6 concludes the paper.



## I. Localization technique

A considerable progress has been done in different research areas of WSN, including the domain of localization systems; as localization via WSN is required in many domains, such as emergencies, vehicle navigation, mobile robotics, and user tracking in wireless networks.

Accurate localization algorithms require extensive memory and processor resources, especially when dealing with a large number of sensors or when using complex statistical methods to estimate direction (angles of arrival, AOA) and distance between sensors and relative locations between pairs (or groups) of sensors [2].

According to [2], the classification of the location systems, they can be classified through a tree, as illustrated in the figure 1 below.

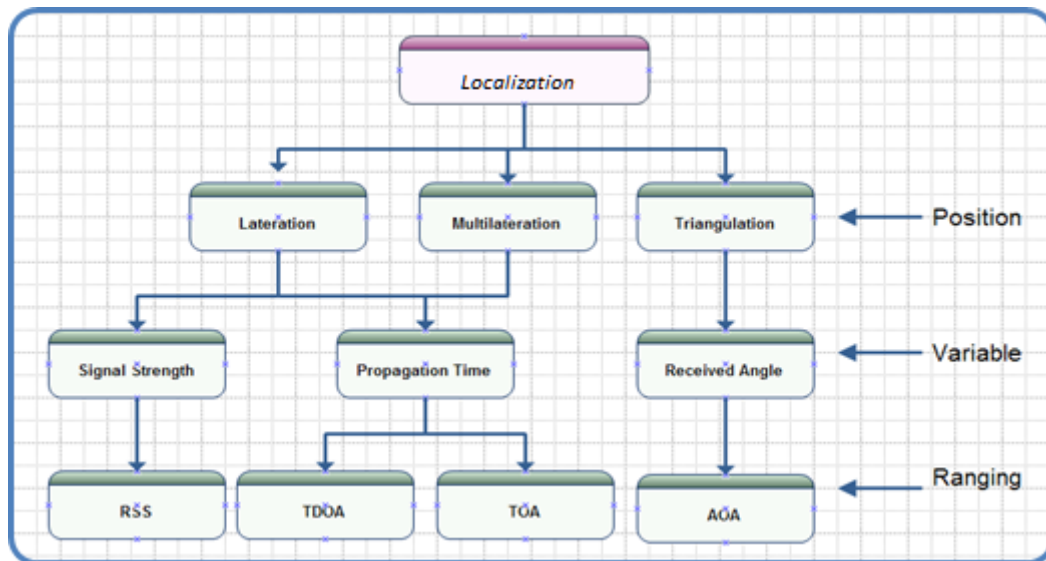


Fig. 1. Classification of location system. Figure 1. Classification of location system.

### A. Triangulation:

Triangulation is a mathematical method used to determine an unidentified location based on two angles and the distance between them. To apply this method in the wireless network, the mobile node needs to know the angles  $\theta_1$  and  $\theta_2$  and the distance between the two base stations [3].




Figure 2. Triangulation

$$\frac{a}{\sin \alpha} = \frac{b}{\sin \beta} = \frac{c}{\sin \theta} \quad (1)$$

$$\pi = \alpha + \beta + \theta. \quad (2)$$

$$a = \frac{d \times \sin \alpha}{\sin(\pi - \alpha - \beta)} \quad (3)$$

$$b = \frac{d \times \sin \alpha}{\sin(\pi - \alpha - \beta)} \quad (4)$$

$$d = \sqrt{(x1 - x)^2 + (y1 - y)^2} \quad (5)$$

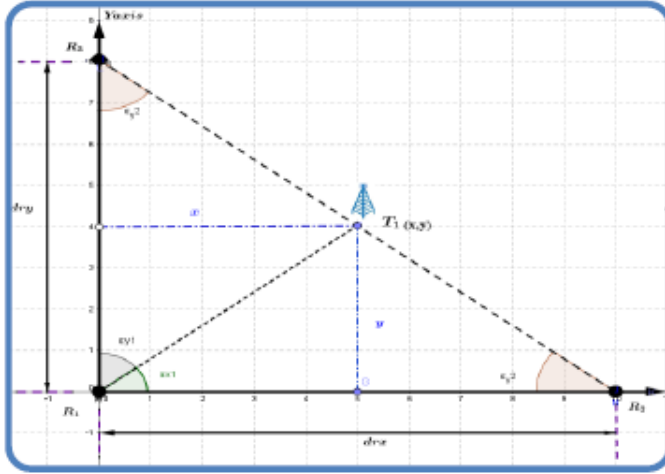


Figure 3. Trilateration.

$$\begin{cases} x = \frac{d_y \sin(\alpha_{y1}) \sin(\alpha_{y2})}{\sin(\alpha_{y1} + \alpha_{y2})} \\ y = \frac{d_x \sin(\alpha_{x1}) \sin(\alpha_{x2})}{\sin(\alpha_{x1} + \alpha_{x2})} \end{cases} \quad (6)$$

### B. Trilateration:

Trilateration is a well-known localization algorithm; it needs a number of linear equations that is equal to the number of nodes [4]. Thus, it is simple and efficient; with a lower computation overhead [5]. In the following section we illustrate the manner of calculating an unknown position with this method.

Based on the work of [3] [4] [5], let us develop the following process to calculate the position of the intersection of three circles. We have a circle with the center A (x1, y1) and the radius r1, where r1 is the distance between A and U. This circle will pass through U. The second circle with the center B (x2, y2) and the radius r2, where r2 is the distance between U and B.

Finally, a third circle with the center C (x3, y3) and the radius r3, where r3 is the distance between U and C.

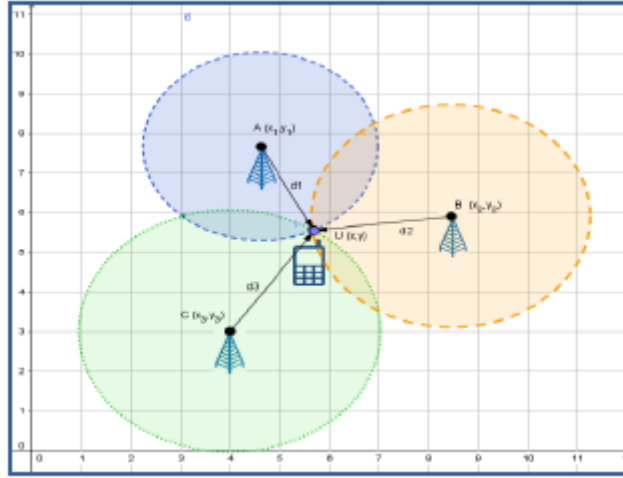


Figure 4. Trilateration Process.

The formula (7) and (8) demonstrate how to calculate the distance between target and the sensor node

$$d_i^2 = (x_i - x)^2 + (y_i - y)^2 \quad / \quad i = 1, 2, 3. \quad (7)$$

$$d_1^2 = (x_1 - x)^2 + (y_1 - y)^2 = x_1^2 - 2x_1x + x^2 + y_1^2 - 2y_1y + y^2. \quad (8)$$

$$d_2^2 = (x_2 - x)^2 + (y_2 - y)^2 = x_2^2 - 2x_2x + x^2 + y_2^2 - 2y_2y + y^2.$$

$$(9) \quad d_3^2 = (x_3 - x)^2 + (y_3 - y)^2 = x_3^2 - 2x_3x + x^2 + y_3^2 - 2y_3y + y^2. \quad (10)$$

After we do: (8) - (9) and (8)-(10):

$$d_1^2 - d_3^2 = (x_1 - x)^2 - (x_3 - x)^2 + (y_1 - y)^2 - (y_3 - y)^2$$

$$(4) \Rightarrow d_1^2 - d_3^2 = x_1^2 - 2x_1x + x^2 + y_1^2 - 2y_1y + y^2 - x_3^2 + 2x_3x - x^2 - y_3^2 + 2y_3y - y^2$$

$$\Rightarrow d_1^2 - d_3^2 = x_1^2 - 2x_1x + y_1^2 - 2y_1y - x_3^2 + 2x_3x - y_3^2 + 2y_3y$$

x =

$$\frac{2(y_3 - y_1) \cdot ((d_1^2 - d_3^2) - (x_1^2 - x_3^2) - (y_1^2 - y_3^2)) - 2(y_3 - y_1) \cdot ((d_2^2 - d_3^2) - (x_2^2 - x_3^2) - (y_2^2 - y_3^2))}{4(x_3 - x_1)(y_3 - y_1) - 4(x_3 - x_2)(y_3 - y_2)}$$

By transforming this equation to matrices we find:

$$y = \frac{((d_2^2 - d_3^2) - (x_2^2 - x_3^2) - (y_2^2 - y_3^2)) - 2(x_3 - x_2) \cdot x}{2(y_3 - y_2)}$$

$$2 \begin{bmatrix} x_3 - x_1 & y_3 - y_1 \\ x_3 - x_2 & y_3 - y_2 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} (d_1^2 - d_3^2) - (x_1^2 - x_3^2) - (y_1^2 - y_3^2) \\ (d_2^2 - d_3^2) - (x_2^2 - x_3^2) - (y_2^2 - y_3^2) \end{bmatrix}$$

### C. Measurement technique:

These algorithms can be roughly classified into two categories: range-based and range free. Three main techniques have been considered in WSN localization method. They are RSSI, TOA and TDOA [6], [7]. RSSI of a received packet has been used to locate the transmitting sensor node [8]. Time of flight of an acoustic beacon has been used to localize a sensor node using TOA and TDOA techniques [1].

Also another interesting technique is UWB (Ultra wideband) based communication and positioning systems have become popular as UWB signals possess the capability of measuring accurate position up to centimeter level due to its high multipath resolution [9].

Measurement-based algorithms use the received signal strength (RSS) [10]. Using this method, the distance between the pair of sensors could be obtained by converting the power loss due to propagation from a sensor to another on the basis of some propagation rules. Unfortunately, due to the probable presence of noise and interference, the estimated distance would be far from being accurate [11].

Actually, these algorithms require high power to guarantee communication between nodes which are small battery-powered units. Unlike range-based algorithms, range-free algorithms, which rely on the network connectivity to estimate the regular node positions, are more power-efficient, and do not require any additional hardware and, hence, are suitable for WSNs [12] [13].

In [13], the authors recommend a pattern-driven localization scheme (PDS) by applying different distance estimation algorithms for mobile nodes based on their exhibiting patterns. They identified three different patterns and employed a different localization method for each. These algorithms first adopt DV-Hop [15] or Amorphous to obtain the distance between nodes and then perform refinement.

Authors in [16] show that the proposed localization scheme, called DV-maxHop, can achieve good accuracy and efficiency. They formulate the multi-objective optimization functions to minimize localization errors as well as the number of trans-missions during the localization phase.

In [17] authors study the impact of nodes mobility in the routing protocol, they show that nodes move independently from each other, each model can be classified according to the randomness of its movement, either a movement is completely random with no memory of the past, or a movement is flexible where changes in speed, direction and position at every moment are based on the previous state.

Authors in [18] developed an adaptive signal strength based localization approach (ASSLA) is proposed for increasing location accuracy with node update method. In this solution, the stable paths are found with the determination of bit error rate, signal strength and packet delivery ratio.

For our study, we combine a mathematical method with a measurement approach to determine the position of nodes by taking into consideration the mobility of the mobile node. This issue is very important, especially in disaster situations.

## **II. Proposed solution**

In order to get the position node of the target we use the trilateration method combined with RSSI measurement presented in the previous section.

RSSI is a method for determining the location of a target device. According to a path loss model, the distance between two nodes can be estimated by measuring the energy of the received signal at one end. In order to calculate the distance from the RSS measurements, the channel characteristics must be classified.

Each reference node (three nodes in our case) is considered as a point in the center of the circle. The target node is in the intersection of the three circles. The distance between the center of the circle (reference node) and the target node is the radius of the circle. The intersection of these three perimeters is the location of the target node. The radius of circle will be presented as the signal power level. Each node is moving according to the waypoint model.

The model used in [17] [19], [20] indicates that path loss increases exponentially with distance. That mean path loss is a function of distance to the  $n$  power, the characteristics of

RSS, received signal strength will decrease with increased distance as the equation below shows:

$$\overline{PL}(d)[dB] = PL(d_0)[dB] + 10 \times n \times \log_{10} \left( \frac{d}{d_0} \right)$$

Where:

$\overline{PL}$  = Path Loss Model. PL

$d$  = is a reference distance.  $d$

$d_0$  = is the transmitter receiver separation distance.  $d_0$

$n$  = path loss exponent which indicates how fast path loss increases with distance.  $n$

Our main objective and contribution is to improve the location of the expected node, will focus on the variation of distances between nodes, this is function of the coordinates of their node (Circle center).

We can mostly say that every disaster scenario is composed of three periods in terms of mobility nodes behavior: 1-random mobility node, this model of mobility will cause many changes in neighbors, 2-high mobility, this level will cause many broken links, and 3-stability of network[18].

As we have discussed before, our proposed solution impact principally one layer in OSI model; in the next section we try to present these points.

The figure 5 presents the state diagram of the behavior of the radio model on reception of the message MSG\_RADIO\_From\_Channel\_End (This has been found after many traces with Glomosim). In both cases, it was clearly remarked that the transition to standby mode (SLEEPING) is carried out using the Glomo\_Energy\_Radio\_Go\_To\_Sleep function, and return to the IDLE mode via the Glomo\_Energy\_Radio\_Wake\_Up function. These diagrams have been plotted analysis and simulation carried out in the Glomosim simulator.

In order to understand the general operation of the radio layer in Glomosim, we illustrate for states (idle, in old, receive or transmit) in the following state diagram (Figure 5), that shows the transitions between these modes.

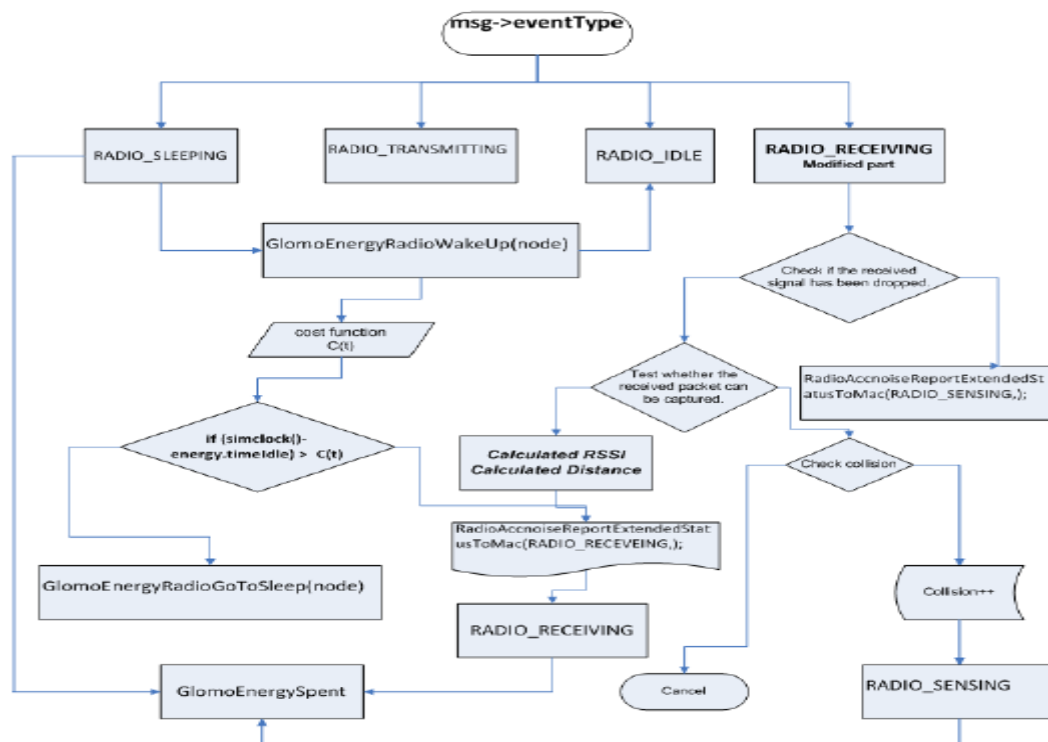


Figure 5. State Diagram of radio Layer in Glomosim.

### III. The simulation environment

The simulation consists of reproducing an abstract representation of the system studied using the Glomosim simulator [21] [22]. We implemented the proposed algorithm with both C++ and glomosim-2.03, it's a library scalable simulation environment for the wireless network system using the parallel discrete-event simulation capability provided by PARSEC [22]. The latter is a specific language based on C developed at UCLA (the University of California). Glomosim respects the OSI model and associates an object to each layer.

### IV. ANALYSIS AND RESULTS

Performance metrics that have been used to analyze the localization system in WSN are as follows:

- Received Signal Strength Indication RSSI :

$$RSS = -10 \times n \times \log_{10}(d) + P$$

D: Distance from the sensor in meter.

n: is the propagation constant or path-loss exponent. for example: 2.7 to 4.3 (Free space has n = 2)

p :power in reception mode (Dbm)

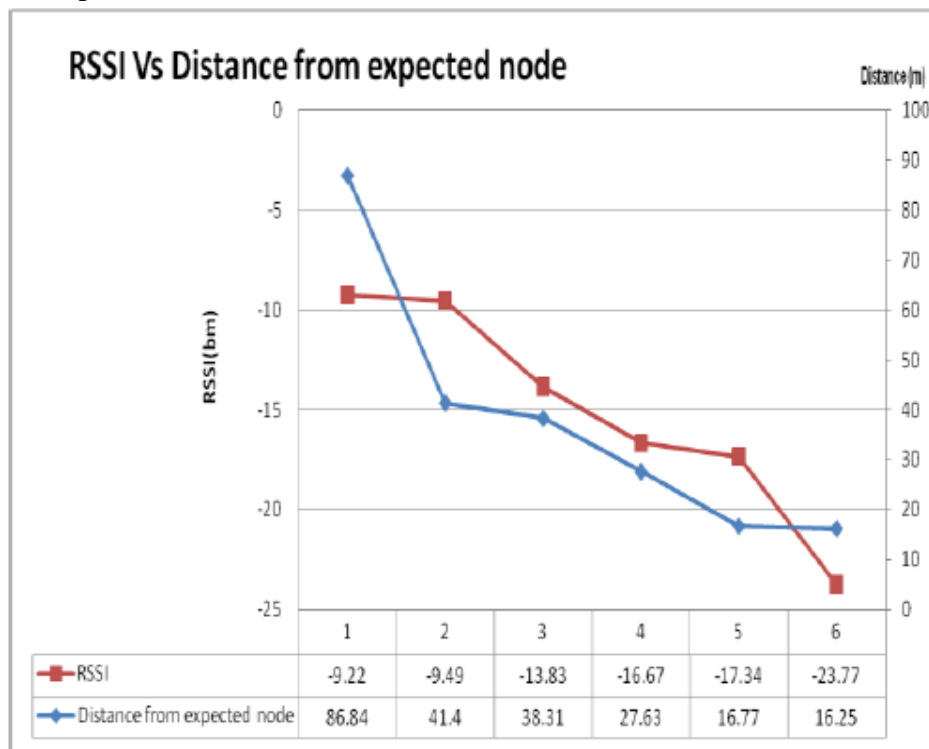


Figure 6. Level RSSI in relation with distance.

According to the results shown in figure 6, the nodes are deployed at random in a DIMENSIONS-GROUND (1000, 1000), where the nodes connect to their neighbors in the given range. We have observed in the figure 6, the relationship between the RSSI of the nodes and their respective distances. The results of the simulation show that when the distance between the two sensor nodes of the same range increases, the power of the received signal decreases. In large areas, note that the distance increases the RSSI decreases, and the opposite is just if the distance decreases the RSSI increases, and this because of the signal strength of the transmitters.

- Consumed Energy

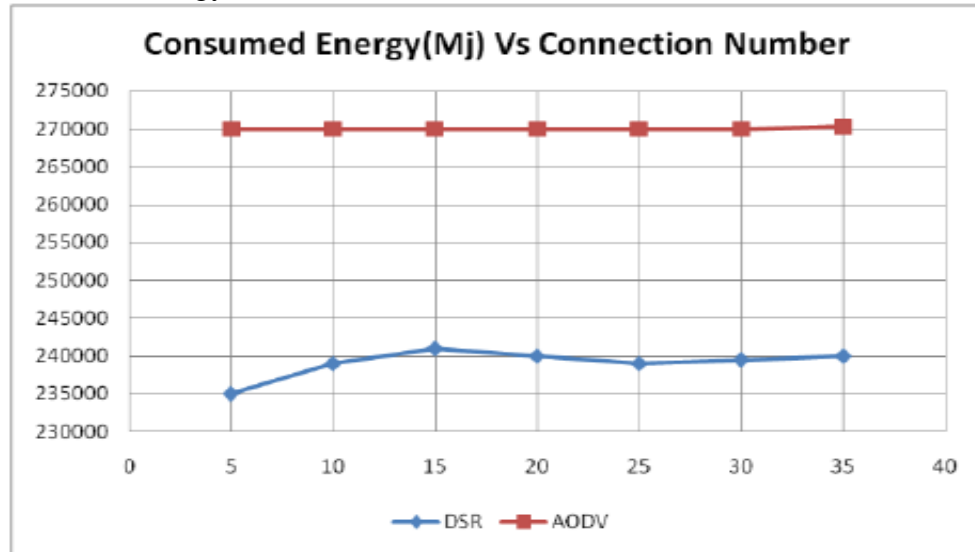


Figure.7: Consumed energy in the entire network.

In figure 8, the energy consumed in case of AODV protocol is stable (between 270,000 and 270,300 MJ), due to non-mobility (sleeping) of the nodes. But it remains almost stable (between 235000 and 245000 MJ) in the case of DSR protocol.

### Conclusion

In this study, we have used and combined a mathematical method (Trilateration) with a measurement technique to know the RSS level of each node in the wireless network, in order to calculate the exact position of the node in the network. On the basis of many radio models, we have integrate a module into the Network Simulator (Glomosim) on which we simulated the routing protocols AODV and DSR. After our simulations, we found out that the integration of the localization technique in a node does not affect the protocols. This solution can be applied in emergency situations to provide the rescuers with the right positions of the survivors.

For future research in this field, we suggest the consideration of mobility models and the study of their impact on the efficiency of the use the localization technique.

### REFERENCES

- [1] AchinthaMaddumabandara, Henry Leung, and Minxiang Liu, Experimental Evaluation of Indoor Localization Using Wireless Sensor Networks, IEEE SENSORS JOURNAL, VOL. 15, NO. 9, pp.5227-5237, SEPTEMBER, 2015.
- [2] K. Derr and M. Manic, "Wireless Sensor Network Configuration—Part I: Mesh Simplification for Centralized Algorithms," in IEEE Transactions on Industrial Informatics, vol. 9, no. 3, pp. 1717-1727, Aug. 2013.
- [3] H. J. Shao, X. P. Zhang and Z. Wang, "Efficient Closed-Form Algorithms for AOA Based Self-Localization of Sensor Nodes Using Auxiliary Variables," in IEEE Transactions on Signal Processing, vol. 62, no. 10, pp. 2580-2594, May, 2014.
- [4] Han, S., Lee, S., Lee, S. et al, Node distribution-based localization for large-scale wireless sensor networks, Wireless Networks, Volume 16, Issue 5, pp 1389–1406, July 2010.
- [5] H. Lee, S. Lee, Y. Kim and H. Chong, "Grouping multi-duolateration localization using partial space information for indoor wireless sensor networks," in IEEE Transactions on Consumer Electronics, vol. 55, no. 4, pp. 1950-1958, November 2009.

- [6] K. D. Frampton, —Acoustic self-localization in a distributed sensor network, *IEEE Sensors J.*, vol. 6, no. 1, pp. 166–172, Feb. 2006.
- [7] T. Damarla, L. M. Kaplan, and G. T. Whipps, —Sniper localization using acoustic asynchronous sensors, *IEEE Sensors J.*, vol. 10, no. 9, pp. 1469–1478, Sep. 2010.
- [8] P. K. Sahu, E. H.-K. Wu, and J. Sahoo, —DuRT: Dual RSSI trend based localization for wireless sensor networks, *IEEE Sensors J.*, vol. 13, no. 8, pp. 3115–3123, Aug. 2013.
- [9] Fazeelat Mazhar, Muhammad Gufran Khan, Benny Sallberg, Precise Indoor Positioning Using UWB: A Review of Methods, Algorithms and Implementations, *Wireless Pers Commun*, DOI 10.1007/s11277-017-4734-x, August 2017.
- [10] J. Rezazadeh, M. Moradi, A. S. Ismail, and E. Dutkiewicz, —Superior path planning mechanism for mobile Beacon-assisted localization in wireless sensor networks, *IEEE Sens. J.*, vol. 14, no. 9, pp. 3052–3064, May 2014.
- [11] Ahmad El Assaf, Student Member, IEEE, Slim Zaidi, Member, IEEE, Sofiene Affes, Senior Member, IEEE, and Nahi Kandil, —Low-Cost Localization for Multihop Heterogeneous Wireless Sensor Networks », *IEEE TRANSACTIONS ON WIRELESS COMMUNICATIONS*, VOL. 15, NO. 1, JANUARY 2016.
- [12] Ahmad El Assaf, Student Member, IEEE, Slim Zaidi, Member, IEEE, Sofiene Affes, Senior Member, IEEE, and Nahi Kandil, —Robust ANNs-Based WSN Localization in the Presence of Anisotropic Signal Attenuation », *IEEE WIRELESS COMMUNICATIONS LETTERS*, VOL. 5, NO. 5, OCTOBER 2016.
- [13] A. Boukerche, H. A. B. F. Oliveira, E. F. Nakamura, and A. A. F. Loureiro, —Localization systems for wireless sensor networks, *IEEE Wireless Commun.*, vol. 14, no. 6, pp. 6–12, Dec. 2007.
- [14] Q. Xiao, B. Xiao, J. Cao, and J. Wang, “Multihop range-free localization in anisotropic wireless sensor networks: A pattern-driven scheme,” *IEEE Trans. Mobile Comput.*, vol. 9, no. 11, pp. 1592–1607, Nov. 2010.
- [15] D. Niculescu and B. Nath, “DV based positioning in ad hoc networks,” *Telecommun. Syst.*, vol. 22, no. 1–4, pp. 267–280, 2003.
- [16] Farrukh Shahzad, Tarek R. Sheltami, and Elhadi M. Shakshuki, Multi-Objective Optimization for a Reliable Localization Scheme in Wireless Sensor Networks , *JOURNAL OF COMMUNICATIONS AND NETWORKS*, VOL. 18, NO. 5, pp 796-805, OCTOBER 2016.
- [17] TAHAR ABBES Mounir, Senouci Mohamed, Kechar Bouabdellah, "Impact of Model Mobility in Ad Hoc Routing Protocols", *IJCNIS*, vol.4, no.10, pp.47- 54, 2012.
- [18] Shi et al, *EURASIP Journal on Wireless communications and Networking* , 2017:79 DOI 10.1186/s13638-017-0859-6, 2017.0
- [19] D. C. Cox, R. R. Murray, and A. W. Norris, —800 MHz attenuation measured in and around suburban houses, *AT&T Bell Lab. Tech. J.*, vol. 63, pp. 921-954, July/Aug. 1984.
- [20] A. A. M. Saleh and R. A. Valenzuela, —A statistical model for indoor multipath propagation, *IEEE J. Select. Areas Commun.*, vol. SAC-5, pp. 128-137, Feb. 1987.
- [21] Scott Y. Seidel, Student Member, IEEE, and Theodore S. Rappaport, Senior Member, IEEE, —914 MHz Path Loss Prediction Models for Indoor Wireless Communications in Multifloored Buildings, *IEEE TRANSACTIONS ON ANTENNAS AND PROPAGATION*, VOL. 40, NO. 2, pp. 207-217, FEBRUARY 1992.
- [22] <http://pcl.cs.ucla.edu/projects/glomosim>.
- [23] B. Liang and Z. Haas, —Predictive Distance-based Mobility Management for PCS Networks, *Proceedings of the IEEE INFOCOM 1999*, Vol. 3, New York, NY, USA, pp. 1377-1384, March 1999



# A smart home IoT system based on machine learning

**Rachid BECHAR, Imadeddine BENZAAMIA, Lounissa NAAS LARABA**

Computer science department, Faculty of exact sciences and Informatics,  
Hassiba Benbouali University of Chlef, Algeria.  
r.bechar@univ-chlef.dz

## Abstract

Internet of things (IoT) solutions have become among systems that generate lot of data. Indeed, an IoT system has many devices which are source of different data sets and continuously collected to a local system or to the cloud in order to be processed. At this level, many technics and algorithms can be used depending on data volume and application domain where machine learning (ML) has proved its efficiency. In this paper, we propose a system architecture based on ML adapted to IoT characteristics. We use a decision tree model deployed at the cloud level. Application of this model for a smart home system allowed us to show lot of advantages and improve system performance and user satisfaction at the same time.

## Introduction

Information and communication technologies have known an important evolution in term of hardware and software. As a hardware part, programmable devices as Arduino for example have become cheaper, easy to program, using lot of sensors and doted by different communication interfaces like Wifi, Bluetooth or Zeegbee. So, they can be connected to a private network or internet. It is the IoT infrastructure on which we can run what we need as software part from the simple algorithm or protocol on a device arriving to complex module on the Cloud. At the current time, there is not a standard architecture for IoT systems depending on application and its level. This can be a stack with three layers until six layers like it is shown on the following figure.

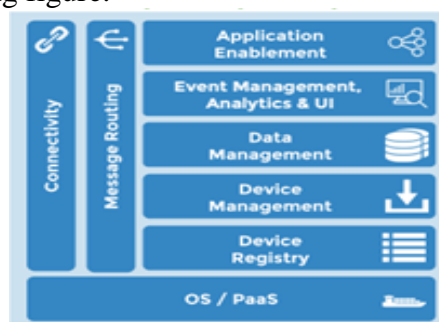


Fig. 1. IoT architecture stack.

In a simple way, three layers are needed for data perception, connection to a network and some application for data processing. In the case of a complete IoT solution, the system is connected to the cloud and have need to manage devices, services, data and events in plus of connectivity and routing, it can have until six layers. In term of data processing whether local or on the cloud, many technics are used like data mining and ML. In this context, recent publications on IoT have treated and proposed solutions based on IoT systems and ML algorithms. In this context, we will give here a quick overview on a proposed solution for smart home using ML at the cloud level.

## I. Related works

The application of ML technics in the field of IoT is an adequate solution for processing big data produced by multiple objects. Here is some recent research works that propose IoT solution where collected data are processed and decisions are made thanks to ML modules and in different domains.

A state of the art and taxonomy of ML algorithms applied to IoT and smart transportation systems are found in [1] and [2] respectively. In [3], Rashid Ashraf et al. study issues of interoperability between communication standards for IoT components by proposing a solution as a ML module based on regression that allows the classification of IoT nodes to form clusters ensuring interoperability when used standards are different. Authors of [4] try to explore calculation capabilities of a Raspberry Pi module to integrate ML like Random Forests and SVM algorithms at the Edge or local level of an IoT network to make it capable of performing learning and inference tasks. Similarly, in [5] neural networks are implemented on FPGA devices. The author of [6] also proposes an IoT solution for object recognition with neural networks based on the Google Cloud API. The k-nearest neighbors algorithm is used in [7] for noise classification in a smart city. The IoT Device Management concept is introduced in [8] where prediction and detection of IoT sensors failure is ensured by learning on collected data using Carriots platform. Finally and since IoT systems are also vulnerable to attacks, authors of [9] study possible solutions and at which level they can be applied. They talk also about attacks on the learning process itself and attacks based on the machine learning too.

## II. Summary on our proposed solution

The majority of smart home systems are private to their constructors. So, many problems can be encountered for this type of solution. We propose here a smart home IoT solution based on ML but in the cloud level. This system allows managing automatically the home air conditioning and lighting in order to economize electrical energy consumption. The diagram and picture in the following figure give a general view of the proposed solution.

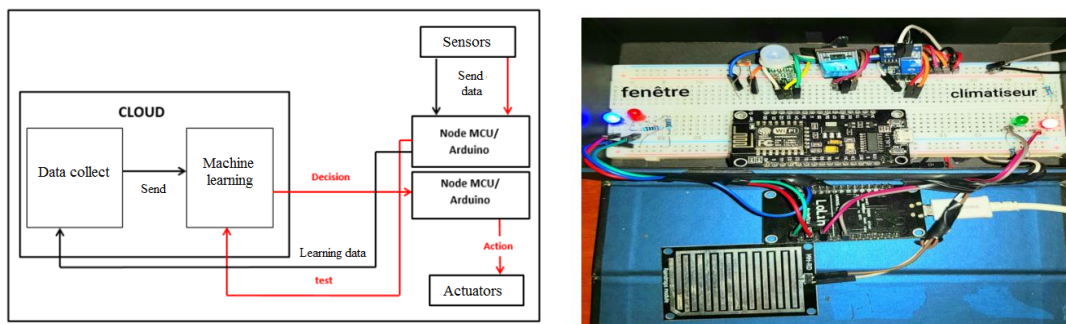


Fig. 2. General view of the proposed solution.

A set of components or things are used for collecting data that will be transferred to the cloud for storage and learning. For managing air conditioning and lighting in a smart home, some sensors are needed like temperature, pressure, light, raining and person presence. Finally, the decision model generated by learning provides decision according to the current conditions of the system. The ML module is based on a decision tree algorithm (ID3algorithm).

This solution presents some advantages like:

- Actuators that are devices installed to do actions react in a dynamic way that depends to new conditions of the system environment.
- IoT systems generate lot of data, their storage and processing on cloud is better than local solution.
- Decision models obtained as learning experience can be shared with other users.

- The cost of smart home solution based on cloud is better than solution based on local processing such as Raspery Pi.

Other performances have been evaluated in this study like running time, data size and decision efficiency using cross validation technique.

## Conclusion

In the design proposed, we have adapted the machine learning concept to automate our system and make all connected objects intelligent in order to better manage and optimize energy consumption in a smart home, we have implemented as a learning algorithm the ID3 algorithm which is based on a decision tree, then we have integrated it on cloud. As preliminary results, we can say that application of this model for a smart home system allowed improving system performance and user satisfaction at the same time. System becomes dynamic and intelligent making the home consumes less energy. Finally, using a ML module deployed on the cloud allows newly installed systems to benefit from the experience of existing smart homes by sharing data after learning and their adaptation automatically according to the occupants' habits and preferences.

## REFERENCES

- [1] M. S. Mahdavinejad, M. Rezvan, M. Barekatin, P. Adibi, P. Barnaghi and A. P. Sheth, Machine Learning for Internet of Things Data Analysis : A Survey, Digital Communications and Networks, 4(3), August 2018, pp 161-175.
- [2] F Zantalis, G Koulouras, S Karabetsos, D Kandris, A review of machine learning and IoT in smart transportation, Future Internet 2019, 11(94), doi:10.3390/fi11040094.
- [3] R .A. Malik, A. .I Kawoosa and O.S. Zargar. Machine learning in the internet of things – standardizing iot for better learning , International journal of advance research in science and engineering ,7(4), march 2018, pp 1676-1683.
- [4] M.T.Yazici, S.Basurra and M.M. Gaber, Edge Machine Learning : Enabling Smart Internet of Things Applications, School of Computing and Digital Technology, Birmingham City University 2018.
- [5] X. Zhang, A. Ramachandran and C. Zhuge, Machine Learning on FPGAs to Face the IoT Revolution , IEEE/ACM International Conference on Computer-Aided Design (ICCAD), Irvine, CA, USA, 13-16 Nov. 2017.
- [6] A. Saichandu ,T. Chandu ,P. Nagasatish ,P. V. Kumar and M. A.Shareef, Cloud vision for robots and blind persons, University of Knowledge Technologies Nuzvid, India, August 2017.
- [7] Y. Alsouda, S. Pillana,A. kurti, A Machine Learning Driven IoT Solution for Noise Classification in Smart Cities, arXiv:1809.00238 [cs.SD], 2014.
- [8] H. Adikari , Detection of faulty sensors in IoT using Machine Learning Algorithms ,Faculty of Computing, Sri Lanka Institute of Information Technology, 2017.
- [9] J. Mao, Q. Lin and J. Bian, Application of learning algorithms in smart home IoT system security, Mathematical Foundations of Computing, 2018, 1 (1), pp 63-76. doi: 10.3934/mfc.2018004.

# Traitement d'Images et les Systèmes d'Information Géographique

Nassima BOUSAHBA<sup>1,2</sup>, Réda ADJOUJ<sup>2</sup>

<sup>1</sup>Faculty of Exact Sciences and Informatics, Hassiba Benbouali University of Chlef, Chlef, Algeria

<sup>2</sup>EEDIS Laboratory, Djillali Liabes University of Sidi Bel Abbes, Sidi Bel Abbes, Algeria  
n.bousahba@univ-chlef.dz, adjoudj@univ-sba.dz,

## Résumé

Une étude méthodologique sur la signification de l'image et ses applications dans le domaine de la vision par ordinateur est effectuée. Dans une opération de traitement d'image, une image est fournie en entrée et son résultat est une image de haute résolution améliorée selon les techniques utilisées. Le traitement d'image est généralement appelé traitement d'image numérique, mais il est également possible d'effectuer un traitement d'image optique et analogique. Notre étude fournit une solide introduction au traitement de l'image ainsi qu'aux systèmes d'information géographique, aux principes fondamentaux de la vision par ordinateur et à ses applications.

*Mots clés : Traitement d'images, vision par ordinateur, système d'information géographique.*

## Introduction

Dans le traitement numérique des images, des algorithmes informatiques sont utilisés pour effectuer le traitement des images. Le traitement numérique des images présente plusieurs avantages par rapport au traitement analogique des images. Il fournit un grand nombre d'algorithmes à utiliser avec les données d'entrée. Dans le traitement numérique des images, nous pouvons éviter certains problèmes de traitement tels que la création de bruit, et la distorsion du signal à un moment donné du traitement du signal. Dans les années 2000, des ordinateurs rapides sont devenus disponibles pour le traitement du signal et le traitement numérique des images est devenu la forme la plus populaire de traitement des images. C'est pourquoi le traitement des signaux d'image est devenu une méthode polyvalente, et aussi la moins chère.

Le traitement d'image par des techniques analogiques peut être utilisé pour les copies papier comme les documents imprimés et les photographies. Les analystes d'images utilisent une série de principes fondamentaux d'interprétation tout en utilisant ces techniques visuelles. Le traitement des images n'est pas seulement limité à la zone qui doit être étudiée, mais aussi aux connaissances de l'analyste. L'association est un autre outil important dans le traitement de l'image par les techniques visuelles. Ainsi, les analystes appliquent un mélange de connaissances personnelles et de données collatérales au traitement d'images.

Le traitement de l'image est très largement lié à la vision par ordinateur et à l'infographie. Les objectifs du traitement de l'image peuvent être divisés en cinq catégories :

1. Hallucination (surveiller les objets qui ne sont pas visibles.)
2. Restauration et accentuation de l'image (pour créer une meilleure image.)
3. Récupération d'images (recherche de l'image qui vous intéresse).
4. Mesure de motif (mesure d'une gamme d'objets dans une image.)
5. Reconnaissance d'image (différencier les objets dans une image) [1]

## I. Représentation d'images

Une image est la projection sur un plan d'une scène 3D, Elle peut être définie comme une fonction à 2 variable  $f(x,y)$ ,  $(x,y)$  est la position d'un point dans l'espace sur le plan de projection,  $f(x,y)$  est l'intensité (brillance) au point de coordination  $(x,y)$ . Une image est un plan analogue dans lequel les intensités sont réelles.

L'image numérique est l'image dont la surface est divisée en éléments de tailles fixes appelés cellules ou pixels, ayant chacun comme caractéristique un niveau de gris ou de couleurs prélevé à l'emplacement correspondant dans l'image réelle, ou calculé à partir d'une description interne de la scène à représenter.

L'image peut être représentée sous deux formes : Représentation matricielle et représentation vectorielle.

### A. Représentation matricielle

Elle est composée d'une matrice (tableau) de points à plusieurs dimensions appelés « pixels », chaque dimension représentant une dimension spatiale (hauteur, largeur, profondeur), temporelle (durée) ou autre (par exemple, un niveau de résolution).

### B. Représentation vectorielle

Le principe est de représenter les données de l'image par des formules géométriques qui vont pouvoir être décrites d'un point de vue mathématique. Cela signifie qu'au lieu de mémoriser une mosaïque de points élémentaires, on stocke la succession d'opérations conduisant au tracé.

La principale différence entre ces deux formats est qu'une image vectorielle peut être agrandie sans perdre sa qualité alors qu'une image matricielle perd en netteté à l'agrandissement.




Fig. 1. Image analogique.

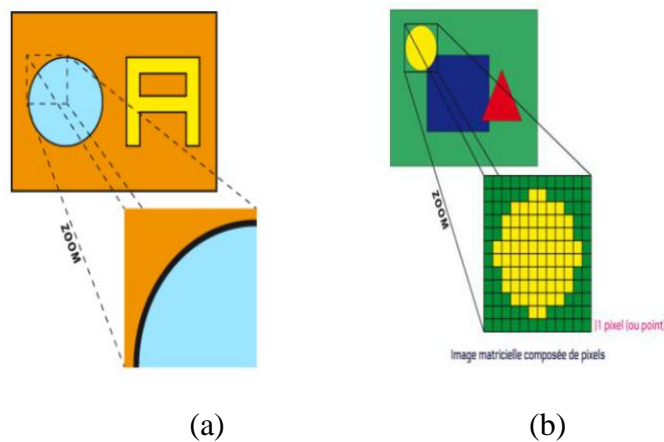


Fig. 2. (a). Représentation vectorielle, (b). Représentation matricielle [2]

## II. Traitement d'images

Le traitement d'image consiste à appliquer des transformations mathématiques sur des images dans le but d'améliorer leurs qualités ou d'en extraire une information, il existe 3 types de traitements :

### A. Amélioration de l'image

L'amélioration de l'image modifie l'impact visuel que l'image a sur l'interprétation d'une manière qui améliore le contenu de l'information. Il affine les caractéristiques des images telles que les contours, les bordures ou le contraste afin de rendre un affichage graphique plus utile pour l'affichage et l'analyse. Les techniques d'amélioration de l'image sont appliquées lorsque la qualité des images est importante pour l'interprétation individuelle. De nombreux algorithmes d'amélioration du contraste ont été développés et appliqués à des problèmes de traitement d'images tels que l'amélioration du contraste, Réalisation de mosaïques numériques [3].

### B. Compression d'images

La compression d'images est une application de la compression de données qui permet de diminuer la non-pertinence et l'inutilité des données d'images afin de pouvoir stocker des données sous une forme compacte [4]. L'objectif de la compression des images est de réduire la redondance de l'image et de stocker les données sous une forme efficace. La compression des images peut être avec ou sans perte. La compression sans perte est préférable pour des raisons d'archivage et fréquemment pour le traitement d'images médicales, de dessins techniques, etc.

### C. Segmentation d'images

Le processus de partitionnement d'une image en plusieurs régions ou objets, de manière à modifier la représentation d'une image en quelque chose de plus facile à analyser afin d'obtenir plus d'informations dans la région d'intérêt d'une image qui aide à l'annotation de la scène de l'objet est appelée segmentation de l'image. La segmentation de l'image est nécessaire afin d'identifier soigneusement le contenu de l'image.

Bien que les différentes techniques de segmentation existent, Toutes les méthodes ne conviennent pas de la même façon à un type d'image particulier. Ainsi, l'algorithme approprié pour une classe d'images peut ne pas convenir à une autre classe d'images. Par conséquent, il n'y a pas d'unanimité méthode de segmentation de l'image pour toutes catégories d'images et, par conséquent, cela reste un défi dans le domaine du traitement de l'image et de la vision par ordinateur [5].

Il existe d'autres traitements de bas niveaux tels que l'Analyse fréquentielle, l'échantillonnage et la quantification [6].

Quant aux traitements de moyen et de haut niveau il existe :

- A. **Représentation et description d'images** : C'est la transformation de l'image en un ensemble de "concepts" utilisables par l'ordinateur pour des algorithmes plus évolués [6].
- B. **Détection des caractéristiques** : Généralement, les points caractéristiques sont définis à partir des contours. Ils recouvrent les extrémités des lignes et les points de forte courbure. Ces points sont utilisés pour la fermeture des contours et la création de contours virtuels. Ils sont souvent des points de focalisation dans l'interprétation des images [6].
- C. **Indexation d'images** : tri d'images selon un ensemble de descripteurs, fouille dans les bases d'images.
- D. **La Reconnaissance** : association d'une étiquette à un objet à partir de ses descripteurs tels que : Reconnaissance biométriques.

La Figure 3 décrit les trois traitements sur une image satellitaire de prévision météorologique.

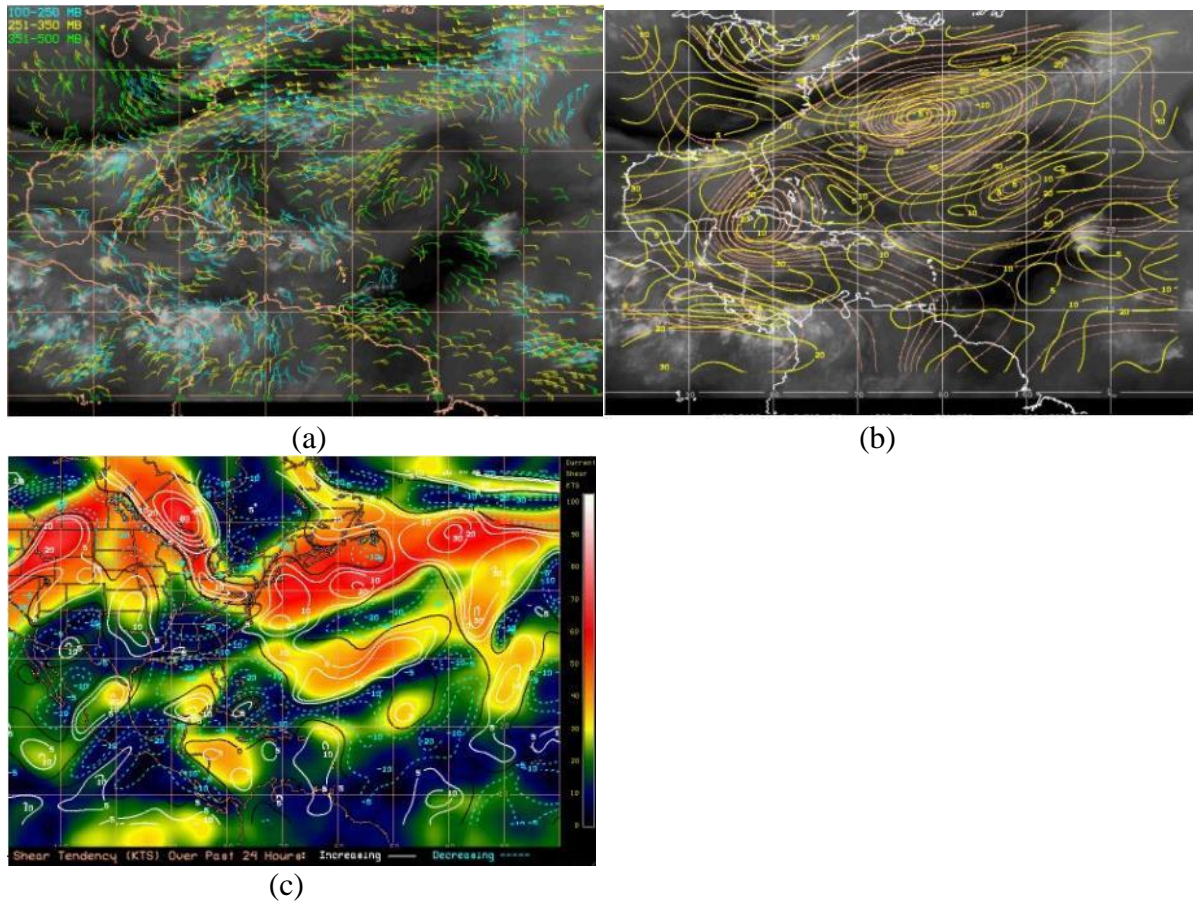


Fig. 3. (a) Traitement bas niveau : extraction de vecteurs de mouvement.  
 (b) Traitement moyen niveau : vecteurs de mouvement  $\Rightarrow$  carte des pressions.  
 (c) Traitement haut niveau : carte des pressions  $\Rightarrow$  prévision météorologiques.

### III. Rastérisation/vectorisation

A. *La rastérisation* : (Passage du vecteur au raster) correspond à la conversion d'une image vectorielle (MNT, MNE, MNH) en une matrice de pixels (un maillage). Chaque pixel détermine une valeur, correspondante au thème étudié, et selon une certaine résolution. [7].

B. *La vectorisation* : (Passage du raster au vecteur) correspond à la conversion d'une matrice de pixels en une image constituée de vecteurs avec des éléments géographiques individualisés [7].

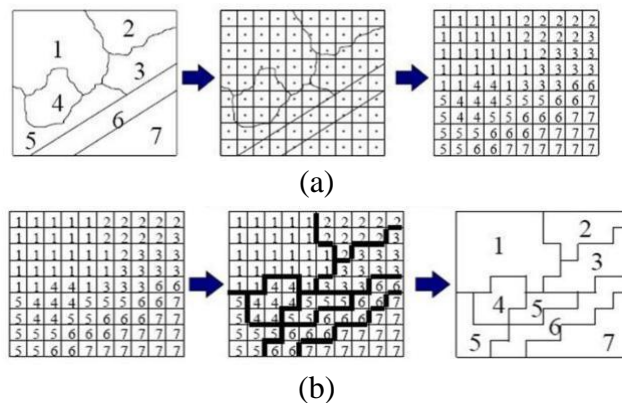


Fig. 4. (a) du vecteur vers le raster. (b) du raster vers le vecteur [7]

## Conclusion

Aujourd'hui, il n'y a pratiquement aucun domaine technique qui ne soit pas touché par le traitement numérique de l'image. De nombreux analyseurs d'images orientés application sont disponibles et fonctionnent de manière satisfaisante en environnement réel. Parmi les méthodes les plus simples pour comprendre l'application du traitement d'images on site les systèmes d'information géographiques « SIG » qui regroupe : la détection météorologique, cartographie et l'astronomie.

Les traitements d'images dans les SIG peuvent être principalement regroupés en trois catégories : Rastérisation et restauration d'images, rehaussement et extraction d'information. La rastérisation d'images est le prétraitement des données satellitaires pour les connexions géométriques et radiométriques. Le rehaussement est appliqué aux données d'image afin d'afficher efficacement les données pour une interprétation visuelle ultérieure.

L'extraction de l'information est basée sur une classification numérique et est utilisée pour générer des cartes thématiques numériques.

Il existe d'autres applications du traitement d'images, tels que :

- *Imagerie médicale* : Aide au diagnostic, tomographie, suivi automatique, reconstruction 3D.
- *Applications militaires* : Guidage de missile, reconnaissance terrestre.
- *Robotique* : Reconnaissance/assemblage de pièces, véhicules autonomes, contrôle de qualité.
- *Sécurité* : Identification de visages, reconnaissance d'empreintes digitales, tatouage d'image (watermarking), data hiding

## REFERENCES

- [1] R.C. Gonzalez and R.E. Woods, A textbook on "Digital Image Processing", (Fourth edition, Global edition). Pearson, New York, NY, 2018.
- [2] Cours en ligne graphisme – design. (s. d.). Consulté le 8 décembre 2019, à l'adresse <https://www.imedias.pro/cours-en-ligne/graphisme-design/>
- [3] S. K. Haldar. "Chapter 3 - Photogeology, Remote Sensing, and Geographic Information System". Mineral Exploration. (Second Edition), pp 47-68,2018.
- [4] B. Basavaprasad. "A study on the importance of image processing and its applications." International Journal of Research in Engineering and Technology 03, pp 155-160,2014.
- [5] J.Kuruvilla, S.Anjali and S.Dhanya. "A Study on image analysis of Myristica fragrans for Automatic Harvesting." 2016.
- [6] Ph.Bolon and al. "Analyse d'images : Filtrage et segmentation" .MASSON, Enseignement de la physique, 2-225-84923-4. fhal-00706168f.
- [7] Rastérisation/vectorisation. (2019, mars 4). Consulté le 8 décembre 2019, à l'adresse <https://www.univ-st-etienne.fr/wikimastersig/doku.php/fonctions:structuration:rastervecteu+r?do=>



# SIG et la recommandation contextuelle des POI

**Mhamed HADJ HENNI**

Département d'informatique,  
université Hassiba Ben Bouali  
- Chlef, Algérie.  
md.hadjhenni@univ-chlef.dz

**Nassim DENNOUNI**

Département d'informatique,  
université Hassiba Ben Bouali  
- Chlef, Algérie.  
n.dennouni@univ-chlef.dz

**Zohra SLAMA**

Laboratoire EEDIS, université  
de Djilali Liabes - Sidi Bel  
Abbes, Algérie.  
slama@univ-sba.dz

## Résumé

Les systèmes de recommandation (SR) sont en pleine expansion car les suggestions qu'ils fournissent peuvent aider les utilisateurs à faire des choix pertinents face à l'énorme masse d'informations disponible sur le Web. Dans cet article, nous allons nous intéresser à ces systèmes et plus précisément à leurs rôles dans l'aide à la décision pour les touristes mobiles qui utilisent des applications intégrant la géolocalisation comme les systèmes d'information géographique (SIG), le m-commerce, le m-tourisme, etc. Pour cette raison, nous abordons les techniques de recommandation sensibles au contexte appelée en anglais « Context Aware Recommendation System » (CARS) car elles utilisent des paramètres comme la localisation de l'utilisateur, les contraintes de météo, les horaires de la journée pour affiner leurs suggestions des lieux à visiter. En outre, ce type de recommandation utilise des algorithmes de filtrage collaboratif pour extraire des informations pertinentes à partir des SIG grâce aux différentes mesures de similarité user/user ou item/item. Ces informations peuvent être utilisées dans le cadre du Smart tourisme car elles sont visualisées sous forme de POI (Point Of Interest) sur une carte interactive accessible à partir de PC, Smartphone,...

**Mots clés :** Smart tourisme, Système d'Information Géographique, Point Of Interest, Système de Recommandation Contextuelle, mesures de similarité, filtrage collaboratif.

## Introduction

Actuellement, les utilisateurs de systèmes informatiques comme le e-commerce, le e-Learning, l'e-tourisme, ... sont confrontés à des quantités énormes d'informations sur le WEB. Pour cette raison, il serait intéressant d'assister ces utilisateurs à extraire que l'information pertinente pour eux afin de les aider à faire des bons choix dans un temps réduit. Pour atteindre cet objectif, la recommandation est devenu un processus que nous pouvons utiliser de façon naturelle dans notre vie quotidienne car elle permet d'éviter l'interrogation d'un ou plusieurs experts pour l'achat d'un produit, le choix d'une destination touristique, ... En effet, ces experts ne sont pas toujours disponibles et ne disposent pas de suffisamment d'informations sur nos habitudes et nos préférences pour nous orienter vers l'information pertinente pour nous. Face à cette situation, les algorithmes de recommandation présentent une bonne alternative car ils permettent de donner des résultats satisfaisants, dynamiques et évaluables.

En outre, la recommandation peut être vue comme un dialogue entre une personne experte d'un domaine donné et une autre personne qui souhaite acquérir des informations dans ce domaine. Par exemple, un bibliothécaire suggère des livres, en fonction soit des dernières nouveautés, soit en fonction des goûts clairement explicités d'un de ses clients pour aider les futurs lecteurs qui n'ont pas des connaissances suffisantes pour trier les ouvrages et évaluer leurs pertinences [1].

Dans la littérature, nous pouvons trouver plusieurs SR mais dans le cadre de cet article nous allons nous concentrer sur ceux qui peuvent extraire des informations pertinentes pour les

utilisateurs mobiles du tourisme électronique. Pour cette raison, nous abordons des questions comme : (1) quelles sont les techniques de recommandation de POI à utiliser dans le domaine de tourisme ? (2) Comment intégrer les feed-back des anciens touristes dans ce processus de recommandation ? Et (3) avec quelle précision peut-on évaluer la pertinence de ces recommandations de POI ?

Dans cet article, nous répondons à ces questions en commençons par l'introduction du concept de recommandation puis nous mettons l'accent sur l'apport des SIG pour la localisation des touristes mobiles. Ensuite, nous expliquons le fonctionnement des algorithmes de recommandation qui utilisent les mesures de similarités entre les utilisateurs et les items pour prédire les futurs choix des touristes. Finalement, nous abordons l'utilité des techniques de recommandations sensibles au contexte pour la suggestion des POIs aux nouveaux touristes en se basant sur les évaluations des anciens touristes.

## I. Les systèmes de recommandation

Selon Robin Burke, un SR permet de fournir des recommandations personnalisées afin de guider les utilisateurs vers des ressources intéressantes et utiles au sein d'un espace de données important [2]. En effet, un SR est une sous-classe du système de filtrage de l'information qui cherche à prédire la "note" ou la "préférence" qu'un utilisateur donnerait à un item [3]. Cela permet d'orienter rapidement les utilisateurs des SR vers des listes des items les plus pertinents afin de les fidéliser aux différents produits disponibles au niveau des sites marchands. Ces produits peuvent être des destinations touristiques, des livres (Amazon), des films comme le SR de Netflix [4], des personnes sur les réseaux sociaux (LinkedIn, Facebook,...), des articles scientifiques [5], des restaurants [6], des news [7], des applications (Google Store, Windows Store)...

Pour faire des suggestions, les SR utilisent plusieurs techniques qui peuvent être regroupées en trois catégories comme c'est indiqué dans la figure 1.

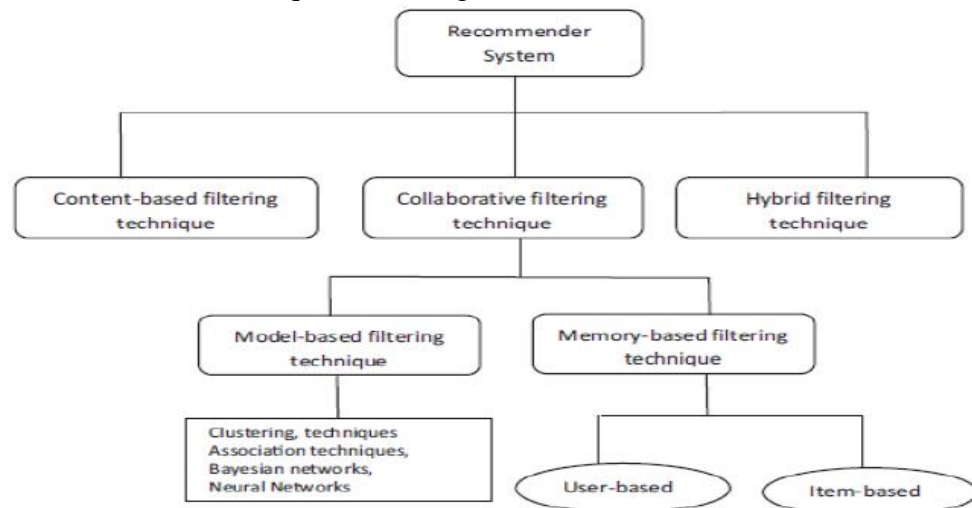


Fig. 1. Les approches de base de systèmes de recommandation [3].

### I.1 La recommandation basée sur le contenu (Content-based filtering)

Cette approche est basée sur le profil utilisateur car elle calcule les distances entre l'item actuel et les autres items. L'objectif est de produire auprès d'un utilisateur (visiteur d'un site, acheteur potentiel d'un produit, ...) une liste personnalisée de suggestions (produits, liens à cliquer, ...) en rapport avec ses préoccupations et ses attentes [8].




Fig. 2. Schéma explicatif de SR basé sur le contenu [9].

La figure 2 explique qu'un SR basé sur le contenu élabore un profil spécifique de chaque contenu, puis établit des matrices de corrélation sur ces données. Les différents éléments sont comparés aux éléments précédemment évalués par l'utilisateur et les articles les mieux assortis sont recommandés [9].

Selon [10], ce type de filtrage est basé essentiellement sur l'historique de l'utilisateur. Par exemple, si un utilisateur a acheté des films de sciences fiction dans le passé, le SR lui recommandera probablement une liste de films de sciences fictions récents qu'il n'a pas encore regardés. Cette liste contient les articles similaires à ceux que l'utilisateur a achetés, visités, parcourus, aimés et évalués positivement dans le passé.

Dans la littérature, nous pouvons trouver plusieurs approches de recommandations basées sur le contenu, mais elles ne garantissent pas des prédictions précises si le contenu ne contient pas suffisamment d'informations [11]. En effet, Il est difficile d'analyser un ensemble suffisant de caractéristiques pour représenter l'intégralité du contenu surtout pour les données multimédia, les flux audio, les flux vidéo et les images graphiques [12]. En outre, un même événement peut être référencé avec un titre différent. Par exemple, un article de presse peut avoir le même contenu avec des titres différents [13]. Enfin, l'utilisateur de ce type de SR risque de se lasser des recommandations fournies car elles deviennent de plus en plus proches de son profil (l'effet entonnoir).

### I.2 La recommandation basée sur le filtrage collaboratif (Collaborative filtering)

Le filtrage collaboratif permet de trouver des utilisateurs dans une communauté qui partagent les mêmes appréciations. Si deux utilisateurs ont des éléments identiques en commun, alors ils ont des goûts similaires. De ce fait, un utilisateur reçoit des recommandations pour les éléments qu'il n'a pas encore évalués, mais qui ont déjà été évalués positivement par les autres utilisateurs de son voisinage [8].




Fig. 3. Schéma explicatif de SR basé sur le Filtrage collaboratif (FC) [9].

Comme le montre la figure 3, un SR basé sur le filtrage collaboratif exploite les informations sur le comportement passé ou les opinions d'une communauté d'utilisateurs existante pour prédire quels éléments l'utilisateur actuel du système aimera ou sera probablement intéressé. Ce système prend comme entrée une matrice d'évaluations d'items utilisateurs donnés et produit une liste de n items recommandés en excluant les items que l'utilisateur actuel a déjà achetés [9].

D'après [14] [15] [16], le modèle de FC est classé en deux catégories : les techniques basées sur mémoire et les techniques basées sur modèle. Les techniques basées sur la mémoire sont également classées en méthodes basées sur l'utilisateur et en méthodes basées sur item. Le premier type de méthodes permet de générer des recommandations en tenant compte des préférences dans le voisinage de l'utilisateur (recommander de nouveaux items sur la base des notations données par des utilisateurs similaires) tandis que le deuxième type utilise le voisinage des items dans le calcul des similitudes entre les items (recommander des items similaires aux items que l'utilisateur a évalués dans le passé). Ces deux types de méthodes sont également appelées "k Nearest Neighborhood method (KNN)" car elles dépendent de leurs voisins dans le calcul des mesures de similarité entre deux utilisateurs ou deux items [17], [18], [19], [20]. Dans la littérature, nous pouvons trouver plusieurs mesures pour ces similarités comme la corrélation de Pearson, le cosinus, le coefficient de Jaccard et la distance de Manhattan [14] [16].

Contrairement aux méthodes basées sur la mémoire qui utilisent le voisinage des utilisateurs ou des items, les méthodes basées sur un modèle utilisent d'autres méthodes comme la factorisation matricielle [21], les systèmes flous [22], les classificateurs bayésiens [23] et les réseaux de neurones [24], etc.

### I.3. Recommandation Hybride (Hybrid filtering)

L'approche hybride a été introduite pour faire face à certains problèmes des SR conventionnels comme le problème du démarrage à froid et le problème de la stabilité (la plasticité).

Le premier problème (le démarrage à froid) survient lorsque des techniques basées sur l'apprentissage sont utilisées car ces techniques doivent collecter en temps réel les informations des utilisateurs (les évaluations, les préférences, le nombre de clics,...). Le deuxième problème (la plasticité) réside dans la difficulté de changer les profils des utilisateurs établis après une période donnée d'utilisation des SR.

Pour résoudre ces deux problèmes, les SR hybrides transforment les données d'entrée comme les modèles d'utilisateurs et les informations contextuelles, les données sur les communautés et les produits, ... en une liste classée d'éléments en sortie comme cela est indiqué dans la figure 4.

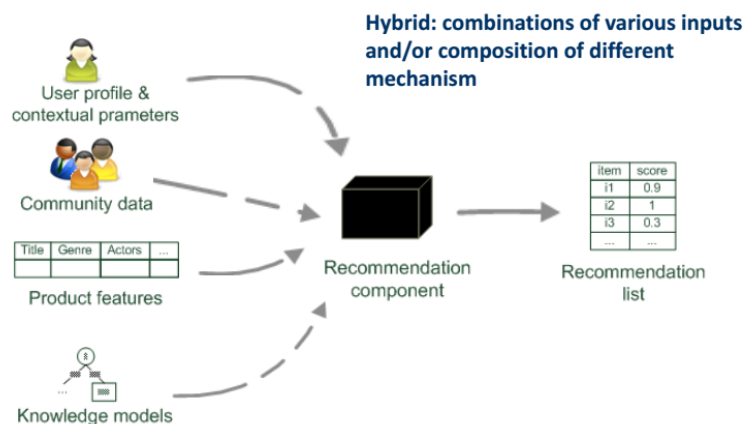


Fig. 4. Système de recommandation hybride comme une boîte noire [9].

Burke [23] a introduit une nouvelle taxonomie pour les SR hybrides en les classant en sept catégories : pondéré (weighted), commutation (switching), mixte (mixed), combinaison de caractéristiques (feature combination), augmentation de caractéristiques (feature augmentation), cascade (cascade) et méta-niveau (meta-level) [23]. Cette taxonomie distingue sept stratégies d'hybridation différentes. Cependant, d'après [9] ces sept variantes peuvent être regroupées en trois modèles de base : les modèles hybrides monolithiques, parallélisés et en pipeline [9].

Le modèle monolithique intègre des aspects de plusieurs stratégies de recommandation dans une seule implémentation d'hybridation alors que les deux modèles d'hybridation restants nécessitent la combinaison d'au moins deux mises en œuvre de recommandation distinctes. Le premier modèle appelé « modèle d'hybridation parallélisé » combine les apports des SR qui fonctionnent de façon indépendante et parallèle pour produire une liste finale de recommandations. Le deuxième modèle appelé « modèle d'hybridation en pipeline » utilisent les résultats obtenus à partir d'un SR comme une entrée pour un autre SR pour mieux affiner les recommandations. Cette opération peut être répéter plusieurs fois en fonction du nombre des SR utilisés dans le processus de recommandation. En outre, ces SR peuvent utiliser des parties des données d'entrée originales à tous les niveaux du pipeline.

Les conceptions monolithiques sont faciles à implémenter car elles ne nécessitent généralement que des modifications mineures de l'algorithme principal et de ses structures de données alors que les conceptions parallélisées nécessitent une correspondance minutieuse des notes de recommandation calculées par les différents algorithmes parallélisés. Les conceptions en pipeline sont les conceptions d'hybridation les plus ambitieuses, car elles nécessitent une connaissance plus approfondie du fonctionnement des algorithmes pour garantir l'efficacité des calculs d'exécution.

#### **I.4 Limitations et problèmes de SR**

Malgré le succès des SR, ces systèmes souffrent de certains problèmes comme le démarrage à froid, le problème du mouton gris, les problèmes de montée en charge, l'évaluation de la qualité des recommandations et la prise en compte du contexte de l'utilisateur.

Lorsqu'un nouvel utilisateur entre dans le système, il n'y aura pas d'informations antérieures telles que l'historique de navigation, les items déjà noté, etc. Dans ce cas, il est difficile de recommander des articles à cet utilisateur. De même, lorsqu'un nouvel item est introduit dans le SR, aucune note n'est attribuée à cet item et de ce fait aucune suggestion qui le concerne ne pourra être calculée par le processus de recommandation. Ce type de problème est appelé « le démarrage à froid » du SR dans le cas d'un nouvel item ou utilisateur. Pour limiter l'impact de ce type de problème, l'utilisation des SR hybrides peut améliorer les algorithmes de base mais aucune variante d'hybridation n'est applicable dans toutes les circonstances.

Par ailleurs, les utilisateurs qui ont des goûts particuliers et des préférences très inhabituelles par rapport aux autres n'auront pas beaucoup d'utilisateurs voisins (utilisateurs similaires). Il sera donc difficile de faire des recommandations pertinentes pour ce genre d'utilisateurs, c'est le problème du mouton gris [25].

Avec l'augmentation du nombre d'utilisateurs et d'items dans le SR, les calculs nécessaires à la recommandation deviennent très coûteux. Souvent des algorithmes de recommandation qui ont une énorme base d'utilisateurs et d'items préfèrent avoir des recommandations moins précises avec un temps de calcul rapide pour éviter le problème de Montée en charge. Dans certain cas, pour réduire le temps de calcul, une des solutions consiste à prendre en compte le contexte des utilisateurs pour filtrer l'espace des évaluations utilisé pour le calcul des similarités et des futures prédictions.

Enfin, l'évaluation des qualités des recommandations fournies par les SR est une étape clé de succès de type de système mais elle souffre de la latence que peut engendrer un processus d'évaluation online des feedbacks des utilisateurs.

## **II. Les systèmes de recommandation sensibles au contexte**

Dey et al. [26] définit le contexte comme "toute information pouvant être utilisée pour caractériser la situation d'une entité. Une entité peut être une personne, un lieu ou un objet qui est considéré comme pertinent pour l'interaction entre un utilisateur et une application, y compris l'utilisateur et l'application elle-même".

Les SR actuels utilisent des informations contextuelles telles que le temps, la localisation, la compagnie d'autres personnes pour améliorer le processus de recommandation dans certains domaines. Ce type de système est appelé "Context Aware Recommendation System" (CARS) [27].

Les SR traditionnels sont à deux dimensions (2D) car ils ne considèrent que les dimensions de l'utilisateur et de l'item. Dans le cas des CARS, les SR ajoutent la dimension du contexte pour mieux affiner l'ensemble des recommandations. Pour cette raison, ce type de systèmes sauvegardent chaque évaluation  $r \in R$  ( $R$  étant l'ensemble des évaluations) effectuée par un utilisateur  $u \in U$  ( $U$  étant l'ensemble des utilisateurs) sur un item  $i \in I$  ( $I$  étant l'ensemble des utilisateurs) en précisant le contexte  $c \in C$  ( $C$  étant l'ensemble des contextes existants). Donc, nous pouvons modéliser cette relation grâce à la fonction  $F$  défini comme suit :

$$F: U \times I \times C \rightarrow R \text{ avec } r = F(u, i, c) \dots\dots\dots (1)$$

Par exemple, un SR de séjours de vacances doit tenir compte de la saison pour fournir une recommandation adaptée et donc notre fonction s'écrit de la façon suivante :

$$Rating_{séjour} = F(\text{Utilisateur}, \text{Séjour de vacance}, \text{Saison}) \dots\dots\dots (2)$$

De même, un SR de tourisme implémenté sur dispositif mobile peut privilégier la recommandation des lieux à visiter en tenant compte de la position de l'utilisateur. La fonction  $F$  peut s'écrire comme suit :

$$Rating_{lieu} = F(\text{Utilisateur}, \text{lieu à visiter}, \text{position de l'utilisateur}) \dots\dots\dots (3)$$

## II.1. Les CARS et le tourisme

Ces dernières années la façon dont les touristes préparent et organisent leurs voyages a nettement changé. Il y a peu de temps, ils utilisaient des guides de voyages et des cartes géographiques dans le but de trouver des points d'intérêt POI (Point Of Interest) à visiter (hôtels, attractions, musées, événements, etc.). De nos jours, ils peuvent trouver n'importe quelle information sur n'importe quel lieu d'activité soit en utilisant un moteur de recherche, ou en faisant recours à des SR qui aident les visiteurs à trouver ce qui les intéresse et leur proposer des parcours de visite personnalisés [28].

Selon [29], un point d'intérêt POI (Point Of Interest) désigne un lieu ou une destination potentiellement intéressant(e) qui peut être une attraction touristique, un hôtel, un restaurant, un distributeur de billets, une pharmacie, un centre médical, un magasin, une station-service, une école, etc. Ce type de point est utilisé par différents logiciels de navigation et appareils GPS car il est décrit par ses coordonnées géographiques.

Ces dernières années, l'évolution des équipements mobiles (smartphones, tablettes...) et des technologies de localisation (4G, GPS...) a envahi le domaine du tourisme car cette évolution permet d'aider et de soutenir les utilisateurs mobiles partout et à tout moment. Cependant, il devient de plus en plus difficile de répondre aux besoins croissants des utilisateurs mobiles à cause de la surcharge d'informations pouvant intéresser les utilisateurs surtout dans le choix de lieux proches de leur localisation instantanée [30]. Face à cette situation, les applications à développer doivent répondre à des questions telles que : (1) quels sont les lieux à visiter ? (2) quels sont les services (restaurant, hôtel...) les plus proches ? (3) quels sont les sites les plus appréciés par les touristes ? Etc.

Pour atteindre cet objectif, les CARS doivent prédire les intérêts de chaque utilisateur mobile grâce à des algorithmes basés sur des statistiques de navigation (le nombre de visites par les touristes, les évaluations antérieures des lieux ...) pour recommander les POI à visiter [31]. Par conséquent, le scénario de la visite touristique sera conçu autour de la notion du POI car

elle permet d'associer la localisation géographique et les offres de produits/services disponibles. En outre, ce type de scénario repose essentiellement sur les similarités entre les POI afin de mieux cibler les produits ou services à promouvoir en fonction de l'historique généré par les anciens utilisateurs [32].

Cependant, lors de la découverte d'une nouvelle ville, les touristes mobiles sont souvent sans profil préalable et ce type de RS ne peut donc pas les aider dans le choix des POI à visiter [31]. Pour résoudre ce problème, des algorithmes de filtrage collaboratif basés sur la mémoire semblent être une bonne solution car ils utilisent les anciennes notations des POI déjà visités par les touristes, quel que soit leur profil [33]. Ce type de SR calcule les similitudes entre les utilisateurs (ou entre les POI) pour pouvoir faire les prédictions des futures notations de POI à recommander.

Par ailleurs, les réseaux sociaux basés sur la localisation (LBSN) tels que Foursquare, Gowalla, Facebook, ... peuvent établir des liens sociaux entre leurs utilisateurs afin de partager leurs expériences de visite de certains POI en effectuant check-ins (signaler le passage) via leurs appareils portables. Ce type de partage reflète les comportements humains dans la réalité et permet de recommander des POI aux utilisateurs en fonction de leurs préférences, apprises à partir des données fournies par la communauté. Cependant, ce type de recommandation s'accompagne d'autres défis spécifiques dus à des influences géographiques, temporelles et sociales [34]. Néanmoins, les LBSN peuvent contribuer à alimenter l'historique de navigation des CARS pour faire face à des problèmes de démarrage à froid surtout dans le cas d'ajout d'un nouvel utilisateur ou d'un nouvel item.

## **II.2. Les CARS et les SIG**

Les SR permettent de suggérer différents types d'items comme des films, des articles, des amis, des restaurants, des monuments historiques, ... à plusieurs types d'utilisateurs. Ces items peuvent être divisés en deux catégories : la première catégorie concerne les items qui possèdent des coordonnées géographiques (restaurants, des monuments historiques...) et la deuxième catégorie des items (films, des articles,...) regroupe les items qui ne disposent d'aucune localisation physique.

Cette première catégorie s'appuie sur la notion du POI et nécessite d'être visualisé sur un SIG alors que la deuxième catégorie n'a pas besoin de carte pour l'affichage de ces items. Donc, les systèmes de recommandation sensibles au contexte de localisation des utilisateurs mobiles doivent utiliser les SIG pour la recommandation, la recherche et la sauvegarde de leurs POI. Cela permet de mieux gérer l'historique de navigation des utilisateurs surtout dans le domaine du Smart tourisme qui permet d'apporter aux visiteurs une information personnalisée en temps réel tout en mesurant l'influence des lieux touristiques grâce à la comparaison des différents parcours des anciens touristes.

Par exemple, les auteurs de [35] ont présenté un système de recommandation mobile qui regroupe un moteur de recommandation hybride et une architecture de SIG 3D mobile. Ce système permet aux touristes de bénéficier de fonctionnalités innovantes telles qu'une interface cartographique 3D et des recommandations sensibles en temps réel. Ces recommandations suggèrent aux utilisateurs des restaurants proches de leurs localisations instantanées grâce à la relation entre le SR, le SIG et l'application mobile. Pour commencer, le système de positionnement global (GPS) intégré à l'appareil sert à récupérer les coordonnées de la position de l'utilisateur. Ensuite, les SIG comme GoogleMap, OpenstreetMap, et autre sélectionnent les lieux (restaurant, gare, etc.) proches de ces coordonnées GPS. Enfin, le SR affine la liste des lieux sélectionnés en se basant sur les évaluations antérieures des touristes.

## Conclusion

Les SR sont omniprésents dans notre vie au quotidien car ils permettent de recommander des films, des morceaux de musiques, des jeux vidéo, des livres, des amis sur les réseaux sociaux, des destinations touristiques, ... grâce à plusieurs techniques. Pour cette raison, nous avons expliqué dans cet article les techniques de recommandation basées sur le contenu et celles basées sur le filtrage collaboratif tout en soulignant l'apport des approches hybrides pour l'amélioration des performances des SR. Puis, nous avons mis en évidence l'utilité de la prise en compte du contexte dans lequel les évaluations ont été faites pour faire la prédiction des items à recommander à l'utilisateur. Ensuite, nous avons fait un zoom sur l'usage des systèmes de recommandations sensibles au contexte (CARS) dans le domaine du tourisme pour la suggestion des POI pertinents pour les utilisateurs de Smartphones. Enfin, nous avons mis l'accent sur l'apport des SIG pour la visualisation instantanée des POIs proches de la position des touristes pendant le déroulement de leurs voyages. Nous avons aussi souligné que l'utilisation des SIG avec les CARS est une piste de recherche très prometteuse car ce type de système permet d'améliorer la qualité des recommandations basées sur des contextes spatio-temporels.

## REFERENCES

- [1] Crowley, Bill. «Rediscovering the history of readers advisory service.» *Public Libraries*, 44(1), 2005: 38.
- [2] ROBIN, B. «Hybrid Recommender Systems: Survey and Experiments.» *User Modeling and User Adapted Interaction*, 2012.
- [3] Francesco, R., R. Lior, et S. Bracha. «Recommender Systems Handbook.» 2011.
- [4] MILLER, B. «MovieLens Unplugged : Experiences with an Occasionally Connected Recommender System.» . *Proceedings of the 8th international conference on Intelligent user*: 263–266 , 2003.
- [5] PAVLOV, D., E. MANAVOGLU, D. PENNOCK, et C. GILES. «Collaborative Filtering with Maximum.» *IEEE Intelligent Systems*, Issue 19: 40–48, 2004.
- [6] ROBIN, B. «Hybrid Web Recommender Systems.» 2007: 377–408.
- [7] DAS, A., M. DATAR, A. GARG, et S. RAJARAM. «Google News Personalization : Scalable Online.» *WWW'07 : Proceedings of the 16th International Conference on World*, 2007: 271–280.
- [8] Asanov, D. «Algorithms and methods in recommender systems.» *Berlin Institute of Technology, Berlin*, 2011.
- [9] Jannach, Dietmar, Markus Zanker, Alexander Felfernig, et Gerhard Friedrich. «Recommender Systems : An Introduction .» *Cambridge University Press, New York, NY*, 2010.
- [10] Suganeshwari, G, et Sp Syed Ibrahim. «A Survey on Collaborative Filtering Based Recommendation System.» *Proceedings of the 3rd International Symposium on Big Data and Cloud Computing Challenges*, 2016.
- [11] Bobadilla, J, F. Ortega, A. Hernando, et A. Gutierrez. «Recommender systems survey.» *Knowledge Based Systems*. 46, 2013: 109–132.
- [12] Shardanand, Upendra, et Pattie Maes. «Explicit and implicit rating.» *Social information filtering: algorithms for automating "word of mouth" Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, 1995.
- [13] Pazzani, M. «A framework for collaborative, content-based, and demographic filtering.» *Artif. Intell. Rev. Spec. Issue Data Min. Internet* 13(5–6), 1999: 393–408.
- [14] Bobadilla, J., F. Ortega, A. Hernando, et A. Arroyo. «A balanced memory based collaborative filtering similarity measure.» *Int. J. Intell. Syst.* 27(10), 939946, 2013.
- [15] Garcia, R., et X. Amatriain. «Weighted content based methods for recommending connections in online social networks.» *Proceedings of the 2010 ACM Conference on Recommender Systems*, 2010: 68–71.



- [16] Bobadilla, J., A. Hernando, F. Ortega, et A. Gutierrez. «Collaborative filtering based on significances.» *Inf. Sci. 185(1)*, 2012: 1–17.
- [17] Symeonidis, P., A. Nanopoulos, et Y. Manolopoulos. «MovieExplain: a recommender system with explanations.» *Proceedings of the 2009 ACM Conference on Recommender Systems*, 2009: 317–320.
- [18] Gemmell, J., T. Schimoler, B. Mobasher, et R. Burke. «Resource recommendation for social tagging: a multi-channel hybrid approach.» *ACM Conference on Recommender Systems*, 2010: 60–67.
- [19] Park, D.H., H.K. Kim, I.Y. Choi, et J.K. Kim. «A literature review and classification of recommender Systems research.» *Expert Syst. Appl.* 39, , 2012: 10059–10072.
- [20] Kong, F., X. Sun, et S. Ye. «A comparison of several algorithms for collaborative filtering in startup stage.» *IEEE Transactions on Networks, Sensing and Control*, 2005: 25–28.
- [21] Luo, X., Y. Xia, et Q. Zhu. «Incremental collaborative filtering recommender based on regularized matrix factorization.» *Knowl.-Based Syst.* 27, 2012: 271–280.
- [22] Yager, R.R. «Fuzzy logic methods in recommender systems.» *Fuzzy Sets Syst.* 136(2), 2003: 133–149.
- [23] Burke, R. «Hybrid recommender systems: survey and experiments.» *User Model. User-Adap.Inter.* 12(4), 2002: 331–370.
- [24] Ingoo, H., J.O. Kyong, et H.R. Tae. «The collaborative filtering recommendation based on SOM cluster-indexing CBR.» *Expert Syst. Appl.* 25, 2003: 413–423.
- [25] Ghazanfar, M. A. and Prügel-Bennett, A. , Leveraging clustering approaches to solve the gray-sheep users problem in recommender systems. *Expert Systems with Applications*, 41(7), 2014:3261–3275.
- [26] Dey, A.K., G.D. Abowd, et D. Salber. «A conceptual framework and a toolkit for supporting the rapid prototyping of context-aware applications.» *Human-Computer Interaction*, 16, 2001: 97-166.
- [27] Jie, Lu, Wu Dianshuang, Mao Mingsong, Wang Wei, et Zhang Guangquan. «Recommender system application developments: A survey.» *Decision Support Systems, Volume 74,ISSN 0167-9236*, 2015: 12-32.
- [28] Benouaret, Idir. «Un système de recommandation contextuel et composite pour la visite personnalisée.» *Université de Technologie de Compiègne. Français. fNNT :2017COMP2332 ff. ffel-01767997 ff*, 2017.
- [29] Chuang, Hsiu-Min et Chia-Hui Chang. «Verification of POI and Location Pairs via Weakly Labeled.» 2015.
- [30] Dennouni, N., Y. Peter, L. Lancieri, et Z. Slama. «To a Geographical Orchestration of Mobile Learning Activities.» *International Journal of Interactive Mobile Technologies (iJIM)*, Vol.8, No.2, 2014: 35-41.
- [31] Dennouni, N., Y. Peter, L. Lancieri, et Z. Slama. «Vers un système d’orchestration adaptatif et collaboratif des activités d’apprentissage en mobilité.» *15ème conférence internationale sur l’extraction et la gestion des connaissances/Atelier GAST, Luxembourg*, 2015.
- [32] Dennouni, N., Z. Slama, Y. Peter, et L. Lancieri. «Recommendation Techniques in Mobile Learning Context: A Review.» *International Journal of Modern Education and Computer Science (IJMECS)*, Vol.9, No.10 DOI: 10.5815/ijmecs.2017.10.05, 2017: 37-46.
- [33] Desrosiers, C., et G. Karypis. «Methods, A comprehensive survey of neighborhood-based recommendation.» 2011: 107-144.
- [34] Miller, Harvey J. «Tobler’s first law and spatial analysis.» *Annals of the American Association of Geographers*, 2004: 40, 49, 85.
- [35] Noguera, J., M. J. Barranco, J. S. Rafael, et L. Martiinez. «A mobile 3D-GIS hybrid recommender system for tourism.» *Information Sciences 215*, 2012: 37–52.

# **GISDAY'2019 proceedings**

## **Résumés des Posters**



**The First day on GIS**  
18 th december 2019

# Fusion des données dans l'imagerie satellitaire

**Narimane Wafaa KROLKRAL**

Département d'informatique

Université Djillali Liabes

Sidi Bel Abbès, Algérie

[wafaa.krolkral@univ-sba.dz](mailto:wafaa.krolkral@univ-sba.dz)

**Kamel Mohamed FARAOUN**

Département d'informatique

Université Djillali Liabes

Sidi Bel Abbès, Algérie

[kamel\\_mh@yahoo.fr](mailto:kamel_mh@yahoo.fr)

## Résumé

La multiplication des satellites de télédétection et l'utilisation de plusieurs capteurs pour l'observation de la terre ont permis l'acquisition d'une multitude d'images présentant des caractéristiques spatiale, spectrale et temporelle différentes. L'extraction des informations utiles, liées à la nature physique des surfaces observées, fait appel à différentes techniques, approches et méthodes de traitement d'images numériques. Parmi ces procédures figure la fusion, qui est devenue un aspect important de traitement de l'information. Face à la diversité d'algorithmes d'analyse d'images, il s'est avéré indispensable de rassembler ces différentes données afin d'aider l'utilisateur dans sa prise de décision, sans avoir à analyser un nombre très important de paramètres.

Depuis quelques années des méthodes de fusion ont été adaptées et développées pour des applications en traitement du signal et d'image. Ces approches sont apparues afin de gérer des quantités très importantes de données multi-sources, ces sources d'information peuvent être de différentes sortes : plusieurs images du même capteur, plusieurs images de capteurs différents.

Dans notre travail, nous nous sommes focalisés sur la fusion des images panchromatiques (PAN) à faible résolution spectrale et haute résolution spatiale avec des images multi-spectrales (MS) à faible résolution spatiale et haute résolution spectrale. Cette fusion est un problème clé dans de nombreuses applications de télédétection qui nécessitent des résolutions spectrales et spatiales très élevées. Notre objectif est de faire une étude comparative entre trois algorithmes, le premier est l'application de la transformée en IHS sur les trois bandes R, G et B de l'image MS, la réponse spectrale du capteur est utilisée afin d'adapter l'IHS aux images utilisées.

Le deuxième algorithme est l'application de la transformée en ondelettes discrète (DWT), qui est qualifiée de capter les détails verticaux, horizontaux et diagonaux dans l'image et le troisième algorithme est une variante de la DWT qui est la transformée en contourlets non sous échantillonnées (NSCT). Ces approches sont comparées en utilisant différentes métriques afin d'évaluer la qualité des images fusionnées.

**Mot clés :** fusion des images, image panchromatique, image multi-spectrale, transformée en ondelettes discrète, NSCT,

# Machine learning and deep learning for face recognition

**Chahreddine MEDJAHED**

Department of Computer Science  
EEDIS Laboratory  
University of SidiBel-Abbes  
[c.medjahed@univ-chlef.dz](mailto:c.medjahed@univ-chlef.dz)

**Abdellatif RAHMOUN**

Department of Computer Science  
EEDIS Laboratory  
University of SidiBel-Abbes  
[rahmoun\\_abd@yahoo.fr](mailto:rahmoun_abd@yahoo.fr)

**Christophe CHARRIER**

Multimedia and Internet Dept.  
GREYC Laboratory  
Université de Caen Normandie  
[christophe.charrier@unicaen.fr](mailto:christophe.charrier@unicaen.fr)

## ABSTRACT

Face recognition has become a popular topic of research recently due to increases in demand for security as well as the rapid development of mobile devices. The application of face recognition in real life situations and pose variations still remains a challenge. This task can be divided into two sub-problems: face detection followed by face recognition. The objective of this work is to evaluate and compare various systems of face recognition based on speed and high accuracy machine learning algorithms. We propose three biometric systems. The first system use Gray-level co-occurrence matrix (GLDM) to extract features and feed-forward Neural Network (MLP) for classification. The second one is based on Local Binary Pattern (LBP) algorithm for extraction features and a Multi-layer perception (MLP) for the classification. These two precedent systems are based on "engineered" features. The third one is based on learned features using deep learning, in particular Convolutional Neural Networks (CNNs). Machine learning and deep learning are two subsets of artificial intelligence which have garnered a lot of attention over the past two years. In Machine learning, most of the applied features need to be identified by an expert and then hand-coded as per the domain and data type.

Deep learning algorithms try to learn high-level features from data. This is a very distinctive part of Deep Learning and a major step ahead of traditional Machine Learning.

In general, a CNN is formed by several convolution, pooling and Flattening operations, usually followed by one or more fully connected layers. The CNN receive image as input then applied convolution operation to extract features. The objective of convolution operation is to learn specific characteristics of an image. Reduce dimensions of each feature map without losing features or patterns is the aim of pooling operation.

A large colored Face Database is used to evaluate these three proposed and adapted architectures. The results are competitive.

**Keywords:** Local Binary Pattern, Gray-level co-occurrence matrix, Convolutional Neural Networks, Deep learning, Machine learning.

# Towards Author Profiling from Modern Standard Arabic Texts

**Asmaa MANSOUR KHOUDJA**

Department of Computer Science

Faculty of Exact Sciences and Informatics

Hassiba Benbouali University of Chlef  
Chlef, Algeria

a.mansourkhoudja@univ-chlef.dz

**Mourad LOUKAM**

LMA Laboratory

Faculty of Exact Sciences and Informatics

Hassiba Benbouali University of Chlef  
Chlef, Algeria

m.loukam@univ-chlef.dz

**Fatma Zohra BELKREDIM**

LMA Laboratory

Hassiba Benbouali University of Chlef  
Chlef, Algeria

f.belkredim@univ-chlef.dz

## Abstract

In the last few years there has been a growing interest in the enormous increase of information on the web, particularly on social Media (Facebook, twitter, blogs, etc.) but Mostly, texts are anonymous where users don't reveal their real identity. Which makes the identification of the authors of these anonymous texts a hard task to do. What is Author profiling Author profiling (AP) is a method in which people's writing is analyzed in an attempt to find out which classes they belong to, such as gender, age group, political affiliation, or native language [1]. Here are a few of them detailed below: Author's Age The author's writing style steadily rise or fall as the individual grows older. As well as looking at changes in an individual author, people have claimed that stylistic changes occur with age for every writer [1]. Also, it is assumed that the users in age group of 13-17 write about topics related to adolescence, school activities, etc. While the users in age group of 23-27 write more about pre-marital affairs, travel and college life and the users belonging to 33-47 age group post more about post-marriage life and social activities [2]. Can and Patton [3] studied the works of two famous Turkish authors, Çetin Altan and Yaşar Kemal, and found that the average word length for both authors showed a significant increase over time. Author's Gender Koppel et al [2] tried to distinguish between male and female authors where they found that Texts written by men were predominantly informational, containing for example more determiners and adjectives, while texts written by women were more involved, with higher rates of pronoun use, negation markers, and use of the present tense. Author's Political Affiliation Political orientation prediction has been a subject of a number of text classification researches. And there have been many contributions to political text classification such as [5] where they produced a system for classifying Arabic language documents according to organizational affiliation and ideology. In which they built a corpus of over 100 documents from several Islamic organizations and chose the 1,000 most common words as features [1]. Author's Native Language Native Language Identification (NLI) is the process of automatically identifying the native language of a writer using just a part of writing in another language as evidence. This is the Identification of the author's original language, not from translations, but from original productions by non-native speakers [1]. Also, Language Variety recognition (LVR) is used in NLI, for example distinguishing between American and British English. For example, the underlined segments in the text 'Language Variety Identification analyses the behaviour of ...' are characteristic of British rather than American spelling. And In a line of English text for example 'Native Language Identification analyzzes the behavior of ...', the underlined segments may be spelt the way they are because of the first language interference from the Italian words 'linguaggio' and 'analizza' [6]. Author Profiling in Modern Standard Arabic Language Arabic is a challenging language because of the numerous levels of linguistic representation (phonology, orthography, morphology, and syntax). In fact, [4] found that gender is morphologically marked when using Arabic texts. One of the relevant constructions with respect to identifying an author's gender are predicative sentences with first person subjects. For example, in the Arabic equivalent of "I am happy", happy is morphologically marked as either feminine or masculine. An additional example 'منذ صغري و أنا شغوف بالقراءة' would be 'Since my childhood, I am passionate about reading.'. from these examples it is clear in the adjective that the

author's gender is masculine. Moreover, from "حصلت على البكالوريا من الثانوية الجديدة للبنات" this example I got my baccalaureate degree from the new secondary Girls' school.", we can guess that the author's gender is feminine because She studied at a school which is reserved for girls. And these features help to detect gender differences very accurately. Also, the age of the author can be obvious from the "بعد أيام سأحتفل بعيد ميلادي الثلاثين", text for example "In a few days, I'm going to celebrate my thirteenth birthday" where, it is easy to extract the author's age for it is given in the text. As well as in "منذ عشرين سنة خلت" "Twenty years ago, I wrote an article in Al Ahram". Where, the author's age is not specified but obviously the author is a middle or an elderly aged person (may be over 40 years old).

**Author Profiling Methods** Many approaches have been proposed in the field of AP, methods based on Linguistic features, methods based on Machine Learning Techniques, and recently Deep Learning. And multiple solutions were proposed by various researchers across the globe. In which researchers used different types of features to identify the writing style characteristics of the authors such as:

- Character-based Features: The total number of characters, The number of capitalized letters, etc.
- Lexical Features: Total number of words, The number of positive emotional words, etc.
- Syntactic Features: N-Grams of POS-Tags, Frequency of punctuations, Stopwords, etc.
- Structural Features: Total number of paragraphs, total number of sentences, etc.
- Content specific Features: Frequency of content specific keywords, Topic specific features, etc.

Author Profiling applications Author Profiling has attracted much attention from researchers recently, due to its wide range of applications such as, forensic, security, marketing analysis, and historic/literary text authorship verification. For instance, Author Profiling helps in Solving Crime through Forensic by analyzing signatures, documents, and anonymous letters to identify the perpetrator of a crime [7]. From another perspective such as marketing and based on analyzing online product reviews, companies can reveal the age category of their clients whether the younger or the older population are attracted to their products so that these companies adopt new strategies to serve their customers. Author Profiling is also beneficial in plagiarism where, author profiling and plagiarism detection are considered together because these topics are often related to fraudulent behavior and they are mainly text classification techniques [1].

**Keywords:** Author Profiling, Text mining, Modern Standard Arabic Language.

## Bibliography

- [1] M. P. Oakes, "Author Profiling and Related Applications," in *The Oxford Handbook of Computational Linguistics* 2nd edition, .
- [2] J. Schler, M. Koppel, S. Argamon, and J. Pennebaker, "Effects of Age and Gender on Blogging in Proceedings of 2006 AAAI Spring Symposium on Computational Approaches for Analyzing Weblogs," 2006.
- [3] F. Can and J. M. Patton, "Change of writing style with time," *Comput. Hum.*, vol. 38, no. 1, pp. 61–82, 2004.
- [4] D. Estival, T. Gaustad, B. Hutchinson, S. B. Pham, and W. Radford, "Author profiling for English and Arabic emails," 2008.
- [5] M. Koppel, J. Schler, and S. Argamon, "Computational methods in authorship attribution," *J. Am. Soc. Inf. Sci. Technol.*, vol. 60, no. 1, pp. 9–26, 2009.
- [6] M. Franco-Salvador, G. Kondrak, and P. Rosso, "Bridging the Native Language and Language Variety Identification Tasks," *Procedia Comput. Sci.*, vol. 112, pp. 1554–1561, 2017.
- [7] T. R. Reddy, B. V. Vardhan, and P. V. Reddy, "Profile specific document weighted approach using a new term weighting measure for author profiling," *Int. J. Intell. Eng. Syst.*, vol. 9, no. 4, pp. 136–146, 2016

# Une approche de migration des machines virtuelles pour la gestion des contrats SLA dans le Cloud Computing

K.MOULEY

Département d'Informatique  
Faculté des Sciences Exactes et informatique  
Université de Hassiba Ben Bouali, Chlef, Algérie,

## Résumé

Le Cloud Computing qui peut être défini comme un ensemble de technologies permettant de fournir des services payants et d'accéder aux ressources partagées sur le réseau en fonction de la demande du consommateur avec un minimum de risques de gestion, ce paradigme est devenu l'une des plus importantes révolutions technologiques au monde. Cependant, la croissance rapide du Cloud Computing a imposé un fardeau financier énorme et entraîné des effets secondaires sur l'environnement dus à une consommation d'énergie excessive. La consommation d'énergie élevée n'est pas seulement attribuée à la taille des centres de données, mais également à l'inaptitude à utiliser les ressources. La plupart des recherches en cours portent sur la réduction de la consommation d'énergie par une consolidation agressive des machines virtuelles, ce qui conduit à la violation du contrat de niveau du service, et la dégradation de la qualité de service (Qos). De plus, la consommation de ressources non équilibrée exacerbe le gaspillage de ressources indisponibles, appelé fragmentation des ressources non disponibles. Nous avons proposé et implémenté deux nouvelles approches de migration des machines virtuelles dans les datacenters pour gérer les différents paramètres d'un contrat SLA entre le fournisseur de services Cloud et ses clients. Ces approches cherchent à fournir aux prestataires des services un moyen de réduire leurs charges en termes de pénalités de violations des contrats SLA et de consommation énergétique. Nous avons utilisé deux technologies : la virtualisation et la migration à chaud des machines virtuelles, puis proposé deux politiques 'DRT' et 'EET'. Ces approches sont basées sur deux phases à savoir la phase de sélection de VMs pour les faire migrer, cette phase permet de répondre à la question : Quand doit-on migrer les machines virtuelles ? , et la phase d'allocation pour trouver le meilleur placement des VMs sélectionnées sur les hôtes (L'affectation d'une VM à un hôte). L'approche 'DRT (Double Resource Threshold)', est basée sur l'utilisation des ressources physiques (Cpu et Ram) , et un "Safety Parameter" pour affiner les seuils supérieur de ces ressources . 'EET (Energy Efficient Threshold)', aussi, basée sur l'utilisation des ressources physiques, en plus d'un seuil de taux de violation SLA pour modérer la consolidation agressive. Les seuils d'approches sont dynamiques, et calculés par des formules mathématiques qui dépendent de l'utilisation de CPU et de la RAM, puis le nombre des VMs. Les résultats détaillés de la simulation de différents types de charge de travail valident et reconnaissent l'importance des méthodes proposées pour la réduction de la consommation d'énergie et les violations des contrats de niveau de service dans le Cloud Computing. Le simulateur utilisé est le CloudSim, qui est une application de simulation qui permet la modélisation, la simulation, l'expérimentation en continu de l'informatique en nuage et des services d'application, puis des composants du système Cloud tels que les centres de données, les machines virtuelles et les stratégies d'allocation de ressources. La première approche proposée 'DRT' est mieux que les autres approches existantes dans la littérature (IQR, LR, LRR, MAD, THR, MMT, MC, MU, RS.). Et la deuxième 'EET' est mieux que les autres approches existantes en termes de consommation d'énergie.

**Mots clés :** Cloud Computing , Qos , consommation d'énergie ,approche migration des machines virtuelles

# Distributed data clustering using ensemble techniques

Guellil ZOUAOUI

Département d'Informatique,  
Faculté des Sciences Exactes et informatique,  
Université de Hassiba Ben Bouali, Chlef, Algérie,

## Abstract

Data clustering is an important field of data analysis; the aim is to identify similar groups in entire of data set and affect each data elements in their similar groups. Several methods have been proposed in the literature, it differs in their modes of operation (iterative, hierarchical ...), representation of the data (centroid, kernel ...) and type of data to process (vector of descriptors, matrix of distance ...). However, these methods are designed to process on centralized data, in many applications the data set is distributed among several sites that cannot be gathered centrally because of machine constraint (ex: storage) or privacy constraint. Developing distributed data clustering algorithms are needed to deal with these challenges using a clustering procedure that builds the global model without requiring access to data from different sites.

Ensemble techniques method has proved their efficiency to improve performance of classification algorithms [1] [2], its aggregate models produced by multiple algorithms to get better results, this allows to take advantage of their strength and overcoming their Weaknesses of each algorithm.

The success of this paradigm has led researchers to apply the same ideas to clustering problem [3][4]; this field called consensus-clustering, aims to combine various models using a consensus function. The combined models can be obtained using different clustering algorithms on the entire of data, applying a given algorithm many times with different parameters, resulting from clustering a subset of features (disjoint or overlapping) or a subset of dataset[5].

In this paper, we present a framework for a distributed clustering based on ensemble techniques, our approach is based on three steps: first, each site searches for clusters (models) of its local data, co-occurrence matrix are created at each site and then the number of occurrences of two data from different sites is deduced without having access to the local data, Finally, we proceed with the search for the consensus-clustering.

**Keywords:** Distributed clustering, Cluster analysis, Cluster ensemble, Co-occurrence matrix.

## Bibliography

- [1] Breiman, L. Bagging predictors. *Machine Learning*, 1996.
- [2] Dietterich, T.G. An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees: Bagging, Boosting, and Randomization. *Machine Learning*, 2000.
- [3] Fred A. (2001) Finding Consistent Clusters in Data Partitions. In: Kittler J., Roli F. (eds) *Multiple Classifier Systems*. MCS 2001.
- [4] Fred, A.L.N., Jain, A.K.: Combining multiple clustering using evidence accumulation. *IEEE Trans. Patt. Anal. Mach. Intell.* 2005
- [5] Rozmus D. Cluster Ensemble Based on Co-occurrence Data. In: *Advances in Data Analysis, Data Handling and Business Intelligence: Proceedings of the 32nd Annual Conference of the Gesellschaft für Klassifikation*, July 16-18, 2008



# **Système immunitaire artificiel hybride pour la classification de données**

**Ahmed SLIMANI**

Département d'Informatique,  
Faculté des Sciences Exactes et informatique,  
Université de Hassiba Ben Bouali, Chlef, Algérie,

## **Résumé**

La classification des données est le processus consistant à analyser des données structurées ou non structurées et à les organiser en catégories, en fonction du type et du contenu des fichiers.. Plusieurs méthodes ont été appliquées pour résoudre ce problème par exemple des des méthodes inspirées de la biologie tels que les algorithmes génétiques et les systèmes immunitaires artificiels

Le développement de systèmes intelligents à travers l'hybridation est l'une des tendances à venir. Ces techniques sont la combinaison de différentes approches d'apprentissage automatique telles que la logique floue, le calculs évolutionnaires, les réseaux de neurones artificiels (RNA), les algorithmes génétiques (AG) et les systèmes immunitaires artificiels. Le motif principal est de surmonter les limites de l'algorithme individuel, en combinant différentes techniques d'apprentissage et d'adaptation, par lesquels il est possible d'obtenir des effets de collaboration. Au cours des dernières années, les approches intelligentes sont utilisées pour le développement d'un grand nombre de nouveaux systèmes intelligents.

.Dans cette rapport nous nous sommes intéressés aux approches de classification des Systèmes Immunitaires Artificiels hybrides, nous chercherons à concevoir un système hybride de la méthode AIS et d'autres méthodes de classification (Optimisation par essaim de particules PSO, réseau de neurone, .....) pour la classification de donnée

**Mots clés :** AIS, classification des données, système immunitaire hybride

# **GISDAY'2019**

## **proceedings**

### **Posters**



#### **The First day on GIS**

**18<sup>th</sup> December 2019**



Asmaa Mansour Khoudja  
Department of Computer Science  
Hassiba Benbouali University of Chlef,  
chlef, Algeria  
a.mansourkhoudja@univ-chlef.dz

Mourad Loukam  
LMA Laboratory  
Faculty of Exact Sciences and Informatics  
Hassiba Benbouali University of Chlef, chlef, Algeria  
m.loukam@univ-chlef.dz

Fatma Zohra Belkredim  
LMA Laboratory  
Faculty of Exact Sciences and Informatics  
Hassiba Benbouali University of Chlef, chlef, Algeria  
f.belkredim@univ-chlef.dz




## Towards Author Profiling from Modern Standard Arabic Texts

### Introduction

In the last few years there has been a growing interest in the enormous increase of information on the web, particularly on social Media (Facebook, twitter, blogs, etc.) but Mostly, texts are anonymous where users don't reveal their real identity. Which makes the identification of the authors of these anonymous texts a hard task to do.

### What is Author profiling (AP)



Author profiling (AP) is a method in which people's writing is analyzed in an attempt to find out which classes they belong to, such as gender, age group, political affiliation, or native language [1]. Here are a few of them detailed below:

#### Author's Age

The author's writing style steadily rise or fall as the individual grows older. As well as looking at changes in an individual author, people have claimed that stylistic changes occur with age for every writer [1]. Also, it is assumed that the users in age group of 13-17 write about topics related to adolescence, school activities, etc. While the users in age group of 23-27 write more about pre-marital affairs, travel and college life and the users belonging to 33-47 age group post more about post-marriage life and social activities [2].

#### Author's Gender

Koppel et al [2] tried to distinguish between male and female authors where they found that Texts written by men were predominantly informational, containing for example more determiners and adjectives, while texts written by women were more involved, with higher rates of pronoun use, negation markers, and use of the present tense.

#### Author's Political Affiliation

Political orientation prediction has been a subject of a number of text classification researches. And there have been many contributions to political text classification such as [5] where they produced a system for classifying Arabic language documents according to organizational affiliation and ideology. In which they built a corpus of over 100 documents each from Hamas, Hezbollah, Al Qaeda and the Muslim Brotherhood and chose the 1,000 most common words as features [1].

#### Author's Native Language

Native Language Identification (NLI) is the process of automatically identifying the native language of a writer using just a part of writing in another language as evidence. This is the Identification of the author's original language, not from translations, but from original productions by non-native speakers [1].

Also, Language Variety recognition (LVR) is used in NLI, for example distinguishing between American and British English. For example, the underlined segments in the text 'Language Variety Identification analyses the behaviour of ...' are characteristic of British rather than American spelling. And In a line of English text for example 'Native Language Identification analyzes the behavior of ...', the underlined segments may be spelt the way they are because of the first language interference from the Italian words 'linguaggio' and 'analizza' [6].

#### Author Profiling in Modern Standard Arabic Language

Arabic is a challenging language because of the numerous levels of linguistic representation (phonology, orthography, morphology, and syntax). In fact, [4] found that gender is morphologically marked when using Arabic texts. One of the relevant constructions with respect to identifying an author's gender are predicative sentences with first person subjects. For example, in the Arabic equivalent of "I am happy", happy is morphologically marked as either feminine or masculine. Moreover, from this example

حصلت على البكالوريا من الثانوية الجديدة للبنات  
I got my baccalaureate degree from the new secondary Girls' school.", we can guess that the author's gender is feminine because She studied at a school which is reserved for girls. And these features help to detect gender differences very accurately.

Also, the age of the author can be obvious from the text for example, "بعد أيام سأحتفل بعيد ميلادي الثلاثين  
In a few days, I'm going to celebrate my thirteenth birthday" where, it is easy to extract the author's age for it is given in the text. As well as in "منذ عشرين سنة خلت كتبت مقالة في جريدة الأهرام  
Twenty years ago, I wrote an article in Al Ahrām". Where, the author's age is not specified but obviously the author may be over 40 years old.

### AP Methods

1. Many approaches have been proposed in the field of AP, methods based on Linguistic features, methods based on Machine Learning Techniques, and recently Deep Learning. And multiple solutions were proposed by various researchers across the globe. In which researchers used different types of features to identify the writing style characteristics of the authors such as:
  - Character-based Features: The total number of characters, The number of capitalized letters, etc.

- Lexical Features: Total number of words, The number of positive emotional words, etc.
- Syntactic Features: N-Grams of POS-Tags, Frequency of punctuations, Stopwords, etc.

### AP Applications

Author Profiling has attracted much attention from researchers recently, due to its wide range of applications such as, forensic, security, marketing analysis, and historic/literary text authorship verification.

For instance, Author Profiling helps in Solving Crime through Forensic by analyzing signatures, documents, and anonymous letters to identify the perpetrator of a crime [7].

From another perspective such as marketing and based on analyzing online product reviews, companies can reveal the age category of their clients whether the younger or the older population are attracted to their products so that these companies adopt new strategies to serve their customers.

Author Profiling is also beneficial in plagiarism where, author profiling and plagiarism detection are considered together because these topics are often related to fraudulent behavior and they are mainly text classification techniques [1].

### Bibliography

- [1] M. P. Oakes, "Author Profiling and Related Applications," in *The Oxford Handbook of Computational Linguistics 2nd edition*.
- [2] J. Schler, M. Koppel, S. Argamon, and J. Pennebaker, "Effects of Age and Gender on Blogging in Proceedings of 2006 AAAI Spring Symposium on Computational Approaches for Analyzing Weblogs," 2006.
- [3] F. Can and J. M. Patton, "Change of writing style with time," *Comput. Hum.*, vol. 38, no. 1, pp. 61-82, 2004.
- [4] D. Estival, T. Gaustad, B. Hutchinson, S. B. Pham, and W. Radford, "Author profiling for English and Arabic emails," 2008.
- [5] M. Koppel, J. Schler, and S. Argamon, "Computational methods in authorship attribution," *J. Am. Soc. Inf. Sci. Technol.*, vol. 60, no. 1, pp. 9-26, 2009.
- [6] M. Franco-Salvador, G. Kondrak, and P. Rosso, "Bridging the Native Language and Language Variety Identification Tasks," *Procedia Comput. Sci.*, vol. 112, pp. 1554-1561, 2017.
- [7] T. R. Reddy, B. V. Vardhan, and P. V. Reddy, "Profile specific document weighted approach using a new term weighting measure for author profiling," *Int. J. Intell. Eng. Syst.*, vol. 9, no. 4, pp. 136-146, 2016.



## Simulation d'algorithmes d'ordonnancement pour la QoS

Chaib Mostefa

Réseaux et télécommunications



### Introduction

Le déploiement sans arrêt de nouvelles applications IP relèvent de nouveaux défis, en exigeant des demandes de ressources très différentes et précises par rapport à celles pour laquelle internet a été conçu. Offrir plusieurs niveaux de services est le fondement de la qualité de service QoS.

Ce travail s'inscrit dans le mécanisme d'ordonnancement qui sert essentiellement à contrôler la distribution des ressources entre les flux ou les classes de services.

Plusieurs techniques ont été développées, soit pour contrôler le partage des ressources, soit pour isoler les classes de services ou bien pour réduire le temps d'attente dans les files ou encore pour minimiser le taux de perte de certains flux.

L'objectif est de simuler quelques algorithmes d'ordonnancement et de les comparer en termes de meilleurs offre de QoS

### Analyse et Conception

La diversité des modèles d'ordonnancement est motivée par la multiplicité des paramètres et métriques intervenant dans la garantie d'une meilleure qualité de service QoS: débit, gigue, délai (latence), perte ..., et ça peut satisfaire quelques classes de service, mais la combinaison de tous ces paramètres dans un algorithme équitable, qui satisfait tous les besoins en QoS, est loin d'être atteinte.

La raison pour laquelle on n'a pas recours à ces outils comme NS2, GNS3, OPNET est claire: on ne veut rien y ajouter. Notre objectif est d'étudier les algorithmes déjà existants et fonctionnels, pour des fins éducatives et pédagogiques.

Tout système d'attente est caractérisé par les éléments de base suivants:

- Loi d'arrivée des clients (paquets);
- Loi de traitement (service);
- Durée d'attente (avec le temps de traitement forment le délai);
- La taille de la file (tampon);
- Nombre de serveurs (processus);

L'arrivée des paquets dans un système n'est pas à intervalle régulier mais plutôt aléatoire et parfois par rafales. Pour cela, dans un environnement de simulation il faut un modèle de trafic aléatoire. Le processus de poisson convient très bien pour simuler le nombre de paquets arrivés par unité de temps. Toutefois, on ajoute de modèles de données prédéfinis pour les tests. Plusieurs générateurs sont instanciés selon le nombre de files d'attente paramétrées.

Les paquets arrivant au ordonnanceur, doivent être déjà classifiés. Le champs ToS, dans l'entête IP, est utilisé.

### Architecture & implémentation

Pour des fins pédagogiques, le langage JavaFX est utilisé. La programmation concurrentielle et multi threading est mieux adaptée, vu l'aspect temporelle, visuel et la nature de notre simulation:

- Plusieurs générateurs de paquets: aléatoires ou à partir d'un fichier;
- Arrivées des paquets et service d'ordonnancement en concurrence;
- Animations et transitions instantanée des paquets;

L'utilisation du patron de conception Observateur est très utiles. Car tous les paquets observent le changement de l'état de la file pour modifier leurs comportements. Le patron état (State) prend la responsabilité de réagir à ce changement. Notamment le pattern producteur / consommateur où les producteurs de paquets alimentent les files qui sont partagées avec un seul consommateur qui n'est d'autre que l'ordonnanceur.

### Principaux résultats

Les résultats montre bien les lacunes de quelques algorithmes vues au chapitre précédent. En effet, dans ce scénario, les flux ont chacun des paquets de même taille, celui ayant des paquets de grande taille domine toujours avec le meilleur débit.

Les algorithmes pondérés (DWRR, WFQ) offrent le moyen de différencier les demandes de QoS, et cela avec les poids attribués à chaque classe de service.

### Conclusions

Les résultats sont généraux et ne montrent pas la convergence des algorithmes étudiés à long terme. Les Ily a une relation entre les trois paramètres de qualité de service: débit, gigue, délai. L'amélioration de deux paramètres est au détriment de l'autre. En plus, les débits se stabilisent mais les délais augmentent et conduiront obligatoirement à des congestions.

### Perspectives

Aucun algorithme n'est parfait pour satisfaire toutes les demandes de QoS. Néanmoins, chacun est adapté pour certaines situations que d'autres. Peut-être un algorithme dynamique s'adaptant à toutes les situations verra le jour et sera standardisé. Les autres réseaux comme les SWNs, mobiles vont aider à améliorer les algorithmes d'ordonnancement.



# Adaptation d'une solution NoSQL orientée graphe à partir d'une base de données relationnelle



BENDIAF Mohammed Lotfi

## Introduction

Cela fait plus de vingt-cinq ans que les systèmes de bases de données relationnelles règnent en maître. Cependant, ces dernières années, le Web a connu une révolution avec l'avènement des sites web à fort trafic tels que Facebook, Amazon et LinkedIn. Ces grands acteurs du web ont été rapidement limités par lesdits systèmes à bases de données relationnelles pour deux raisons majeures : • Les gros volumes de données • Les montées en charge

## Problématique



Quelle solution NoSQL à adopter avec toute la diversité existante dans le marché et comment l'implémenter ?

### Analyse et Conception

#### Les limites du modèle relationnel


- Partitionnement des données
- Problème lié à l'application des propriétés ACID en milieu distribué
- Problème de requête non optimale dû à l'utilisation des jointures

Pour cela nous devons analyser le théorème de CAP



### Architecture & implémentation

Architecture = mapping + reducing



Neo4j est un système de base de données orienté graphe. C'est un projet Open Source sous licence GPLv3. Sa première version est sortie en 2007. Ce type de solution est utilisé dans le monde des réseaux sociaux

**Requêtage (Cypher)**  
 Cypher est un langage informatique de requête orienté graphe utilisé par Neo4j. Le langage se veut simple et efficace dans la formulation des requêtes d'interrogation et de mise à jour des bases de données orientées graphe.

```

Exemple d'implémentation en Cypher

USE (PREVIOUS)
MATCH (p:PERSON)
MATCH (c:COMPANY)
MATCH (p)->(c)
RETURN p, c
  
```


Algorithme de migration vers l'orientée Graphe

```

Algorithme : Migration vers l'orienté graphe

fonction Migration()
  Récupère le modèle de données (Dépendance de classes)
  Pour chaque classe
    Récupère les attributs et les relations
    Le type des attributs est récupéré pour être converti en un autre type
  FinPour
  Récupère le modèle physique des données
  Pour chaque ligne de données
    Le type des attributs est récupéré pour être converti en un autre type
    Les données sont converties en un autre type
  FinPour
  Ajoute les données dans le modèle de données
  Retourne le modèle de données
  
```



## Principaux résultats



Représentation d'un résultat en schéma heuristique

Traduction du modèle de données source vers le modèle de données cible

- Traduction des tables
- Traduction des enregistrements (lignes) d'une table d'entité
- Traduction de la table de jointure



Résultat final de la migration vers le NoSQL en NEO4J

## Conclusions

Nous concluons par dire qu'outre le modèle relationnel, la plupart de SGBD relationnels sont transactionnels, ce qui leur impose le respect des contraintes d'Atomicité, de Consistance, d'Isolation et de Durabilité, communément appelé propriétés ACID. Dans un contexte centralisé, ces contraintes sont plutôt aisées à garantir. Dans le cas de systèmes distribués, il est en revanche nécessaire de distribuer les traitements et les données entre différents serveurs. Il devient alors difficile de maintenir les contraintes ACID à l'échelle du système distribué entier tout en maintenant des performances correctes. Nous ajoutons que notre migration a en effet amélioré le système à savoir :

- Relation entre entités difficile à extraire du schéma relationnel tandis que facilement récupérable avec l'orienté graphe (Relations apparentes)
- Beaucoup de jointures pour exprimer des relations entre entités pour le relationnel
- Relations facilement exprimables pour l'orienté graphe
- Schéma général plus lisible

## Perspectives

Nous songerons comme perspectives à proposer des outils d'analyse et d'administration mûre dans un premier temps. L'approche de migration ici proposée, pourra donner lieu à la mise sur pied d'une plateforme (outil) de migration des bases de données relationnelles vers des bases NoSQL orientées graphes. Cet outil permettra de soulager les moteurs relationnels qui croulent sous le poids d'une forte volumétrie et d'incessantes mises à jour dues à l'évolution permanente des structures de données. Et finalement concevoir un système de gestion de base de données hybride alliant à la fois la stabilité et la maturité des systèmes relationnels avec les systèmes NOSQL de part leur légèreté, leur évolutivité ainsi maniabilité.



## Fusion des données dans l'imagerie satellitaire

KROLKRAL Narimane Wafaa & FERAOUN kamel Mohamed

Université Djillali Liabes, Département d'informatique, sidi Bel Abbes, Algérie



### Introduction

La télédétection a pour objectif l'analyse et l'interprétation des images acquises pour en extraire des informations utiles. En effet l'information extraite permet l'identification et la classification des différents matériaux présents dans une scène imagée. La plupart des systèmes de télédétection les plus récents, tels que Landsat 7, SPOT, IKONOS, QuickBird, etc, fournissent des capteurs avec une haute résolution spatiale panchromatique (PAN) et plusieurs bandes multi-spectrales (MS) simultanément. Les différents traitements appliqués sur ces derniers ont conduits les chercheurs à s'intéresser à la fusion pour avoir une information plus complète sur l'image. Dans diverses applications, l'avantage d'obtenir des images multi-spectrales possédant une haute résolution spatiale avec une conservation du contenu spectral a été démontré, particulièrement pour une meilleure discrimination de la végétation, de l'agriculture et les structures urbaines et routières. Dans ce poster, nous présentons quelques algorithmes (IHS, DWT and NSCT) qui visent à améliorer la qualité de l'image fusionnée, ces approches sont comparées par le biais de divers indices de qualité qui seront détaillés dans ce qui suit.

### Analyse et conception

#### 1. Fusion basée sur l'IHS (Intensity, Hue and Saturation)

La technique IHS est l'une des techniques de fusion les plus couramment utilisées, les informations spectrales se reflètent principalement sur la teinte et la saturation. La transformée en IHS choisie est sous la forme:

$$\begin{bmatrix} I \\ V_1 \\ V_2 \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{6}} & -\frac{2}{\sqrt{6}} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} & 0 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad H = \tan^{-1} \frac{V_2}{V_1} \quad \& \quad S = \sqrt{V_2^2 + V_1^2} \quad \begin{bmatrix} R' \\ G' \\ B' \end{bmatrix} = \begin{bmatrix} 1 & \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{2}} \\ 1 & \frac{1}{\sqrt{6}} & -\frac{1}{\sqrt{2}} \\ 1 & -\frac{2}{\sqrt{6}} & 0 \end{bmatrix} \begin{bmatrix} I \\ V_1 \\ V_2 \end{bmatrix}$$


#### 2. Fusion basée sur DWT (Discret Wavelet Transform)

L'algorithme de décomposition multi-résolution décompose une image en entrée en un ensemble d'images de détails et une image d'approximation. A chaque niveau de décomposition la taille des images transformées est réduite par un facteur de deux.



#### 3. Fusion basée sur NSCT (Non-Subsampled Contourlet Transform)

NSCT élimine les sous-échantillonnageurs et les échantillonneurs pendant la décomposition et la reconstruction de l'image; elle est construite sur les banques de filtres pyramidaux non sous-échantillonnées (NSPFB) et les DFB non sous-échantillonnées (NSDFB).



### Architecture & implémentation

- **IHS**: La transformée en IHS est appliquée sur les trois bandes : R, G et B. Les composantes H et S sont utilisées avec l'image Pan pour obtenir l'image RGB fusionnée, grâce à la transformée IHS inverse.

- **DWT**: La transformée en ondelettes est appliquée sur les deux images MS et PAN, suivi d'une fusion des coefficients des détails de PAN avec les coefficients de l'image MS et à la fin l'image reconstruite est obtenue par l'application de la transformée en ondelettes inverse sur l'image a coefficients fusionnée.

**NSCT**: La transformée NSCT est appliquée sur les images PAN et MS, puis différentes règles de fusion sont utilisées telque le max, la moyenne, le min...etc. A la fin la transformée NSCT inverse est appliquée sur les coefficients fusionnés pour obtenir l'image fusionnée.

La figure suivante, nous montre le déroulement de chaque méthode:




Fig.1: Les schémas des approches utilisées.

### Principaux résultats




Fig.2: exemple des trois approches appliquées sur Les images MS et PAN de la même scène .

IM 1	approche	CC	Var	SD	Q4	ERGAS	SAM	sCC	ZCC	TE
IM 1	IHS	0,832	0,659	0,077	0,725	2,153	3,234	0,785	0,981	0,708
	DWT	0,903	0,344	0,072	0,811	2,014	3,112	0,819	0,951	0,692
	NSCT	0,909	0,352	0,070	0,821	1,955	3,033	0,821	0,951	0,765
IM 2	IHS	0,832	0,659	0,077	0,725	2,153	3,234	0,785	0,981	0,708
	DWT	0,903	0,344	0,072	0,811	2,014	3,112	0,819	0,951	0,692
	NSCT	0,909	0,352	0,070	0,821	1,955	3,033	0,821	0,951	0,765
IM 3	IHS	0,833	0,521	0,045	0,641	1,823	1,728	0,885	0,945	0,689
	DWT	0,888	0,302	0,041	0,679	1,998	2,124	0,901	0,907	0,718
	NSCT	0,896	0,334	0,040	0,721	1,961	2,046	0,904	0,904	0,768
IM 4	IHS	0,762	0,673	0,063	0,598	2,217	3,589	0,837	0,961	0,602
	DWT	0,838	0,572	0,059	0,744	1,818	2,720	0,868	0,905	0,664
	NSCT	0,848	0,579	0,057	0,770	1,766	2,617	0,870	0,904	0,755

Fig.3: Le calcul des indices de qualité spatiale et spectrale .

### Conclusions

Dans des conditions idéales, une bonne méthode de fusion d'images tente de générer l'image qu'un capteur obtiendrait s'il avait la même réponse spectrale du capteur MS d'origine mais la résolution spatiale du capteur PAN. Après l'application des approches sur différentes sources images, et le calcul des différents indices de qualité spatiale et spectrale. La méthode IHS a une performance globale supérieure et fonctionne mieux que les autres en ce qui concerne à la fois la qualité spectrale et spatiale. Il convient à diverses images satellite, mais les analyses visuelles et quantitatives des résultats expérimentaux montrent que la méthode NSCT donne les meilleures images fusionnées en termes de coefficient de corrélation (CC), et l'erreur relative globale de synthèse (ERGAS).

### Perspectives

Le domaine de la fusion a toujours besoin de nouvelles approches et de nouveaux indices d'évaluation de la qualité de l'image fusionnée. D'après les résultats obtenus, nous recommandons vivement l'utilisation des approches basées sur l'analyse multi-résolution et de tester le résultat de ces dernières pour des post traitement tel que la classification, la segmentation, la détection des changements... etc, afin d'évaluer et de montrer l'influence de la fusion sur les résultats obtenus.



## Système immunitaire artificiel hybride pour la classification de données

SLIMANI AHMED<sup>(1)</sup> Rahmoun Abdellatif<sup>(2)</sup>

(1) A.slimani@univ-chlef.dz (2) A.rahmoun@esi-sba.dz

Laboratoire de Recherche en Informatique de Sidi Bel-Abbes : LabRI-SBA




### Introduction

La classification des données est le processus consistant à analyser des données structurées ou non structurées et à les organiser en catégories, en fonction du type et du contenu des fichiers. Plusieurs méthodes ont été appliquées pour résoudre ce problème par exemple des méthodes à base mathématiques comme les séparateurs à vaste marge (SVM) et les chaînes de Markov cachées. Ainsi que des méthodes inspirées de la biologie tels que les algorithmes génétiques et les systèmes immunitaires artificiels et des techniques inspirées du comportement des insectes sociaux par exemple, les algorithmes de colonies de fourmis et les algorithmes de colonies d'abeilles. dans cette représentation nous nous sommes intéressés aux approches de classification des Systèmes Immunitaires Artificiels.

### Le système immunitaire artificiel (SIA)


Les Systèmes Immunitaires Artificiels (SIA) sont des systèmes adaptatifs s'inspirant

- Théories
  - Fonctions
  - Principes
- modèles immunitaires Biologiques
- Appliqués à la résolution de problèmes de science et d'ingénierie tels que la classification.



- Structure de conception d'un système immunitaire artificiel adaptée par [dCT02a].

#### Algorithmes de classification par SIA



### les approches SIA hybrides

Le développement de systèmes intelligents à travers l'hybridation est l'une des tendances à venir. Ces techniques sont la combinaison de différentes approches d'apprentissage automatique telles que la logique floue, le calculs évolutionnaires, les réseaux de neurones artificiels (RNA), les algorithmes génétiques (AG) et les systèmes immunitaires artificiels. Le motif principal est de surmonter les limites de l'algorithme individuel, en combinant différentes techniques d'apprentissage et d'adaptation, par lesquels il est possible d'obtenir des effets de collaboration. Au cours des dernières années, les approches intelligentes sont utilisées pour le développement d'un grand nombre de nouveaux systèmes intelligents.

Le système SIA	Approche hybride	référence
Réseau immunitaire artificiel	Les algorithmes génétiques AG	[HYL97]
Sélection clonale	Logique floue	[NUCG03]
Réseau immunitaire artificiel	les algorithmes évolutionnaires	[VdCMVZ03]
sélection clonale	K-means	[XLT05]
Réseau immunitaire artificiel	swarm learning)	[FLT07]
AIS	SVM	[AKA11]
Sélection clonale	Median Filter	[RIM16]
Sélection clonale	Average Cells Clonal Al.Gorithm (AC-CLONALG)	[RIM16]

### Principaux résultats

Bases de données utilisées pour la classification du cancer du sein :

- Wisconsin Dagnostic Breast Cancer Database (WDBC) (30 att)
- Digital Database for Screening Mammography (DDSM) (22 att)

Algorithmes SIA	% Classification (WBCD)	% Classification (DDSM)
CLONALG	71.9	95.55
CSA	72.8	91.17
AIRS	90.3	82.15
CLONAX	93.4	94.25
MF-AIS	92.55	97.94
CCS-AIS	94.40	98.13

Comparaison des résultats avec d'autres algorithmes SIA

### Conclusions

Il existe de nombreuses possibilités d'approches hybrides, car il y a beaucoup de paradigmes à considérer. Les approches citées ci-dessus sont quelques exemples de la façon dont les SIA peuvent améliorer ou être améliorés par d'autres techniques pour la résolution de problèmes difficiles, quant à leur complexité (SIA), un seul algorithme peut ne pas être suffisant.

L'une des conclusions avec lesquelles nous nous sommes ressortis est que ces méthodes ont permis une nette amélioration des résultats de CLONALG, mais nécessitent des coûts de calcul non-négligeables.

### Perspectives

- S'intéresser aux deux autres volets des algorithmes immunitaires artificiels qui sont la sélection négative et les réseaux immunitaires artificiels, afin d'avoir une vue plus généralisée sur ces méthodes.
- Expérimenter plus profondément les formules de clonage et leur impact sur la pertinence des cellules mémoires et la rapidité de l'algorithme.
- L'hybridation des méthodes de SIA avec les nouvelles méthodes de Machine learning par exemple deep learning.



## PREDICTION DU TEMPS DE TRANSCODAGE VIDEO POUR L'EQUILIBRAGE DE CHARGE DANS LE CLOUD

Kherarba Mohamed

Univercité Hasiba Ben Bouali Chlef




### Introduction

L'utilisation des vidéos numérique sur internet a énormément augmenté au cours des dernières années en raison des progrès de la technologie de l'information, de la capacité de calcul et des réseaux de communication. Une vidéo peut être visualisée par plusieurs appareils, cependant ces appareils sont très variés en termes de logiciel et de matériels, ce qui nécessite une adaptation à chaque utilisateur. Pour atteindre cet objectif, des applications de traitement vidéo telles que le transcodage est de plus en plus déployées en tant que service dans des environnements basés sur le cloud. Cependant, la puissance de calcul requise pour faire le transcodage varie en fonction des caractéristiques de la vidéo d'entrée, des paramètres de traitement et des taux d'arrivée des demandes. Ces variations affectent de manière critique la gestion efficace des ressources informatiques et par conséquent, le coût de fonctionnement de ces services. En plus, étant donné que les infrastructures de cloud et de calcul distribué sont composées de processeurs à fréquence différente, ces services de traitement multimédia qui les utilisent doivent équilibrer la charge entre les nœuds exécutant le transcodage. Dans ce travail on s'est concentré sur la distribution de la charge entre l'ensemble des nœuds exécutant un transcodage vidéo, on a proposé un modèle de prédiction du temps de transcodage, et des algorithmes de distribution de la charge dans le but de les utiliser pour l'équilibrage de charge sur le cloud.

### Analyse et Conception

Le modèle de prédiction a pour but de prédire le temps de transcodage d'un segment vidéo en se basant sur un ensemble des caractéristiques extraites de la vidéo et un ensemble de paramètres de transcodage de la vidéo. Les étapes pour construire un modèle de prédiction sont illustrées dans la figure suivant.



Les étapes de construction du modèle de prédiction.

#### Construction du dataset:

Pour construire un modèle de prédiction de temps de transcodage efficace qui couvre le maximum des cas possibles, il nous faut un dataset très varié en termes de contenu et de caractéristiques, l'organigramme suivant résume les étapes de construction du dataset.



#### Analyse des caractéristiques des vidéos

Il existe plusieurs caractéristiques vidéo. Dans le modèle proposé, nous avons utilisé les descripteurs suivants.


- L'information spatiale (SI) : mesure la quantité d'information sur chaque frame.
- L'information temporelle (TI) : mesure la quantité d'information sur le segment video.
- Texture : parmi les paramètres de texture on a utilisé la GLCM (Gray Level Co-occurrence Matrix), il exprime le contraste, la corrélation, l'energy, homogeneity et entropy.
- Différence de frame déplacée (DFD) : il mesure la quantité de mouvement sur un segment vidéo.

#### Paramètres de transcodage cible

Paramètre	valeur
Codec	Vp9, H264, H265
Résolution	240p, 360p, 480p, 720p, 1080p, 2k, 4k
Bitrate	(700,300,100), (1000,400,100), ..., (51000,20000,500)
Frame rate	25, 30, 50, 60

### Architecture & implémentation

#### Architecture générale de système




#### Construction du dataset:


Après avoir analysé les caractéristiques et déterminé les paramètres de transcodage cible de la séquence, l'opération de transcodage est lancée, le temps de transcodage est mesuré durant cette étape

### Principaux résultats

#### Évaluation du modèle de prédiction :



#### Évaluation des algorithmes d'équilibrage de charge:



### Conclusions

Ce projet s'est attelé à la problématique du transcodage vidéo dans le cloud et particulièrement au calibrage de charge dans ce dernier. L'objectif étant de proposer une méthode permettant d'effectuer une distribution efficace des segments vidéo sur un ensemble de nœuds dans le cloud tout en maintenant un temps minimal de transcodage des segments.

De nombreuses solutions ont été proposées pour cette problématique. Nous avons proposé une démarche en deux étapes, la première réside dans la conception d'un modèle de prédiction du temps de transcodage de la vidéo, et comme deuxième étape l'exploitation de cette information pour l'équilibrage de la charge dans le système de transcodage.

### Perspectives

Comme travaux futurs, nous proposons d'introduire la notion d'élasticité en se basant sur l'analyse de la qualité d'expérience de l'utilisateur. D'une autre manière, le système pourra augmenter et réduire le nombre d'instances en fonction des besoins et ceci a fin de satisfaire l'utilisateur final. Aussi, nous envisageons de tester notre méthode dans un cloud public type Amazon (AWS).





# MACHINE LEARNING AND DEEP LEARNING FOR FACE RECOGNITION

Medjahed Chahreddine  
c.medjahed@univ-chlef.dz

UDYS-UHBC



## Introduction

Face recognition has become a popular topic of research recently due to increases in demand for security as well as the rapid development of mobile devices. This task can be divided into two sub-problems: face detection followed by face recognition. The objective of this work is to evaluate and compare various systems of face recognition based on speed and high accuracy machine learning algorithms. We propose three biometric systems. The first system use Gray-level co-occurrence matrix (GLDM) to extract features and feed-forward Neural Network (MLP) for classification. The second one is based on Local Binary Pattern (LBP) algorithm for extraction features and a Multi-layer perception (MLP) for the classification. These two precedent systems are based on "engineered" features. The third one is based on learned features using deep learning, in particular Convolutional Neural Networks (CNNs). The results are competitive.

## Analyse et Conception

□ The LBP algorithm is the most widely used in face recognition for extract features. This operator works with the eight neighbors of a pixel, using the value of this center pixel as a threshold. If a neighbor pixel has a higher gray value than the center pixel so one is assigned to that pixel, else it gets a zero. The LBP code for the center pixel is then produced by concatenating the eight ones or zeros to a binary code.

□ GLDM is a particular type of co-occurrence matrix obtained as the histogram on a 2D domain of dimension  $N_{GL} \times N_{GL}$ , where  $N_{GL}$  is the number of gray levels in the image (typically 256). In other words, the co-occurrence matrix counts the number of gray level transitions between two pixel values such that the bin of the histogram whose coordinates are equal to the values of the two pixels is incremented. The way pixel couples are determined depends on the two parameters,  $d$  and  $\theta$ . A value of  $d=1$  and  $\theta=0$ .

□ The feed forward neural network was the first and simplest type of artificial neural network devised. It contains multiple neurons (nodes) arranged in layers. Nodes from adjacent layers have connections or edges between them. All these connections have weights associated with them.

A feed forward neural network can consist of three types of nodes: Input Nodes, hidden Nodes and output nodes.

A Multi Layer Perceptron (MLP) contains one or more hidden layers. While a single layer perceptron can only learn linear functions, a multi layer perceptron can also learn non-linear functions.

□ A convolutional neural network (CNN) is a class of deep neural networks, most commonly applied to analyzing visual imagery. They are also known as shift invariant or space invariant artificial neural networks, based on their shared-weights architecture and translation invariance characteristics. They have applications in image and video recognition, image classification and natural language processing.

## Architecture & implémentation

□ We choose from the Put Database, the same available number of persons' images that correspond to 90 people. The used sub-set contains 7560 color images with different colors of background and different positions of face are used. All images are characterized by 2048 x 1536 as size and jpg format. These images represent 90 persons. Each person has 64 images for training and 20 images for validation and test, for each person  $((10+10+64)*90=7560$ . We have applied the BLP [26] feature extraction method on our dataset. We obtained vectors of 177 features for each image.

□ We propose three biometric systems. The first system use Gray-level co-occurrence matrix (GLDM) to extract features and feed-forward Neural Network (MLP) for classification. The second one is based on Local Binary Pattern (LBP) algorithm for extraction features and a Multi-layer perception (MLP) for the classification. These two precedent systems are based on "engineered" features. The third one is based on learned features using deep learning, in particular Convolutional Neural Networks (CNNs).




Figure : A Convolution Neural Network

## Principaux résultats




Figure : Neural Network training performance (GLDM)




Figure : Neural Network training performance (LBP)




Figure : Training progress with CNN.

	Time CPU(min)	Taux
LBP	108.06	97.29 %
GLDM	246.5425	97.83 %
CNN	301.47	99.61 %

Table : Performance of our Face Recognition Systems

## Conclusions

□ A good face Recognition system classifier would recognize faces in accuracy during adequate time despite the different face poses, uncontrolled illumination conditions, expression, and image quantity and quality.

In this work, we have adapted and tested empirically three systems of face recognition using MPL with LBP extracted features, then MLP with GLDM extracted feature and deep learning with the same quantity of data but in raw form.

The GLDM gives a good result compared to LBP in term of recognition rate. The Face Recognition system performance is further improved using the CNN.

In general, the experiments show that the systems of recognition assure good results, particularly for identifying faces acquired across varying conditions. We found these first results hopeful and encouraging.

## Perspectives

□ Among the perspectives of this work is to use other feature extraction algorithms such as HOG and SURF algorithms for the inputs of ML classifiers. In addition, we plan to evaluate other Machine deep learning neural network with more face data and hand data. The goal is to integrate the best ones on a final multi-biometric recognition system.



## Titre du poster

### Un système de navigation à base de la logique floue : Application sur un système multi robots

**Noms & prénoms des auteurs**



MEDJROUD Sarah

**Affiliations**  
Système Informatique

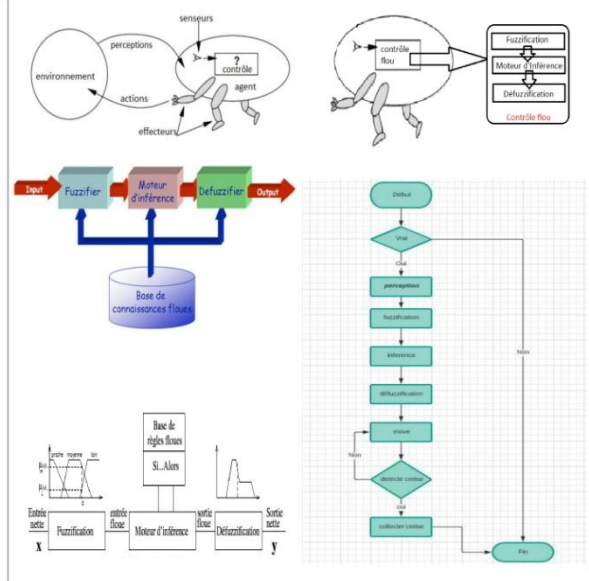
### Introduction

Actuellement, l'Intelligence Artificielle se déploie fortement dans tous les domaines, où sa vitesse de calcul et sa masse de connaissances dépassent déjà de loin les capacités du cerveau humain. Egalement, la machine devrait s'inspirer de notre cerveau le raisonnement et interagir de manière intelligente. Pour qu'une machine peut prendre une décision dans l'incertitude et imprécision, on a proposé une des méthodes pour gérer l'incertain : la logique floue. Notre contribution c'est d'intégrer un système de navigation floue dans le processus de décision d'un robot.

### Analyse et Conception

- Navigation : c'est d'aller de tel point à tel point
- Robot (agent physique): percevoir la distance, prendre une décision s'il va avancer directement et vite (tant qu'il n'y a pas d'obstacle) ou de l'éviter (tourner avec un certain angle et doucement)
- Ex: feu tricolore
  - SI le feu est rouge & je suis proche je réduits la vitesse
  - SI le feu est vert & je suis loin j'accélère
- Variables / données : distance - vitesse - angle
- Inputs : distance
- Outputs : vitesse - angle de rotation
- la distance est mesurer via les capteurs
- Système flou présente 3 étapes:
  - 1- Fuzzification: transformer une variable numérique à une variable floue  
Variable floue : caractérisée par un triplet (x: nom, T(x): valeurs floues, U: univers de discours)  
Ex: x: distance - T(x): (proche, moyenne, loin) - U: {0,100}m
  - 2- Moteur d'inférence : processus de décision  
R1: **Si** 'distance' est 'proche' **Alors** 'vitesse' est 'lente' et 'angle' est 'grand'
  - 3- Défuzzification : rendre la valeur floue en valeur numérique

### Architecture & implémentation



### Principaux résultats

- Un module d'un système flou :
  - En entrée (distance)
  - En sortie (vitesse & angle de rotation),
- Robot qui intègre ce module dans son cycle de vie,
- Simulation d'un système de navigation basé sur la logique floue,
- Meilleur comportement en comparant avec un robot qui intègre un raisonnement classique.

### Conclusions

Ce projet nous a permis de réaliser une application dont l'objectif est la simulation d'un système de navigation multi-robots en proposant l'intégration du raisonnement flou dans le système de navigation de robot.

### Perspectives

- Enrichir le système flou,
- Application dans un robot réel,
- Application dans autre domaines,
- Généraliser le système.



# Une approche dirigée par les modèles pour l'intégration du BIG-DATA



**BETTACHE Djelloul**  
Systèmes informatiques

## Introduction

L'évolution de la technologie à savoir les réseaux d'entreprises et l'utilisation de plusieurs applications informatique au sein d'une même organisation, a créé le besoin d'exploitation de plusieurs sources de données, sachant que ces sources peuvent être représentées sous différents modèles selon le besoin informatique et peuvent être distribuées, ceci entraîne une difficulté d'interrogation de ces sources hétérogènes par l'utilisateur. Les systèmes d'intégration offrent à l'utilisateur une possibilité d'exploitation de ces sources d'une manière transparente, c'est-à-dire comme s'il interagissait avec une seule source.

En effet, l'Ingénierie Dirigée par les Modèles (IDM) est un thème en pleine expansion aussi bien dans le monde académique que dans le monde industriel. Elle apporte un changement important dans la conception des applications en prenant en compte la pérennité des savoir-faire, des gains de productivité et en tirant profit des avantages des plateformes sans souffrir d'effets secondaires. L'architecture IDM se base sur la transformation de modèle pour aboutir à une solution technique sur une plateforme de notre choix à partir de modèles métier indépendants de toute plateforme.



Notre travail consiste à proposer une approche dirigée par les modèles pour l'intégration des données BIG DATA.

## Analyse et Conception

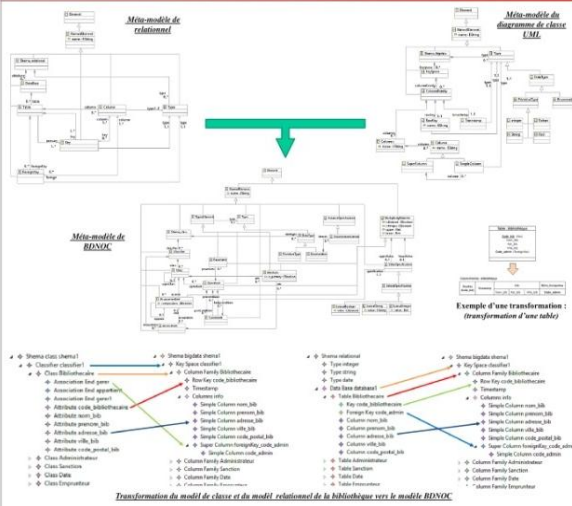
Notre travail porte sur la production automatique d'un schéma non relationnel à partir d'un diagramme de classes UML ou d'un schéma relationnel représentant un modèle du domaine. Les travaux sur le sujet se focalisent sur la richesse des types de structures de données offerts par les modèles objet et relationnel et étudient les possibilités de leur implantation dans le modèle non relationnel.

Notre objectif est de proposer une approche IDM basée sur le principe « tout est modèle » afin de valider et d'automatiser les règles de transformation des modèles objet et relationnel vers le modèle non relationnel. Pour y parvenir, nous avons élaboré trois méta-modèles : le méta-modèle d'un diagramme de classes UML et le méta-modèle relationnel jouant le rôle de méta-modèle source, et le méta-modèle d'une base de données NoSQL orientée colonnes (BDNOC) jouant le rôle de méta-modèle cible pour l'opération de transformation exogène de UML ou relationnel vers BDNOC.

Dans le cadre de ce travail, nous avons adopté une approche de transformation déclarative dont le principe de base consiste à établir des relations entre les éléments des modèles source et cible indépendamment de l'exécution. Chacune de ces relations représente une transformation élémentaire appliquée à un élément décrit conformément à son méta-modèle. La Figure 4.1 illustre les différents éléments impliqués dans notre transformation. Le moteur de transformation utilise le modèle objet (ou relationnel) reçu en entrée afin de générer un schéma non relationnel (BDNOC). Les deux modèles doivent être conformes à leurs méta-modèles respectifs qui peuvent être considérés à leur tour comme étant des entrées pour le moteur de transformation.



## Architecture & implémentation



Nous avons présenté un processus de transformation permettant de générer de manière automatique un modèle non-relational à partir de diagrammes de classes (ou d'un modèle relationnel). Notre contribution consiste à proposer une solution qui s'inscrit dans le cadre de l'approche MDA. La solution proposée consiste en une proposition des règles de transformation de chaque élément du méta-modèle de diagramme de classe UML (ou d'un modèle relationnel) et BDNOC pour réaliser la transformation du diagramme de classe (ou d'un modèle relationnel) au BDNOC après avoir établi le méta-modèle de diagramme de classe (ou d'un modèle relationnel) et de BDNOC.

## Principaux résultats

Nous avons proposé une approche IDM permettant de transformer la transformation des modèles objet et relationnel vers le modèle non relationnel. Pour y parvenir, nous avons élaboré trois méta-modèles : le méta-modèle d'un diagramme de classes UML, le méta-modèle relationnel, et le méta-modèle d'une base de données NoSQL orientée colonnes (BDNOC).

De plus, nous avons conçu et réalisé un programme Uml2BDNOC / Relationnel2BDNOC permettant de transformer un modèle source conforme au méta-modèle source vers un modèle cible conforme au méta-modèle cible. Notre programme est purement déclaratif et utilise avec profit les constructions déclaratives fournies par ATL. En outre, nous avons utilisé comme cas d'étude la gestion de la bibliothèque afin d'expérimenter et valider notre approche.

En outre, nous avons utilisé comme cas d'étude la gestion de la bibliothèque afin d'expérimenter et valider notre approche.

## Conclusions

Dans ce travail, nous avons présenté une approche pour l'intégration des données massives dans une base de données orientée colonne (NoSQL). Il s'agit d'une approche dirigée par les modèles fidèle aux principes de MDA définis par l'OMG. Elle permet au développeur de s'abstraire des difficultés liées à l'implémentation en travaillant sur les modèles de haut niveau, indépendants de la plateforme ou de la technologie d'implémentation cible.

## Perspectives

Les perspectives de ce travail peuvent être déclinées de la manière suivante:

- Dans le schéma général de notre approche, le niveau code n'a pas été intégré. Il serait intéressant de rajouter des processus de transformation pour passer du niveau PSM au code du système. Notons que ce processus est par essence spécifique à la plateforme d'implémentation.
- Améliorer éventuellement l'efficacité de notre programme en étudiant l'apport des patterns d'OCL (Object Constraint Language) pour la transformation de modèles.
- Vérifier davantage le programme en utilisant des techniques de vérification applicables sur des programmes de transformations de modèles : test structurel, analyse de mutation, problème d'oracle et analyse statique.
- Comparer l'approche classique de traduction dirigée par la syntaxe vis-à-vis de la transformation exogène de modèles.



# Reconnaissance Biométrique par Fusion Multimodale du Visage et de l'Iris



**MAABED Mohammed, BOUZEKRI braham, BOUSSAHBA Nassima**

*Université Hassiba Benbouali - CHLEF-*

**Résumé:**

La Biométrie multimodale consiste à utiliser plusieurs systèmes biométriques pour l'identification et/ou l'authentification d'un individu, la multi modalité permet de dépasser certaines limitation des systèmes basés sur une seule modalité tout en augmentant leurs performances. Dans ce travail, un système d'identification multimodale est implémenté en combinant les informations issues de deux traits biométriques à savoir le **visage** et l'**iris** au niveau score. la fusion de score est précédé d'une étape indispensable qui est la normalisation. L'étape d'extraction des caractéristiques utilisée est basée sur la méthode SURF (*Speeded Up Robust Features*), cette méthode est inspirée de la méthode SIFT (*scale-invariant feature transform*) qui est un descripteur de transformation de caractéristique invariant à l'échelle.


**1. Introduction:**

La biométrie vient des mots Grecs bios (vie) et metrikos (mesure ou distance), elle permet la reconnaissance automatique des personnes en utilisant leurs caractéristique physiologique et ou comportementale, la biométrie est un terme dont on entend parler souvent dans notre vie quotidienne, ils existent de nos jours plusieurs applications basant sur la biométrie telle que la délivrance et le contrôle d'identité avec des passeports et des cartes biométriques [1].

**2. Architecture d'un système Biométrique :**

Tout système biométrique doit avoir quatre modules à savoir :

- Module de capture :** ce module est responsable de l'acquisition des données biométriques d'un individu (peut être un appareil photo, un lecteur d'empreintes digitales, une caméra de surveillance, etc).
- Module d'extraction de caractéristiques :** ce module a comme entrée des données prises par le module de capture, et extrait l'information pertinente et fournit une nouvelle représentation des données, cette nouvelle représentation doit être unique pour chaque individu.
- Module de correspondance :** ce module faire la comparaison entre les données extraites avec le modèle enregistré dans la base de donnée du système et détermine le degré de similitude entre les deux.
- Module de décision :** vérifie l'identité affirmée par un utilisateur ou détermine l'identité d'une personne en basant sur le degré de similitude entre les caractéristiques extraites et le model stocké [2].



**3. Mode de Fonctionnement D'un Système Biométrique :**

On peut distinguer trois modes de fonctionnements qui peuvent être fournis par un système biométrique à savoir, l'**enrôlement**, l'**authentification** et l'**identification**.

**4. La biométrie Monomodale :**

Les biométries sont en réalité des systèmes de reconnaissance de formes, ces systèmes détermine l'authenticité des personnes en analysant les traits physiologiques et / ou comportementales possédés par ces personnes. [3]. Les systèmes biométriques monomodale utilisent une seule modalité à la fois, ces modalités peuvent être morphologiques (visage, les empreintes digitales, La rétine, la géométrie de la main et l'iris...etc.) ou comportement-



**5. La biométrie Multimodale :**


les systèmes monomodaux comportent certaines limitations qui ne leurs permettent pas toujours d'être utilisés de manière fiable et efficace pour effectuer la reconnaissance, cependant la combinaison d'information présentée par les différentes modalités peut permettre une authentification (ou identification) précise de l'individu [02], de plus la consolidation d'information offre de nombreux avantages [5] tels que : l'accroissement du nombre de dimensions de l'espace des observations, la réduction de l'ambiguïté des déductions ainsi que l'amélioration de la robustesse et la fiabilité du système.

**6. Les différents modes d'un système biométrique multimodal :**

On peut distinguer trois modes de fonctionnements d'un système biométrique multimodal à savoir : le mode **série**, le mode **parallèle** et le mode **hiérarchique**.

**A. Le mode série :**

Dans ce mode, la sortie d'un trait biométrique est employée pour réduire le nombre d'identités possibles avant l'utilisation du prochain trait biomé-




**B. Le mode parallèle:**

Contrairement à un mode de fonctionnement en série, le mode parallèle utilise les informations de multiples traits simultanément pour exécuter la reconnaissance.

**C. Le mode hiérarchique:**

Dans le mode hiérarchique, les classificateurs sont combinés dans une structure arborescente, ce mode est pertinent lorsque le nombre de classificateurs est important [6].

**7. Les niveaux de fusion:**



**8. Conception du système:**

**A. Choix de modalités:**

Comme nous l'avons mentionné précédemment on a choisit comme modalités L'**iris** et le **visage**. le choix du visage est argumenté par le fait que cette modalité est très acceptée par le public et ne demande aucune action de l'usagé, et pour l'iris cette modalité contient une grande quantité d'information lui permettant de discriminer même les vrais jumeaux.


**B. implémentation :**

**B 1 -extraction par ACP**

Les images originales peuvent être reconstruites par combinaison linéaire de cesvecteurs propres, on les appelle eigenfaces. transformée en ses composantes eigenfaces par une simple opération de projection



**B-2 extraction par surf :**




**C. La normalisation de scores:**

les scores issus des deux modalités sont normalisés à l'aide de la méthode MinMax donnée comme suit :

$$S'_{ik} = \frac{S_{ik} - \min(\{S_i\})}{\max(\{S_i\}) - \min(\{S_i\})}$$

**D. Méthode de fusion de scores:**

pour bien évaluer notre système nous avons utilisé trois méthodes de fusion différentes à savoir, la **somme**, le **produit** et la **somme pondérée** .



**9. Conclusion**

Dans ce travail, nous avons déployé un système multimodal, en combinant les informations issues de deux sources biométriques (iris, visage). Parmi les différents niveaux de fusion existants, nous avons choisi le niveau score, car il est d'une part complètement indépendant des algorithmes générant les scores de similarités, d'autre part il offre un meilleur compromis entre la facilité d'implémentation et la richesse d'information

**10. Références bibliographique:**

[1] ADIOUDI REDA. « Authentification Automatique par Identification &Reconnaissance dans un Système de Haute Sécurité » Thèse Doctorat 2006.  
 [2] Fabien Soyez, janvier 2013. Reconnaissance faciale : plus vraiment de la science-fiction. CNET France  
 [3] Nicolas MORIZET « Reconnaissance Biométrique par Fusion Multimodale du Visage et de l'Iris » 2009.  
 [4] A. Kumar, D.Wong,H. Shen, and A. Jain. "PersonalVerificationUsingPalmprintand Hand GeometryBiometric". In : Proceedings of Fourth International Conference on Audio- and Video-BasedAuthentication (AVBPA), pp. 668-678, Guildford, U.K., June 2003.  
 [5] Hafis Toufik« Reconnaissance Biométrique Multimodale basée sur la fusion en score de deux modalités biométriques : Empreinte digitale et la signature manuscrite cursive en lignes » 2016.



## Titre du poster

### Développement d'algorithme d'évitement d'obstacle dynamique dans un réseau de capture sans file


**Nom & prénoms des auteurs**  
Benhamada Abdelhak

**Affiliations**



### Introduction

La recherche dans le domaine robotique à intérêts industriels se concentre sur l'amélioration du degré d'autonomie du système robotique. Les robots sont conçus pour opérer dans différents conditions. Les systèmes de navigation autonome sont utilisés dans des applications comme les robots de services, de surveillance ou d'exploration où le robot se déplace et effectue la tâche principale. La robotique mobile est affrontée à plusieurs problèmes qu'on peut résoudre en utilisant des approches différentes. Un des problèmes majeur de la robotique mobile est le problème de planification de trajectoire et l'évitement d'obstacle.



### Analyse et Conception

#### L'organigramme de l'algorithme proposer



**d** : la distance mesurée entre l'obstacle et la camera  
**Seuil1** : spécifier pour l'état initial dont la distance est très proche d'un objet à éviter  
**Seuil2** : la distance idéal pour éviter l'obstacle par la décision « tourne à droite »

### Architecture & implémentation

#### Calibration de caméra

L'objectif principal de calibration est de calculer la matrice de caméra et l'utiliser pour mesurer la distance entre la caméra et un obstacle se trouve devant elle



Figure 1. le motif de calibration

#### La Détection et la localisation des obstacles

- La localisation: pour chaque objet présent dans l'image on calcule le hauteur, la largeur, point supérieur à gauche
- Localisation: limiter chaque objet par un rectangle




Figure 2. Localisation Figure 3. Détection

#### La mesure de distance

$$Distance = h_{px} * focal\_length / h_{cm}$$

- $h_{px}$ : la largeur de l'objet en pixel
- $h_{cm}$ : la largeur de l'objet en centimètre
- $Focal\_length$ : la distance focal de camera



Figure 4. Calcul de distance à 60 cm

### Principaux résultats

#### Caractéristique de l'environnement 1

taille de terrain :245cm \* 160 cm  
 Taille de l'objet :(11cm,30 cm)  
 Nombre d'objet :35  
 Le temps de l'expérience:2 minute  
 Les couleurs des objets: rouge , jaune, bleu  
 d:la distance idéal pour l'évitement



Figure .Environment 1




Figure 4. le résultat de l'expérience avec d=25




Figure 5. le résultat de l'expérience avec d=35

#### Caractéristique de l'environnement 2

Taille de terrain :135cm \* 150 cm  
 Taille de l'objet :(11cm,30 cm)  
 Nombre d'objet :30  
 Le temps de l'expérience:2 minute  
 Les couleurs des objets: rouge , jaune, Bleu



Figure .Environment 2




Figure 6. le résultat de l'expérience avec d=25




Figure 7. le résultat de l'expérience avec d=35

**Résultats** : les trois conditions qui sont : la vitesse, la distance et la taille de l'environnement ont un influence remarquable sur le résultat de notre algorithme

### Conclusions

Après avoir effectués plusieurs test et expérimentation sur notre Algorithme on conclue que pour développer un robot mobile il faut penser aux paramètres suivant:

- Traitement et architecteur CPU
- Espace mémoire
- Algorithme de faible complexité

### Perspectives

#### Comme perspective à ce travail:

- Améliorer le processus de détection de contour en minimisant le temps de calcul (en introduisant une deuxième plateforme en parallèles)
- Introduire des buts dans notre algorithme et proposer un chemin optimal
- Faire une communication sans file entre plusieurs robots et introduire la stéréo vision




# Une approche de migration des machines virtuelles pour la gestion des contrats SLA dans le Cloud Computing

## BELALIA Ghalia & MOULEY Karima



Ingénierie des systèmes d'information avancés

**Introduction**  
Le cloud computing permettant aux clients de fournir des ressources à la demande sur une base de paiement à l'utilisation .



La demande croissante des services basées sur les environnements du Cloud Computing fait provenir une augmentation de l'énergie consommée par les datacenters, ce problème critique . Dus aux coûts plus faibles des revenus des fournisseurs et des émissions de gaz CO2 **Comment réduire la consommation d'énergie sans affecter la qualité de service?**

**OBJECTIFS**

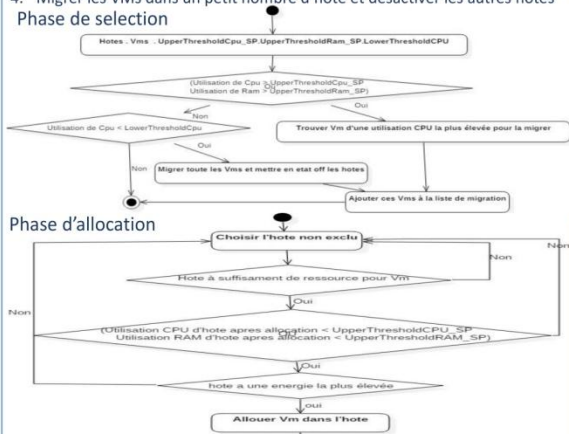
Trouver un compromis acceptable entre la réduction de la consommation d'énergie et l'amélioration de la QoS.

**Analyse et Conception**



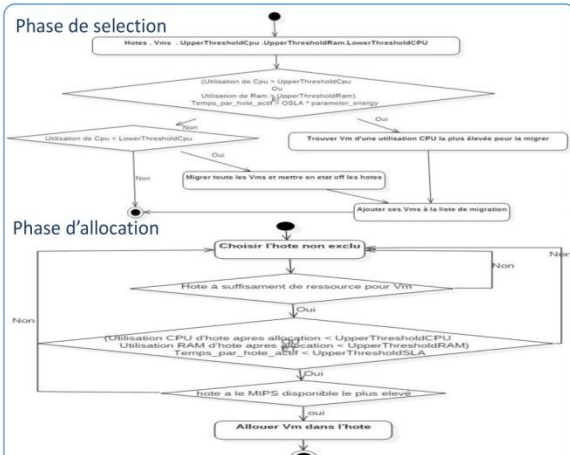
L'approche DRT (Double Resource Threshold)

1. Les seuils dynamique d'utilisation des ressources physique (CPU et RAM)
2. Intègre un paramètre de modération des taux d'utilisation .
3. Sélection VMs les plus gourmandes en CPU , et les placer dans l'hote (ne pas être surcharger après allocation),avec utilisation de CPU la plus grande
4. Migrer les VMs dans un petit nombre d'hote et désactiver les autres hotes




L'approche EET (Energy Efficiency Threshold)

1. Les seuils dynamique d'utilisation des ressources physique (CPU et RAM) « différents à les seuils de "DRT" », et un seuil SLA (le taux de violation SLA produit par chacune des hôtes)
2. Sélection des VMs les plus gourmandes en CPU , et les placer dans l'hote qui a une capacité MIPS disponible maximum .
3. Migrer les VMs dans un grand nombre d'hote .




**Principaux résultats**


**1. La consommation d'énergie**




**2. Violation de SLA globale**



**3. Nombre de migration**



**4. PDM**



**CONCLUSION**

Les résultats obtenus ont montré que l'approche DRT permet d'optimiser les taux de violations SLA tout en donnant des bons résultats en termes de consommation d'énergie , tandis que l'approches EET donne moins bons résultats en terme de consommation d'énergie.

**PRESPECTIVES**

Intégration d'autres paramètres dans le calcul de la consommation d'énergie comme : l'utilisation des disques durs, la bande passante, et les systèmes de refroidissement; Traitement de différents types de services et leurs priorités dans la gestion des taux de violations SLA.

# AUTHENTIFICATION ET IDENTIFICATION D'INDIVIDUS PAR RECONNAISSANCE DE CARACTERISTIQUES BIOMETRIQUES LIEES AUX VISAGES

*Chenaoui Ali, Bousahba Nassima  
Université Hassiba Ben Bouali - Chlef*

## 1. Introduction

La biométrie est un système de mesure qui permet d'identifier automatiquement un individu en se basant sur ses caractéristiques physiologiques ou comportementales. Dans un système biométrique, l'étape extraction des caractéristiques est la plus importante car les performances du système en dépendent. L'idée de ce travail est de faire une comparaison des méthodes d'extraction des caractéristiques sur des images biométriques (visage).

## 2. Architecture d'un système biométrique

Chaque système biométrique comporte deux phases d'exécution :  
**La phase d'apprentissage** : pour stocker les informations lors de l'ajout d'un nouvel utilisateur dans le système.  
**La phase de test** : pour déterminer l'identité de l'utilisateur soit pour une identification ou une authentification.

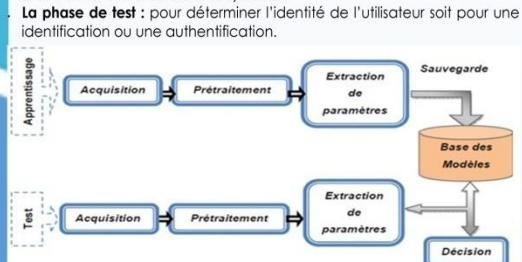


Figure 1: Architecture générale d'un système biométrique

## 3. Les modalités biométriques

**Tableau 2** : Comparaison entre les modalités biométriques en matière de précision, simplicité et acceptabilité[1].

Type	Modalité	Précision	Simplicité d'utilisation	Acceptation par l'utilisateur
Morphologique	visage	Moyenne	Haute	Haute
	Empreinte	Haute	Moyenne	Basse
	Iris	Haute	Moyenne	Moyenne
	Rétine	Haute	Basse	Basse
	Main	Moyenne	Haute	Moyenne
Comportementale	Voix	Basse	Haute	Haute
	Frappe au clavier	Basse	Haute	Moyenne
	Démarche	Basse	Moyenne	Moyenne
Cachée	signature	Basse	Moyenne	Haute
	ECG, EMG	Haute	Moyenne	Moyenne
	IRM du cerveau Imagerie par rayons X	Haute	Basse	Basse


## 5. Evaluation de performance du système

Dans la phase de décision, le paramètre qui nous permet de mesurer les performances du système est le taux d'identification correct (T.I.C) qui est la proportion du nombre de poses qui ont été identifiées sans erreurs.

Pour que l'évaluation donne des résultats fiables, on a développé un algorithme qui teste notre système dans tous les scénarios possible avec la base de données ORL (40 personnes, avec 10 poses pour chaque personne).

Pour le mode identification notre module d'évaluation a lancé 400 tests (40 personnes x 10 images) pour calculer le taux d'identification correct (TIC). Cette vérification est répétée avec différentes valeurs de seuil.

Lorsqu'un système fonctionne en mode vérification, celui-ci peut faire deux types d'erreurs. Il peut rejeter un utilisateur légitime et dans ce premier cas on parle de faux rejet (*false rejection*). Il peut aussi accepter un imposteur et on parle dans ce second cas de fausse acceptation (*false acceptance*).



## 6. Conclusion et perspectives

Dans ce travail, nous nous sommes intéressés au problème de la reconnaissance faciale. Nous estimons avoir réalisé un système répondant à l'objectif que nous nous sommes fixés au départ, à savoir la mise en œuvre d'un système permettant la reconnaissance d'individus et le contrôle d'accès. En guise de perspectives, une extension de ce travail peut être réalisée en intégrant un système d'acquisition des images pour éviter que ces opérations d'identification et de vérification soient de simples simulations. Par ailleurs, il serait aussi intéressant d'appliquer ce projet, dans un système de sécurité biométrique utilisant l'acquisition vidéo. Dans ce cas, on peut exploiter le module de détection et de poursuite des visages dans les séquences vidéo.

## 4. Conception et réalisation du système

Dans ce travail nous avons conçu deux systèmes d'identification biométrique du visage. Le premier est basé sur l'extraction des caractéristiques biométriques par une méthode globale classique à base de réduction d'espace : L'Analyse en Composantes Principales (ACP) et le deuxième basé sur une méthode locale récente pour la détection et la description des points clés d'une image appelée Speeded Up Robust Features (SURF).


Pour effectuer la méthode ACP, nous devons convertir un groupe d'images faciales (dans la base ORL il existe 400 images faciales prétraitées) à un ensemble de visages faciales propres : Eigenfaces qui représentent les principales différences entre les images d'apprentissage.

La reconnaissance revient à projeter une image sur le sous-espace ACP pour voir quel est le meilleur rapport de visages propres pour représenter cette image d'entrée.




L'extraction de caractéristiques par la méthode SURF (Speeded Up Robust Features) [2], comporte deux étapes :

- Extraction des points d'intérêts (Key points) et calcul des descripteurs (Good points).
- Matching des points d'intérêts.



Les caractéristiques qui définissent les points d'intérêt sont : la position dans l'image (x, y), l'angle et la taille du point d'intérêt qu'il exprime la résistance du point à la rotation.



La méthode de reconnaissance optimale est celle qui n'accepte pas les inconnus (taux de fausse acceptation FAR = 0) et qui ne rejette aucun des connus (taux de faux rejet FRR = 0). En réalité on ne peut pas avoir ceci, c'est pour cela qu'on cherche un seuil qui garantit à la fois un faible FRR et un faible FAR.

Pour trouver le seuil optimum, le module d'évaluation a lancé 16000 tests (400 images x 40 personnes) pour calculer le FAR et le FRR. Cette vérification est répétée avec différentes valeurs de seuil.

En remarque que le FAR et le FRR se comporte inversement par rapport au seuil.

Le taux d'erreur égal (EER) qui correspond au point FAR=FRR est égal à 0.94, c'est le seuil optimal de notre système.

## 7. Références bibliographiques

[1]: **Hafs T., 2016.** Reconnaissance biométrique multi-modale basée sur la fusion de en score.  
 [2]: **Bay H., Ess A., Tuytelaars T., Van Gool L., 2008** « Speeded-up robust features (SURF) », Computer Vision and Image Understanding.



# CONSTRUCTION DE L'ENSEMBLE DES ENTIERS NATURELS et leur Impact en Informatique

Abdenour Azzouz  
 Department Tronc Commun  
 Hassiba Benbouali University of Chlef, Algeria  
 Azzouz\_ena@yahoo.fr

Samir Boukabcha  
 Department Tronc Commun  
 Hassiba Benbouali University of Chlef, Algeria  
 S.boukabcha@hotmail.com

Fatma Zohra Belkredim  
 LMA Laboratory  
 Faculty of Exact Sciences and Informatics  
 Hassiba Benbouali University of Chlef, chlef,  
 Algeria  
 fbelkredim@univ-chlef.dz



## Introduction

En mathématiques, un entier naturel est un nombre positif permettant fondamentalement de dénombrer des objets comptant chacun pour un et donc de compter des objets considérés comme équivalents : un jeton, deux jetons... une carte, deux cartes, trois cartes... Un tel nombre entier peut s'écrire avec une suite finie de chiffres en notation décimale positionnelle (sans signe et sans virgule).




Chaque nombre entier a un successeur unique, c'est-à-dire un entier qui lui est immédiatement supérieur, et la liste des entiers naturels est infinie.



La définition originelle, due à Richard Dedekind, de l'ensemble des entiers naturels ne comprend pas le nombre zéro; plus récemment une autre définition a été proposée qui inclut zéro. Ces deux définitions coexistent encore aujourd'hui. Selon les acceptions, la liste des entiers naturels est donc :

- 1 ; 2 ; 3 ; 4 ; 5 ; 6 ; 7 ; 8 ; 9 ; 10 ; 11 ; ...
- ou
- 0 ; 1 ; 2 ; 3 ; 4 ; 5 ; 6 ; 7 ; 8 ; 9 ; 10 ; 11 ; ...



## Construction de l'ensemble N par la théorie des ensembles Von Neuman

Partant de la théorie des ensembles, on identifie 0 à l'ensemble vide, puis on construit un entier naturel. Tous les entiers naturels sont construits à partir des règles suivantes :

- L'ensemble vide est un entier naturel noté 0 ;
- Si n est un entier naturel, l'ensemble n U {n} est aussi un entier naturel, appelé le successeur immédiat de n ;
- Tout entier naturel est construit à partir des règles 1 et 2.

Par exemple, le successeur immédiat de 0 est : 0 U {0} = {0} = 1  
 Celui de 1 : 1 U {1} = {0} U {1} = {0,1} = 2  
 Celui de 2 : 2 U {2} = {0,1} U {2} = {0,1,2} = 3

- Et ainsi de suite

L'axiome de l'infini est nécessaire pour assurer l'existence d'un ensemble contenant tous les entiers naturels.

L'axiome de l'infini : l'axiome de l'infini est l'un des axiomes de la théorie des ensembles de Zermelo-Fraenkel, qui assure l'existence d'un ensemble infini, plus précisément d'un ensemble qui contient une représentation des entiers naturels.

Dans l'ensemble N ainsi construit, on peut définir l'addition de deux entiers +, leur multiplication \*, et la puissance ....


$$n + 0 = n; \quad n + (k + 1) = (n + k) + 1;$$

$$n \cdot 0 = 0; \quad n \cdot (k + 1) = (n \cdot k) + n;$$

$$n^0 = 1; \quad n^{k+1} = n^k \cdot n$$



Grappe de ensembles de nombres



## Construction de l'ensemble N par la méthode de Peano

La structure des entiers naturels a été axiomatisée pour la première fois par Peano et Dedekind à la fin du XIXe siècle. À cette époque zéro n'était pas considéré comme un entier naturel (et certains auteurs font encore ce choix), ce qui ne change pas fondamentalement l'axiomatisation. Ernst Zermelo, quand il a axiomatisé la théorie des ensembles, a montré que les entiers naturels pouvaient être définis en termes ensemblistes

### Axiomes

- La définition axiomatique des entiers naturels de Peano peut être décrite informellement par les cinq axiomes :
- 1. L'élément appelé zéro et noté 0 est un entier naturel.
- 2. Tout entier naturel n a un unique successeur, noté s(n) ou Sn.
- 3. Aucun entier naturel n'a 0 pour successeur.
- 4. Deux entiers naturels ayant le même successeur sont égaux.
- 5. Si un ensemble d'entiers naturels contient 0 et contient le successeur de chacun de ses éléments, alors cet ensemble est égal à N.

- Le premier axiome permet de poser que l'ensemble N des entiers naturels n'est pas vide, le troisième qu'il possède un premier élément et le cinquième qu'il vérifie le principe de récurrence.

De façon plus formelle, dire d'un triplet (E, c, f) qu'il satisfait à ces axiomes, c'est dire qu'il satisfait aux propriétés suivantes :

1. E est un ensemble, c est un élément de E,
2. f est une application de E dans lui-même,
3. c n'appartient pas à Im(f),
4. f est injective,
5. Toute partie F de E contenant c et stable par f (c'est-à-dire telle que f(F) ⊆ F) est égale à E.

- Le premier axiome permet de poser que l'ensemble des entiers naturels n'est pas vide, le second que le successeur est une fonction, le quatrième que cette fonction est injective, le troisième qu'il possède un premier élément (ces deux axiomes assurent que l'ensemble des entiers naturels est infini). Le cinquième est une formulation du principe de récurrence.

## Validation et Conclusion

A l'aide de cinq axiomes seulement, l'ensemble des nombres entiers naturels a été défini; et les opérations sur ces nombres. Nous vérifions l'existence et la nécessité de cette construction.

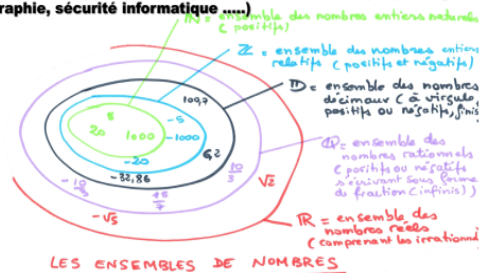
Axiome1 et Axiome2 permettent de donner une existence "discrète" aux entiers.

axiome3 sert à prouver que tout entier possède un prédécesseur et aussi que la relation ≤ est antisymétrique.

Axiome4 est indispensable pour la commutativité.

Axiome5 permet d'établir le théorème de récurrence, base de tout raisonnement dans N.

Il faudrait vérifier non pas qu'ils sont utiles, mais indispensables, mais ça c'est plus difficile. Il faudrait aussi s'assurer qu'il n'y a pas redondance, c'est à dire par exemple que P5 n'est pas un théorème démontrable à l'aide des quatre premiers axiomes; mais ça aussi .... L'ensemble des entiers naturels a permis des constructions et n'a pas dit son dernier mot: théorème de Godel et beaucoup de problèmes ouverts avec des Applications importantes en Informatique (codage, cryptographie, sécurité informatique ....)



## References

- <https://fr.wikipedia.org/>
- <http://www.les-mathematiques.net/>
- <https://www.techno-science.net/>



WIKIPEDIA