



THÈSE DE DOCTORAT
DE L'ÉTABLISSEMENT UNIVERSITÉ BOURGOGNE FRANCHE-COMTÉ
PRÉPARÉE À L'UNIVERSITÉ DE BOURGOGNE

École doctorale n° 37

Sciences Pour l'Ingénieur et Microtechniques

Doctorat d'Informatique

Par

Mme. ABOU JAMRA Hiba

**DÉTECTION ET INTERPRÉTATION DES SIGNAUX FAIBLES
DANS LES RÉSEAUX SOCIAUX NUMÉRIQUES**

Thèse présentée et soutenue à Dijon, le 6 Juin 2023

Composition du Jury :

M. BENSLIMANE Djamel	Professeur, Université Lyon 1 Claude Bernard	Président (Rapporteur)
M. HAMEURLAIN Abdelkader	Professeur émérite, Université Toulouse 3 Paul Sabatier	Rapporteur
M. ARDUIN Pierre-Emmanuel	Maître de Conférences, Université Paris-Dauphine	Examineur
Mme. COMYN-WATTIAU Isabelle	Professeur, ESSEC	Examineur
M. LECLERCQ Éric	Professeur, Université de Bourgogne	Co-directeur de thèse
Mme. SAVONNET Marinette	Maître de Conférences HDR, Université de Bourgogne	Directeur de thèse

Titre : Détection et Interprétation des signaux faibles dans les Réseaux Sociaux Numériques.

Mots clés : Signaux faibles, Réseaux Sociaux Numériques, Topologie du réseau, Graphlets.

Résumé : Les Réseaux Sociaux Numériques sont devenus des outils importants en raison de leur capacité à transmettre l'information plus rapidement que les médias traditionnels, dans différents domaines tels que la politique, le marketing, l'alimentation et, la santé, etc. Les organisations actuelles gérant des environnements complexes utilisent les réseaux sociaux comme un canal de communication afin de pouvoir interagir avec leurs clients et répondre aux besoins du marché. Un signal faible est une information peu visible, rare mais qui se diffuse rapidement, et dont l'interprétation par les experts métier peut déclencher une alerte. Dans ces environnements, l'identification des signaux faibles permet d'anticiper les discontinuités, de répondre aux menaces ou de saisir des opportunités. Dans cette thèse, nous proposons une nouvelle approche (BEAM) qui s'appuie sur la topologie d'un graphe d'interactions temporelles, pour la détection et l'interprétation des signaux faibles.

Nous avons choisi les graphlets comme outil opératoire pour donner une signature au signal faible. En effet, les graphlets répondent aux caractéristiques des signaux faibles : ce sont de petits patterns (fragments d'un graphe), qui pris seuls sont peu visibles, rares et de faible utilité apparente. Afin d'aider les experts métier dans leur prise de décision, nous proposons aussi des éléments contextuels d'interprétation des signaux faibles détectés. Nous avons réalisé des expérimentations sur sept jeux de données issus de plusieurs Réseaux Sociaux Numériques, afin de valider, vérifier la robustesse de BEAM et la reproduction des résultats avec des données périodiques. Les graphlets peuvent être considérés comme une signature d'un signal faible. Ils permettent à la fois d'automatiser la tâche de détection des signaux faibles tout en laissant place à l'interprétation par des experts métier.

Title : Detection and Interpretation of weak signals in online social networks.

Keywords : Weak signals, Online social networks, Network topology, Graphlets.

Abstract : Online Social Networks have become important tools due to their ability to transmit information faster than traditional media, in different fields such as politics, marketing, food and health, etc. Today's organizations managing complex environments use social networks as a communication channel in order to interact with their customers and respond to market needs. A weak signal is a piece of information that is not very visible, rare but spreads quickly, and whose interpretation by business experts can trigger an alert. In these environments, the identification of weak signals allows for anticipating discontinuities, responding to threats, or seizing opportunities. In this thesis, we propose a new approach (BEAM) based on the topology of a temporal interaction graph, for the detection and interpretation of weak signals.

We have chosen graphlets as an operational tool to give a signature to the weak signal. Indeed, graphlets meet the characteristics of weak signals : they are small patterns (fragments of a graph), which taken alone are not very visible, rare and of little apparent utility. In order to help business experts in their decision-making, we also propose contextual elements to interpret the detected weak signals. We carried out experiments on seven datasets from several Online Social Networks, in order to validate and verify the robustness of BEAM and the reproduction of results with periodic data. Graphlets can be considered as a signature of a weak signal. They allow both to automate the task of detecting weak signals while leaving room for interpretation by business experts.

REMERCIEMENTS

L'achèvement de ce travail réalisé sur plusieurs années apporte une grande satisfaction. C'est l'occasion de se remémorer les différents obstacles qu'il a fallu surmonter mais surtout les personnes qui m'ont aidé à y parvenir.

Tout d'abord, j'aimerais exprimer ma sincère gratitude à ma directrice de thèse Madame Marinette SAVONNET, pour le soutien continu qu'elle a apporté à mon doctorat, pour son engagement, sa patience et ses précieux conseils, qui ont été des éléments clés pour atteindre les objectifs de ce travail. Je tiens à remercier également Monsieur Éric LECLERCQ co-directeur de thèse, pour m'avoir accueilli au sein de l'équipe des Sciences des données du laboratoire LIB et pour sa réflexion scientifique.

Je voudrais remercier les membres du jury pour l'intérêt qu'ils ont porté à évaluer mon travail de thèse :

- Monsieur Djamal BENSLIMANE, Professeur à l'Université Lyon 1 Claude Bernard ;
- Monsieur Abdelkader HAMEURLAIN, Professeur émérite à l'Université Toulouse 3 Paul Sabatier ;
- Monsieur Pierre-Emmanuel ARDUIN, Maître de conférence à l'Université Paris-Dauphine ;
- Madame Isabelle COMYN-WATTIAU, Professeur à l'ESSEC.

C'est un honneur de présenter mes travaux devant ce jury.

J'adresse notamment mes remerciements au projet Cocktail qui a financé cette thèse, et à tous ses membres avec lesquels j'ai eu la chance de travailler durant ces années.

Je suis également reconnaissante envers mes collègues doctorants de l'équipe des Sciences des données du laboratoire LIB, pour leur soutien continu, leur gentillesse et tous les moments exceptionnels que nous avons vécu ensemble. Je souhaite aussi exprimer ma gratitude envers toutes les personnes avec lesquelles j'ai collaboré pour la réalisation de ce travail de thèse. Leur participation active, directe ou indirecte, a été d'une grande importance et a contribué à la réussite de ce travail.

Je souhaite remercier spécialement Antonio pour son écoute, son encouragement et sa patience tout au long de la thèse.

Finalement, je tiens à exprimer toute ma gratitude à mes parents, mes frères et sœur, Joe, Nicolas et Nicole pour leur soutien continu durant les moments les plus difficiles et tout le long de cette thèse, et sans lesquels je n'en serais pas là aujourd'hui.

À mes parents, mes frères et ma sœur ...

TABLE DES MATIÈRES

I	Contexte et Problématiques	1
1	Introduction	3
1.1	Cadre de la thèse	3
1.1.1	Contexte général	3
1.1.2	Cadre de travail	5
1.2	Objectifs et problématiques de la thèse	6
1.3	BEAM : une méthode d'identification des signaux faibles	8
1.3.1	Détection des signaux faibles	8
1.3.2	Interprétation des signaux faibles	9
1.3.3	Évaluation de la méthode	9
1.4	Plan du manuscrit	10
2	État de l'art	13
2.1	Signal faible : une notion multi-facettes	14
2.1.1	Description de la notion de signal faible : des définitions et des termes pluriels	15
2.1.2	Spécificités des signaux faibles et modèle tri-dimensionnel de Hiltunen	17
2.1.3	Cycle de vie d'un signal faible	19
2.2	Différentes méthodes d'identification d'un signal faible	20
2.2.1	Méthodes basées sur les techniques de Traitement Automatique des Langues	22
2.2.2	Méthodes basées sur des algorithmes de Machine Learning	31
2.2.3	Méthodes basées sur les graphes	34
2.2.4	Méthodes basées sur les réseaux bayésiens	36
2.3	Synthèse et conclusion	38
II	Contributions	41
3	BEAM : Étape de détection des signaux faibles	43

TABLE DES MATIÈRES

3.1	Graphlets	45
3.1.1	Définitions des notions de graphlets et d’orbites	45
3.1.2	Énumération des graphlets	47
3.1.3	Choix de l’algorithme pour l’énumération des graphlets	50
3.2	Préparation des données	52
3.2.1	Présentation des données brutes	52
3.2.2	Nettoyage et filtrage de données : construction du corpus d’étude . . .	53
3.2.3	Structure et temps : construction de snapshots de graphes	54
3.3	Signature d’un signal faible	56
3.3.1	Mise en place de l’outillage nécessaire à la détection des signaux faibles	56
3.3.2	Estimation du renforcement du signal : diffusion et amplification . . .	58
3.3.3	Identification des précurseurs	59
3.4	Détection des signaux faibles	61
3.5	Confirmation par une méthode statistique : cross-correlation	62
3.6	Synthèse et conclusion	65
4 BEAM : Étape d’interprétation des signaux faibles		67
4.1	Points de vue pour interpréter les signaux faibles	68
4.1.1	Point de vue séquence de snapshots	68
4.1.2	Point de vue snapshot	70
4.1.3	Point de vue nœud	72
4.2	Visualisation de données	73
4.3	Implémentation d’un <i>Proof of Concept</i>	75
4.4	Synthèse et conclusion	79
5 Évaluation de la méthode BEAM		81
5.1	Validation au moyen d’une vérité de terrain	83
5.1.1	Visite surprise du Président Macron à l’usine Lubrizol	83
5.1.2	Agression dans un groupe de babouins	94
5.2	Validation par contre-exemple	100
5.2.1	Cas d’évènements prévus et répétitifs : école primaire	100
5.2.2	Cas où le contexte n’est pas connu : Facebook et MathOverflow . . .	102
5.3	Étude de la reproduction de résultats avec des données périodiques	103
5.3.1	Description des données brutes et construction du corpus d’étude . . .	103
5.3.2	Étude du premier épisode	104
5.3.3	Étude du deuxième épisode	113
5.3.4	Suivi de comptes porteurs de signaux faibles dans la huitième saison de GOT	115
5.4	Étude de la sensibilité de la méthode	117
5.4.1	Visite surprise du Président Macron à l’usine Lubrizol : graphe des retweets	117
5.4.2	Visite surprise du Président Macron à l’usine Lubrizol : espace des hashtags	118
5.4.3	Game of Thrones : espace des hashtags dans le premier épisode . . .	121
5.5	Synthèse et conclusion	126

TABLE DES MATIÈRES

III	Conclusion et perspectives	129
6	Conclusion Générale	131
6.1	Bilan	131
6.2	Perspectives	132
6.2.1	Perspective à court terme	133
6.2.2	Perspectives à plus long terme	135
IV	Annexes	137
A	Compléments sur les graphlets	139
A.1	Mesures sur les graphlets	139
A.2	Utilisation des graphlets dans des domaines connexes	140
B	Prise en compte de la dimension temporelle dans les graphes	143
C	Expérimentations sur l'impact du changement de la taille des snapshots	145
C.1	Jeu de données Lubrizol : graphe des mentions	145
C.2	Jeu de données GOT : graphe des retweets	146
D	Expérimentation sur l'annonce de la Politique Agricole Commune (PAC)	151
E	Tweets originaux annonçant la visite du Président Macron à Lubrizol	153
F	Résumé sous forme algorithmique de la détection des signaux faibles	157
G	Expérimentations sur l'utilisation de la SVD et du clustering pour détecter des variables latentes	161
G.1	Jeu de données Lubrizol	161
G.2	Jeu de données GOT	162
H	Publications Scientifiques	165

TABLE DES FIGURES

1.1	Réponses aux questions de recherche traitées dans notre thèse.	10
2.1	Impact d'une menace ou d'une opportunité sur les profits d'une entreprise, extrait de [8].	14
2.2	Modèle tri-dimensionnel proposé par Hiltunen, extrait de [82].	18
2.3	Cycle de vie des signaux faibles.	20
2.4	Processus d'identification de mots-clés signaux faibles avec les quatre familles de techniques employées.	21
2.5	Classification du signal dans une matrice BCG.	25
2.6	Construction des chaînes de thèmes au cours du temps.	27
2.7	Tableau de bord d'identification des signaux faibles, extrait de [107].	37
3.1	Les grandes étapes de notre méthode BEAM.	44
3.2	Deux graphes G et G' isomorphes et leur bijection ϕ	45
3.3	Représentation des trente graphlets et des soixante-treize orbites allant de 2 à 5 nœuds.	46
3.4	Extrait de graphlets orientés jusqu'à la taille quatre et leurs orbites, extrait de [10].	47
3.5	Relations entre les orbites O_9 et O_{12} et le graphlet G_1	49
3.6	Temps de réponse d'Orca avec des graphes de 200 nœuds dont la densité croît.	51
3.7	Construction du corpus de l'étude à partir des données brutes.	53
3.8	Représentations possibles à partir d'une liste d'interactions à trois composantes.	54
3.9	Représentation des interactions temporelles sous forme de s snapshots.	55
3.10	Renforcement du signal inspiré du modèle tri-dimensionnel de Hiltunen.	56
3.11	Résumé des calculs sur les graphlets, des vitesses et des accélérations pour les snapshots de l'étude.	59
3.12	Structure des cartes d'émergence de graphlets.	60
3.13	Exemple de quatre cartes d'émergence de graphlets.	61
3.14	Corrélogramme montrant une corrélation positive avec un décalage négatif entre X et Y_x [33].	64
3.15	Resumé de l'étape de détection de la méthode BEAM.	66

TABLE DES FIGURES

4.1	Deux représentations de l'évolution du nombre de graphlets entre deux snapshots consécutifs.	68
4.2	Représentation des données à l'aide d'un cube.	69
4.3	Trois formes différentes pour visualiser des instances de graphlets sur la base <i>Neo4j</i>	72
4.4	Exemple de la visualisation point de vue nœud sous forme de graphe.	74
4.5	Options de visualisation des données proposées par BEAM.	75
4.6	Architecture du <i>Proof of Concept</i>	75
4.7	Diagramme de classes modélisant les objets utilisés par BEAM et leurs relations.	76
4.8	« Pseudo-schéma » graphe représentant le corpus d'étude.	77
4.9	Maquette d'interface utilisateur pour un snapshot particulier, à droite, un panneau historique pour tous les snapshots étudiés.	78
4.10	Capture d'écran d'un notebook Jupyter.	78
5.1	Premiers tweets relatifs à l'incendie de Lubrizol.	83
5.2	Graphlets précurseurs identifiés <i>via</i> la carte d'émergence pour le snapshot étudié.	86
5.3	Séries temporelles du nombre des mentions et du graphlet G_{11} signal faible, le jour de la visite.	87
5.4	Corrélogrammes des graphlets G_{11} signal faible, et G_{22} pour la période étudiée.	87
5.5	Cube représentant les données sur les utilisateurs.	89
5.6	Une instance du graphlet G_{10} mise en évidence parmi les six instances, dans le snapshot de 16 heures 30 minutes.	91
5.7	Une instance du graphlet G_{14} et les mentions, dans le snapshot de 16 heures 30 minutes.	91
5.8	Exemple de classification de tweets dans les trois catégories.	93
5.9	Communautés détectées par l'algorithme de Louvain appliqué sur le graphe global représentant les mentions.	93
5.10	(a) Babouins portant le collier (b) Intérieur d'un capteur et sa batterie (extrait de [67]).	95
5.11	Graphlets précurseurs identifiés <i>via</i> la carte d'émergence pour le snapshot étudié.	96
5.12	Séries temporelles des interactions et de deux graphlets, sur quelques snapshots de l'étude.	97
5.13	Positions des nœuds dans des instances des cinq graphlets signaux faibles entre 8 heures et 8 heures 30.	99
5.14	Deux communautés obtenues dans le jeu de données issues des capteurs avec l'algorithme de Louvain.	100
5.15	Carte d'émergence des graphlets montrant les précurseurs sélectionnés dans le snapshot de 17 heures.	105
5.16	Corrélation du graphlet G_{13} signal faible avec les retweets dans le premier épisode de GOT.	105
5.17	Quelques tweets publiés le jour de la diffusion du premier épisode de GOT autour du snapshot de 17 heures par des fans de golf et de GOT.	107
5.18	Tweet de @TylerIAM et sa viralité.	107
5.19	Plusieurs instances du graphlet G_9 signal faible avec @TylerIAM, dans le snapshot de 17 heures.	108
5.20	Instances du graphlet G_{13} signal faible dans le snapshot de 17 heures.	109

TABLE DES FIGURES

5.21	Diagrammes en radar montrant quelques utilisateurs appartenant aux graphlets signaux faibles à 17 heures.	110
5.22	Instances du graphlet G_9 dans le snapshot de 19 heures.	111
5.23	Tweet de @JeffMillerTime.	111
5.24	Communautés les plus importantes obtenues avec l’algorithme Louvain. . . .	112
5.25	Tweet viral de Lucas Baini	113
5.26	Tweet viral de @ohmytargaryen.	114
5.27	Instances des graphlets signaux faibles G_5 et G_{10} détectés dans le snapshot de 19 heures du deuxième épisode.	114
5.28	Diagramme Sankey montrant l’évolution des utilisateurs participant aux signaux faibles, sur les six épisodes de GOT.	116
5.29	Diagramme en bâtons pour montrer l’évolution des utilisateurs participant aux signaux faibles, sur les six épisodes de GOT.	117
5.30	Illustration d’un exemple de co-occurrence de hashtags.	118
5.31	Instances de G_2 graphlet signal faible avec le hashtag #rem et ses co-occurents.	120
5.32	Mise en récit par @AlexandreQuiec de la visite présidentielle à Lubrizol.	121
5.33	Hashtags et emoji de Game of Thrones.	122
5.34	Séries temporelles des co-occurrences des hashtags, et celles de deux graphlets signaux faibles, pour quelques snapshots du premier épisode de GOT.	123
5.35	Deux instances des graphlets signaux faibles G_{12} et G_{19}	125
5.36	Tweet citant GOT et le tournoi de Golf.	125
5.37	Relation entre hashtags et utilisateurs appartenant aux signaux faibles.	126
6.1	Étapes suivies pour faire apparaître des variables latentes.	134
A.1	Graphe G , nombre de graphlets de taille 2 et 3 et les mesures GDV et GDD, inspirée de [12].	140
B.1	Représentations temporelles étiquetées sur les liens et les nœuds du graphe statique.	144
B.2	Flot de liens du graphe statique de la figure B.1.	144
C.1	Appartenance des utilisateurs à quatre instances de G_4 et de G_{11} signaux faibles, ayant différentes valeurs de Δt	147
C.2	Appartenance des utilisateurs aux instances du G_{21} signal faible, pour trois valeurs de Δt	149
D.1	Corrélogramme du graphlet signal faible G_{15}	152
E.1	Tweet émis par @jeremychatet.	154
E.2	Tweets émis par @Tendanceouest76.	154
E.3	Tweet émis par @ViolaineGargala.	154
E.4	Tweets émis par @paris_normandie.	154
E.5	Tweets émis par @76actu.	155
E.6	Tweets émis par @JeromeMoriniere.	155
G.1	Différentes positions de @76actu dans deux instances des graphlets G_{10} et G_{11} signaux faibles.	162

TABLE DES FIGURES

G.2 Visualisation des quatre clusters d'utilisateurs dans le snapshot de 17 heures
du premier épisode. 163

LISTE DES TABLEAUX

1.1	Analyse des données sur différents niveaux de granularité.	6
2.1	Spécificités d'un signal faible versus information courante, extrait de [120]. . .	18
2.2	Utilisation de la méthode développée par Yoon [191] dans divers travaux. . .	25
2.3	Identification des signaux faibles utilisant la LDA.	29
2.4	Détection des signaux faibles avec des mesures de centralité.	36
3.1	Nombre de graphlets non orientés et orientés ainsi que leurs orbites respectives en fonction de leur taille.	47
3.2	Résumé des algorithmes présentés d'énumération de graphlets.	50
3.3	Extrait de l'expérience menée pour mesurer le comportement d'Orca sur des graphes dont le nombre d'arêtes est fixé.	52
3.4	Exemple d'interactions.	53
3.5	Exemple des trente graphlets énumérés pour les s snapshots de l'étude.	57
3.6	Exemple des valeurs normalisées des graphlets, de leur vitesse et accélération pour les snapshots de la période d'étude.	58
3.7	Classification des graphlets dans quatre catégories.	62
3.8	Définitions conceptuelle et opérationnelle des critères caractérisant les signaux faibles.	65
4.1	Extrait du résultat d'une requête avec la clause ROLLUP sur le cube de données de la figure 4.2.	70
4.2	Approche macroscopique d'un snapshot.	71
4.3	Exemple de la visualisation point de vue nœud sous forme de tableau.	73
5.1	Indicateurs globaux calculés à partir du corpus de l'étude de Lubrizol.	84
5.2	Top cinq des graphlets qualifiés de signaux faibles dans le snapshot étudié. . .	86
5.3	Positions (orbites) des comptes Twitter importants apparaissant dans les ins- tances de trois graphlets signaux faibles pour le snapshot étudié.	88
5.4	Tweets annonçant quelques heures à l'avance, la venue du Président Macron à Rouen le 30 octobre. L'annexe E montre ces tweets.	92
5.5	Extrait du fichier de données des interactions entre babouins collectées par les capteurs.	96

LISTE DES TABLEAUX

5.6	Top cinq des graphlets qualifiés de signaux faibles dans le snapshot de 8 heures.	97
5.7	Extrait du fichier de données des interactions entre babouins observées par un humain.	98
5.8	Extrait du fichier brut des données de l'école primaire.	101
5.9	Top-5 graphlets détectés signaux faibles dans le snapshot de 17 heures - 17 heures 10 minutes.	104
5.10	Extrait des nœuds importants appartenant aux orbites du graphlet G_9 , et leur classement PageRank pour le snapshot de 17 heures.	106
5.11	Top cinq graphlets signaux faibles détectés dans deux autres snapshots du premier épisode.	110
5.12	Signaux faibles détectés dans trois snapshots du deuxième épisode.	113
5.13	Apparition d'utilisateurs dans les signaux faibles, épisode par épisode.	115
5.14	Propriétés globales du graphe de co-occurrence des hashtags, avec la liste des signaux faibles identifiés par BEAM. $ V _G$, $ E _G$, $ V _S$ et $ E _S$ sont le nombre de nœuds et de liens respectivement dans le graphe global et le snapshot étudié.	119
5.15	Résultats de corrélation entre les séries temporelles de deux graphlets et celles des interactions correspondant aux co-occurrences des hashtags.	119
5.16	Trois co-occurrences du hashtag #rem dans le graphe hashtag-hashtag.	120
5.17	Graphlets signaux faibles identifiés dans le snapshot de 17 heures à 17 heures 10 minutes.	121
5.18	Liste des top trois co-occurents de #GameofThrones avec leur fréquence d'apparition.	123
5.19	Hashtags occupant des orbites de G_{12} et G_{19}	124
C.1	Lubrizol : top-5 graphlets signaux faibles détectés entre 16 heures et 17 heures, en faisant varier la durée du snapshot. $ V $ et $ E $ correspondent aux nombres de nœuds et de liens dans les sous-graphes de chaque snapshot, et D leur densité.	146
C.2	GOT : top cinq graphlets signaux faibles détectés entre 17 heures et 18 heures, en faisant varier la durée du snapshot. $ V $ et $ E $ correspondent aux nombres de nœuds et de liens dans les graphes de chaque intervalle, et D leur densité. .	148
C.3	Participation des graphlets signaux faibles dans les snapshots de l'étude.	148
D.1	Caractéristiques topologiques du graphe étudié. $ V $ est le nombre de nœuds, $ E $ le nombre de liens, d_{mean} le degré moyen d'un nœud, Δ le degré maximum et D sa densité.	151
G.1	Trois clusters d'utilisateurs parmi les cinq clusters obtenus avec l'algorithme K-means.	162

Première partie
Contexte et Problématiques

INTRODUCTION

Sommaire

1.1	Cadre de la thèse	3
1.1.1	Contexte général	3
1.1.2	Cadre de travail	5
1.2	Objectifs et problématiques de la thèse	6
1.3	BEAM : une méthode d'identification des signaux faibles	8
1.3.1	Détection des signaux faibles	8
1.3.2	Interprétation des signaux faibles	9
1.3.3	Évaluation de la méthode	9
1.4	Plan du manuscrit	10

CETTE thèse, réalisée au sein de l'équipe Sciences des Données du Laboratoire d'Informatique de Bourgogne, a pour objectif la détection et l'interprétation des signaux faibles dans les Réseaux Sociaux Numériques. Dans ce chapitre d'introduction, nous présentons tout d'abord le contexte général de la thèse, ses motivations et son cadre de réalisation avec le projet iSite Cocktail. Ensuite, nous présentons nos objectifs, les problématiques et nos contributions, et finalement le plan du manuscrit.

1.1 Cadre de la thèse

1.1.1 Contexte général

Actuellement, le Web est devenu un important moyen de communication où des plateformes de partage de connaissances, comme les réseaux sociaux, se sont développées. Un réseau social consiste en un groupe d'individus ou d'organisations reliés par des centres d'intérêt, des relations professionnelles ou personnelles. Les Réseaux Sociaux Numériques permettent de rassembler des millions de personnes et de renforcer leurs relations et leurs échanges avec de nouvelles formes de coopération et de communication. Il existe plusieurs types de Réseaux Sociaux Numériques, comme les plateformes généralistes avec Twitter et Facebook, les plateformes professionnelles comme LinkedIn, et les plateformes de partage de médias avec par

exemple Youtube, Flickr, etc.

Ces réseaux font l'objet de recherche en sciences politiques avec par exemple le projet Politoscope¹, en sciences de la communication, en économie, en marketing, en informatique, mais aussi en sociologie où ils ont presque supplanté les outils classiques de sciences sociales comme les entrevues et les questionnaires. Ils fournissent un volume important de données grâce aux interactions entre individus qui, lorsqu'elles sont analysées et exploitées peuvent conduire à une valeur ajoutée importante. En général, l'exploitation de ces réseaux se concentre sur la détection de communautés, la prédiction de liens, l'analyse de sentiment des utilisateurs, la classification d'utilisateurs, la construction de profil utilisateur pour caractériser leurs compétences et connaissances, l'analyse de leur influence, mais aussi pour détecter, expliquer ou anticiper des événements, etc. [179]. En effet, des tendances ou des événements émergent plus rapidement à travers les Réseaux Sociaux Numériques qu'à travers d'autres médias plus traditionnels comme les sites Web, la radio, la télévision ou les journaux [3]. Par exemple, Jane Jordan-Meier dans [96] relate le rôle de Twitter dans la diffusion de l'information concernant l'amerrissage d'un avion sur le fleuve Hudson en janvier 2009. Le premier tweet, « *There's a plane in the Hudson. I'm on the ferry going to pick up the people. Crazy* » accompagné d'une photographie, est envoyé par Janis Krum à ses 170 abonnés. Trente-deux minutes après ce tweet, les médias traditionnels commencent à diffuser et à signaler l'incident². Twitter est considéré comme un révélateur d'événements importants souvent quelques minutes ou heures après qu'ils se soient produits [59] et comme une chambre d'écho dans laquelle les utilisateurs sont exposés aux opinions en accord avec leurs propres points de vue (bulle de filtre). Cet effet de résonance amplifie les événements et par là même influence les politiques publiques, industrielles et les comportements des utilisateurs.

Les Réseaux Sociaux Numériques jouent un **rôle informatif et préventif important par la diffusion d'informations et d'alertes**. Au Japon, suite au tsunami de mars 2011, la communication sur les Réseaux Sociaux Numériques a facilité les alertes publiques mais a aussi été une aide précieuse dans la localisation des personnes disparues [84]. Tien et al. [182] ont étudié l'utilisation de Twitter lors du rassemblement « Unissons la droite » à Charlottesville en 2017³. Durant ce rassemblement, il y a eu des affrontements violents qui ont entraîné la mort d'un manifestant causée par un accident de voiture intentionnel. L'étude de l'utilisation du hashtag #Charlottesville via le retweet montre que Twitter a joué un rôle informatif et que le réseau s'est fortement polarisé. En janvier 2017, une jeune fille de 14 ans a filmé son suicide sur le Live de Facebook⁴. Une amie voyant la vidéo, a alerté la police qui n'est pas arrivée à temps pour sauver l'adolescente. Suite à ce drame, des plateformes comme Facebook et Twitter ont travaillé sur la prévention du suicide, en créant de nouveaux systèmes d'alerte conçus pour mieux identifier et signaler les personnes à risque⁵.

Les Réseaux Sociaux Numériques sont devenus un outil indispensable pour **anticiper des événements ou pour les expliquer a posteriori**. Dans [13], les auteurs proposent une méthode

1. <http://politoscope.org>

2. <https://www.cnbc.com/2014/01/15/the-five-year-anniversary-of-twitthers-defining-moment.html>

3. https://fr.wikipedia.org/wiki/Manifestation_%C2%AB_Unite_the_Right_%C2%BB_%C3%A0_Charlottesville

4. <https://www.linfo.re/monde/amerique/710950-etats-unis-une-adolescente-filme-en-direct-sur-facebook-son-suicide>

5. Article dans le journal *Scientific American* : <https://www.scientificamerican.com/article/can-facebooks-machine-learning-algorithms-accurately-predict-suicide/>

1.1 Cadre de la thèse

reposant sur le Traitement Automatique des Langues pour détecter l'arrivée de l'épidémie de grippe à partir des mots employés sur Twitter. De même, un autre travail a proposé une méthode de détection de la grippe en temps réel à partir de données Twitter. Cette méthode permet aussi de surveiller la répartition des cancers sur un territoire donné et l'efficacité des traitements utilisés [117]. Les auteurs dans [36] ont effectué une double analyse avec Twitter face à la propagation du COVID-19 dans plusieurs régions italiennes en février 2020. Ce travail analysait les raisons des appels d'urgence et leur relation/corrélation avec les publications sur Twitter. Cette surveillance active et conjointe avait pour objectif d'adapter les moyens sanitaires grâce à une prévision de l'arrivée de l'épidémie dans une région. D'autres travaux ont analysé les réactions des internautes par une étude du contenu textuel et des photographies publiés sur Facebook lors des attaques terroristes qui ont eu lieu à Paris en 2015 [47].

Les Réseaux Sociaux Numériques sont aussi utilisés par les organisations pour **adapter leurs stratégies lors de crises**. Une étude dans [166], suite à la crise provoquée par la guerre en Ukraine, a été menée sur les données collectées depuis les sites Web d'organisations de paiement centralisés comme Paypal, Skrill, Stripe. Les résultats de cette étude montrent le rôle et les avantages des réseaux sociaux dans la stratégie de marketing numérique pour ces organisations. Une étude dans [4] a montré que les directeurs d'école au Koweït utilisent les réseaux sociaux, principalement WhatsApp et Twitter, pour gérer les crises scolaires et revenir à une situation normale.

1.1.2 Cadre de travail

Cette thèse a été financée par le projet de recherche iSite Cocktail (<https://projet-cocktail.fr>, travail soutenu par le programme "Investissements d'Avenir", projet ISITE-BFC contrat ANR-15-IDEX-0003) dont l'objectif est l'analyse de la circulation des discours ambiants et émergents sur Twitter, dans les secteurs de la santé et de l'alimentation soumis à des crises depuis plusieurs années.

Il s'agit d'un projet interdisciplinaire, basé sur un partenariat public/privé, regroupant des chercheurs en sciences de l'information et de la communication (laboratoires CIMEOS, TIL, EL-LIADD), en informatique (laboratoire LIB), et en sciences alimentaires (CSGA). Par ailleurs, les différentes étapes et thématiques du projet mobilisent plusieurs groupes de travail de chercheurs soutenus par le pôle de compétitivité VITAGORA et par l'expertise de deux entreprises partenaires, Atol CD et Webdrone. Il s'agit également d'un projet sociétal puisqu'il traite de sujets sur la sécurité sanitaire et alimentaire. Un des volets du projet est de **mettre en évidence les signaux faibles cachés dans les discours et les pratiques de Twitter**, sujet de ma thèse.

La plateforme associée à Cocktail comprend plusieurs fonctionnalités :

1. la collecte de données lancée *via* des critères de collecte spécifiques (comptes, mots-clés et hashtags) pour constituer un corpus global ;
2. le stockage des données dans le polystore Hyde [70] c'est-à-dire un système unifié qui



ISITE-BFC (ANR-15-IDEX-0003)

permet de tirer parti de plusieurs sous-systèmes de stockage hétérogènes, d'exploiter l'expressivité des différents modèles de représentation de données proposés et leurs performances ;

3. l'analyse des données à différents niveaux de granularité, après nettoyage et filtrage du corpus global pour constituer un corpus correspondant au cas d'étude.

Des indicateurs macroscopiques permettent aux experts métier de comprendre le contexte général des corpus global et d'étude. Ensuite, une analyse mésoscopique plus ciblée est menée sur le corpus d'étude pour comprendre les éléments du Réseau Social Numérique et détecter des communautés en s'appuyant sur des relations Utilisateur-Utilisateur, Hashtag-Hashtag et Utilisateur-Hashtag. Enfin, à partir des résultats de l'analyse mésoscopique, une analyse microscopique est réalisée en réduisant le nombre d'éléments d'intérêt pour répondre à des questions spécifiques. Dans ce niveau, des analyses qualitatives sur de petits sous-ensembles de données peuvent être menées. Des fonctionnalités offertes par ces niveaux d'analyse sont détaillées dans le tableau 1.1.

Niveau de granularité	Corpus	Fonctionnalités
Macroscopique	Corpus global et corpus étude	- Indicateurs globaux (nombre de tweets, retweets, mentions, hashtags, etc.) - TOP k (utilisateurs, hashtags co-occurrence, etc.) - Séries temporelles pour suivre l'évolution des tweets, retweets, mentions, réponses, etc.
Mésoscopique	Corpus d'étude	- Détection de communautés - Détection des utilisateurs influents
Microscopique	Sous-ensemble du corpus d'étude	- Détection de scandale - Viralité - Détection des signaux faibles

TABLE 1.1 – Analyse des données sur différents niveaux de granularité.

Les analyses ont pour objectif de permettre aux utilisateurs de la plateforme :

- d'analyser l'impact d'un évènement ou d'une campagne marketing ;
- d'élaborer une stratégie de communication ;
- d'anticiper une situation de crise ;
- d'adapter leur offre commerciale ou industrielle ;
- d'analyser les spécificités territoriales.

1.2 Objectifs et problématiques de la thèse

Les entreprises doivent prendre des décisions dans un environnement soumis à des changements constants et rapides. En effet, ces dernières années ont été marquées par de multiples crises sanitaires, économiques et géo-politiques qui ont mis en évidence l'importance des signaux faibles pour aider les gouvernements et les entreprises à comprendre le plus tôt possible les changements dans leur environnement et s'y adapter. Venugopal et al. [185] ont remarqué au début des années 2010, un regain d'intérêt pour l'identification des signaux faibles au vu

1.2 Objectifs et problématiques de la thèse

du nombre de publications en constante augmentation. Ces années correspondent à un changement dans les technologies, par exemple, en informatique il y a la sortie de l'iPad, le *cloud computing*, les applications mobiles. Ces changements se traduisent soit par des discontinuités soit par l'émergence de tendance [169]. Il existe différentes définitions pour représenter ces changements, les deux formes les plus fréquentes reposent sur les notions de signal faible et de tendance. Les signaux faibles sont les signaux précurseurs d'évènements futurs alors que les tendances définissent les changements technologiques, économiques, politiques et sociétaux.

Dans cette thèse, nous nous intéressons aux signaux faibles, sources d'information capables d'aider les entreprises à prendre des décisions stratégiques face aux opportunités ou aux menaces futures. Détecter et interpréter ces signaux faibles lorsque les évènements ne sont pas connus à l'avance sont des problèmes complexes pour les chercheurs. Comme les signaux faibles sont de petits précurseurs, ils sont généralement cachés au milieu d'une grande quantité d'informations [187] et la prise de décision est limitée par des contraintes temporelles et nécessite un traitement rapide d'une grande masse de données. En 1978, Turner estime que la plupart des accidents sont liés à des enchaînements d'erreurs et de défauts, qui sont presque toujours détectables avant que l'accident se produise [151]. À la suite de catastrophes naturelles, industrielles ou de crises, il est essentiel de trouver des indicateurs antérieurs ou précurseurs, des signaux négligés et des alertes rejetées qui, s'ils avaient été reconnus et gérés de manière appropriée avant l'évènement indésirable, auraient pu éviter certaines conséquences. En effet, la littérature présente de nombreux exemples de ce type d'évènements. Un exemple d'accident qui aurait pu être évité est l'accident du train de Paddington à Londres en 1999. Un train a franchi un signal rouge alors qu'il aurait dû s'arrêter, il est entré en collision avec un autre train faisant trente-un morts et quatre cent dix-sept blessés. La mauvaise visibilité du feu avait été signalée et une collision évitée un an avant, mais l'installation d'un système de protection automatique des trains avait été rejetée pour des raisons de coût [43]. Un autre exemple d'accident est celui de la navette spatiale Challenger. La *Columbia Accident Investigation Board (CAIB)*, commission interne convoquée par la NASA pour enquêter sur la destruction de Challenger lors de la mission du 28 janvier 1986, a déterminé que l'accident était dû à la mousse isolante qui s'est détachée du réservoir externe de carburant, formant des débris qui ont endommagé l'aile de l'orbiteur. Le problème de la chute des débris était bien connu mais considéré comme « acceptable »⁶. Diane Vaughan, dix ans après l'accident de Challenger reprend l'idée que des signaux précurseurs sont disponibles mais qu'ils ne sont pas traités, ce qu'elle nomme « *normalisation de la déviance* »⁷. De la même manière, la pandémie de la COVID-19 a montré la nécessité d'une politique préventive : plusieurs études avaient évoqué la possibilité d'une pandémie nécessitant l'usage de masques [42], malgré tout l'usine de production de masques de protection Plaintel dans les Côtes d'Armor a été fermée en 2018 et ses machines détruites⁸.

Nos recherches portent sur l'identification des signaux faibles dans les Réseaux Sociaux Numériques et plus globalement dans des graphes d'interactions temporelles entre entités. Nous devons alors répondre aux deux questions de recherche suivantes :

6. https://fr.wikipedia.org/wiki/Columbia_Accident_Investigation_Board, [66]

7. <https://www.techniques-ingenieur.fr/actualite/articles/challenger-30-ans-apres-un-cas-decole-pour-lanalyse-des-risques-31508/>

8. <https://www.letelegramme.fr/bretagne/masques-l-usine-de-plaintel-a-ferme-il-y-a-deux-ans-28-03-2020-12532801.php>

Comment exploiter les données issues des Réseaux Sociaux Numériques pour détecter des signaux faibles ?

Comment confirmer si ces signaux faibles sont utiles pour guider et aider l'entreprise dans ses prises de décision ?

Pour répondre à ces deux questions nous construisons une chaîne de traitement permettant de détecter les signaux faibles, les interpréter et visualiser l'information à l'aide de représentations visuelles sous forme de tableaux de bord. Nous formulons cette problématique de la manière suivante :

- La plupart des approches de détection des signaux faibles étudient l'émergence de mots-clés à l'aide des techniques de *text-mining*. Les données issues des Réseaux Sociaux Numériques sont des textes courts contenant des abréviations et des fautes d'orthographe rendant difficile l'utilisation de telles approches. Ces données pouvant être modélisées comme un graphe d'interactions temporelles, une autre voie peut être proposée en analysant la topologie du réseau.

Comment établir une signature des signaux faibles qui permet leur détection à partir d'un graphe d'interactions temporelles entre entités ?

- Une fois détectés, il est nécessaire de donner du sens aux signaux faibles afin qu'ils soient utiles à une organisation pour planifier ses futures stratégies. Les approches existantes proposent peu d'outils d'interprétation des signaux faibles aux experts métier, or celle-ci est une étape cruciale pour étudier la relation entre ces signaux et une menace ou une opportunité futures pour l'organisation. Cette étape a pour objectif d'aider les experts métier à prendre une décision quant à leur pertinence afin de déclencher une action.

Comment prendre en compte les informations contextuelles pour interpréter les signaux faibles détectés ?

1.3 BEAM : une méthode d'identification des signaux faibles

Dans la suite, nous présentons les deux contributions scientifiques de cette thèse, permettant de répondre aux différentes questions de recherche citées ci-dessus ainsi que l'évaluation de la robustesse de notre méthode BEAM⁹. Ces contributions ont abouti à la publication de plusieurs articles scientifiques que nous citons en annexe H.

1.3.1 Détection des signaux faibles

Nous faisons l'hypothèse que la topologie du réseau sert de support à la détection des signaux faibles. Nous proposons une modélisation des données sous la forme d'une séquence temporelle de sous-graphes d'interactions. Par exemple, Twitter est souvent modélisé sous forme d'un graphe dont les nœuds représentent les entités (comme un utilisateur ou un hashtag), et les liens correspondent aux différentes relations entre ces entités (comme un retweet, une

9. BEAM : *a ray or shaft of light beams from the searchlights, a collection of nearly parallel rays (such as X-rays) or a stream of particles (such as electrons), a constant directional radio signal transmitted for the guidance of pilots.*

1.3 BEAM : une méthode d'identification des signaux faibles

mention, une co-occurrence, etc.). Chaque sous-graphe représente les interactions qui se sont produites durant un certain intervalle de temps.

Nous décrivons les signaux faibles au moyen d'une signature sous la forme d'une propriété quantifiable qui les caractérise et permet leur détection. Nous choisissons les graphlets [157] comme outil opératoire pour établir cette signature. Les graphlets sont des sous-graphes induits et connectés (allant de deux à cinq nœuds) choisis parmi les nœuds d'un graphe. Pour détecter les signaux faibles, nous étudions l'évolution des graphlets au cours du temps en utilisant leur nombre, vitesse et accélération comme marqueurs des critères de visibilité, de diffusion et d'amplification du signal. Le critère de rareté est estimé avec un calcul de contribution des graphlets dans les signaux faibles.

1.3.2 Interprétation des signaux faibles

Pour pouvoir évaluer la pertinence des signaux faibles détectés dans notre première contribution, nous proposons une contextualisation de ces signaux, afin de leur donner du sens et ainsi faciliter et améliorer la tâche d'interprétation des experts métier. Cette contribution permet alors de répondre à la deuxième question de recherche relevée dans la section précédente.

Nous fournissons des éléments comme la taille des graphlets, leurs formes prédéfinies ainsi que les orbites, c'est-à-dire les positions ou les rôles des nœuds dans les graphlets, pour faciliter l'interprétation. Ces caractéristiques permettent, par exemple, de surveiller et d'expliquer le rôle des individus dans les discours sur les Réseaux Sociaux Numériques. Nous proposons aussi une étude des caractéristiques des nœuds comme leur nom, leur type, leur activité dans le Réseau Social mais aussi leurs relations avec d'autres et leur rôle dans les signaux faibles, etc. Le rôle de l'expert métier dans cette partie est prépondérant, l'objectif est d'éclairer sa prise de décision avec des éléments et des visualisations utiles.

Ces deux contributions aboutissent à l'identification d'un signal faible, c'est-à-dire à le reconnaître parmi les autres signaux.

1.3.3 Évaluation de la méthode

La méthode BEAM de détection et d'interprétation des signaux faibles que nous proposons est évaluée sur différents jeux de données. Ces jeux de données ont été sélectionnés afin d'offrir des différences en terme de volume de données, d'entités participant aux interactions, de types d'interactions. De plus, ils sont issus de plusieurs dispositifs numériques comme Twitter, Facebook ou des capteurs RFID. Des expérimentations sont réalisées ayant plusieurs objectifs. Le premier est de vérifier la robustesse de BEAM en étudiant son comportement par rapport à des vérités de terrain, le second est d'étudier la reproduction des résultats en travaillant avec des données périodiques, finalement nous faisons varier les conditions expérimentales pour évaluer la sensibilité de la méthode. En plus, le développement de *workflows* reproductibles facilite les analyses exploratoires et permet une visualisation des différents aspects des données traitées. Un *Proof of Concept* a été développé et mis en œuvre à l'aide de *notebooks* Jupyter.

La figure 1.1 illustre nos contributions, les moyens et les différentes méthodes mis en œuvre pour répondre aux questions de recherche.

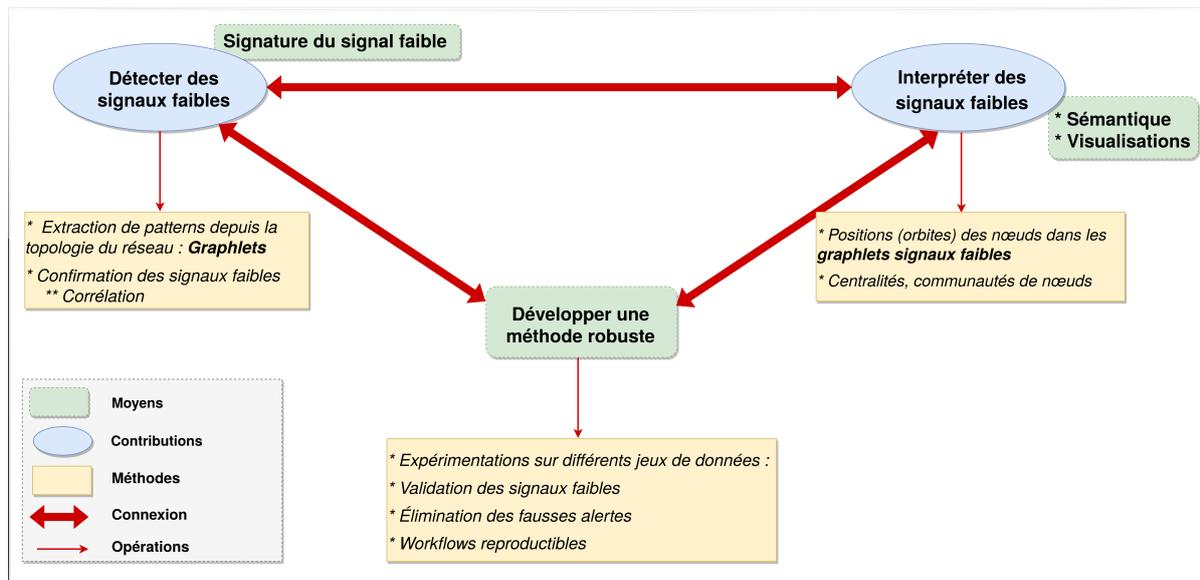


FIGURE 1.1 – Réponses aux questions de recherche traitées dans notre thèse.

1.4 Plan du manuscrit

Ce manuscrit est composé de cinq chapitres en complément de ce chapitre d'introduction. Dans le chapitre 2, nous introduisons la notion de signal faible ainsi que les différents termes utilisés dans la littérature pour le désigner. Nous présentons ensuite ses caractéristiques et son cycle de vie. Enfin, nous présentons les travaux de recherche qui étudient l'identification des signaux faibles dans plusieurs domaines, afin de positionner notre approche par rapport aux travaux existants.

Les deux chapitres suivants décrivent nos contributions dans la détection et l'interprétation des signaux faibles parmi des interactions temporelles. Le chapitre 3 présente notre première contribution avec tout d'abord les graphlets, que nous utilisons comme outil opératoire pour décrire les caractéristiques des signaux faibles, et ainsi les détecter. Ensuite, nous décrivons la collecte et la modélisation des données brutes sous forme de graphes d'interactions temporelles. Puis nous décrivons les différentes étapes de détection de notre méthode BEAM qui consistent à estimer les critères caractéristiques des signaux faibles en utilisant les graphlets.

Le chapitre 4 décrit notre seconde contribution, qui est une étape essentielle pour donner du sens aux signaux faibles détectés, et expliquer leur rôle dans la survenue d'un évènement important. Dans ce chapitre nous présentons les différents éléments contextuels que nous fournissons à l'expert métier pour faciliter la tâche d'interprétation des signaux faibles. En plus, nous proposons différentes techniques qui permettent à l'expert métier de visualiser ces éléments sur différents niveaux de granularité.

Dans le chapitre 5, nous présentons l'étude expérimentale de nos contributions. Cette étude est effectuée sur sept jeux de données. Trois jeux (Lubrizol, PAC et GOT) renferment des données Twitter collectées par la plateforme de collecte du projet Cocktail. Deux autres jeux (Babouins, école primaire) correspondent à des interactions sociales issues de réseaux de capteurs, utilisées comme une vérité de terrain. Nous menons également des expériences sur des réseaux contenant des données aléatoires c'est-à-dire sans évènement connu, que nous utili-

1.4 Plan du manuscrit

sons comme contre-exemples pour valider la méthode. Nous étudions également l'espace des hashtags sur deux jeux de données issus de Twitter (Lubrizol et GOT) pour vérifier la robustesse de BEAM.

Dans le chapitre 6, nous concluons notre travail en revenant sur les contributions apportées dans cette thèse dans la détection et l'interprétation des signaux faibles dans les Réseaux Sociaux Numériques. Nous présentons également nos observations sur la pertinence de la méthode dans l'automatisation de la tâche de détection, tout en laissant une place pour l'interprétation et l'analyse par l'expert de l'impact des signaux faibles sur l'organisation. Nous discutons ensuite une perspective à court terme, dans laquelle nous présentons une méthode qui remplace l'étape 3 de BEAM par une combinaison de l'algèbre linéaire (SVD) et du *clustering* pour détecter des variables latentes qui participent le plus au signal. Finalement, nous présentons des perspectives futures de recherche pouvant enrichir notre travail.



Sommaire

2.1	Signal faible : une notion multi-facettes	14
2.1.1	Description de la notion de signal faible : des définitions et des termes pluriels	15
2.1.2	Spécificités des signaux faibles et modèle tri-dimensionnel de Hil-tunen	17
2.1.3	Cycle de vie d'un signal faible	19
2.2	Différentes méthodes d'identification d'un signal faible	20
2.2.1	Méthodes basées sur les techniques de Traitement Automatique des Langues	22
2.2.2	Méthodes basées sur des algorithmes de Machine Learning	31
2.2.3	Méthodes basées sur les graphes	34
2.2.4	Méthodes basées sur les réseaux bayésiens	36
2.3	Synthèse et conclusion	38

DANS ce chapitre nous introduisons dans un premier temps la notion de signal faible : celle-ci n'est pas définie précisément car des auteurs, appartenant à différents champs disciplinaires, utilisent plusieurs termes pour la désigner voire même, ne la définissent pas en considérant qu'il s'agit d'une notion connue. Une autre façon de définir un signal faible est de préciser ses caractéristiques en mettant en avant des spécificités qui lui sont propres. Malgré tout, nous verrons que les différents travaux sur les signaux faibles nous ramènent à quatre caractéristiques : bien qu'étant informels, rares et difficiles à interpréter, ils sont annonciateurs d'évènement. À l'issue de cette section, nous terminons par une discussion sur les différentes définitions et donnons une définition du signal faible qui correspond à notre domaine applicatif. Nous présentons et discutons ensuite, plusieurs techniques utilisées pour identifier les signaux faibles et appliquées dans des domaines différents.

2.1 Signal faible : une notion multi-facettes

L'article d'Igor Ansoff « *Managing Strategic Surprise by Response to Weak Signals* » [8] demeure la référence dans le domaine de la recherche sur les signaux faibles. Pour la première fois, l'idée de signal faible est identifiée dans le domaine des Sciences de Gestion. Ansoff définit les signaux faibles comme « *les premiers symptômes de discontinuités stratégiques qui agissent comme une information d'alerte précoce, de faible intensité, pouvant être annonciatrice d'une tendance ou d'un évènement important* ». Cet article se focalise sur l'importance qu'il y a pour une entreprise à trouver des informations quasi imperceptibles afin d'éviter les menaces ou au contraire de favoriser les opportunités. La publication de cet article a lieu après le premier choc pétrolier de 1973 où l'instabilité politique a démontré que les plans stratégiques établis lors des trente glorieuses étaient caducs. L'entreprise ne peut plus se contenter d'extrapoler à partir des données du passé et, pour ne pas être surprise par les variations de son environnement, elle doit anticiper les évènements soudains. Ansoff propose de répondre graduellement aux menaces ou opportunités détectées en fonction de l'amplification du signal faible.

La figure 2.1 illustre l'idée que les signaux faibles peuvent contenir des prémises de rupture. Les lignes représentent la croissance d'une entreprise au cours du temps : la courbe centrale montre sa croissance à partir des données du passé sans discontinuités stratégiques alors que les deux courbes de ramification représentent une menace et une opportunité. Si l'entreprise est avertie suffisamment tôt, elle devrait être en mesure soit d'éviter la menace soit de saisir l'occasion¹. C'est l'« état de connaissance » qui d'après Ansoff, explique que lorsqu'une menace ou une opportunité apparaît, elle sera

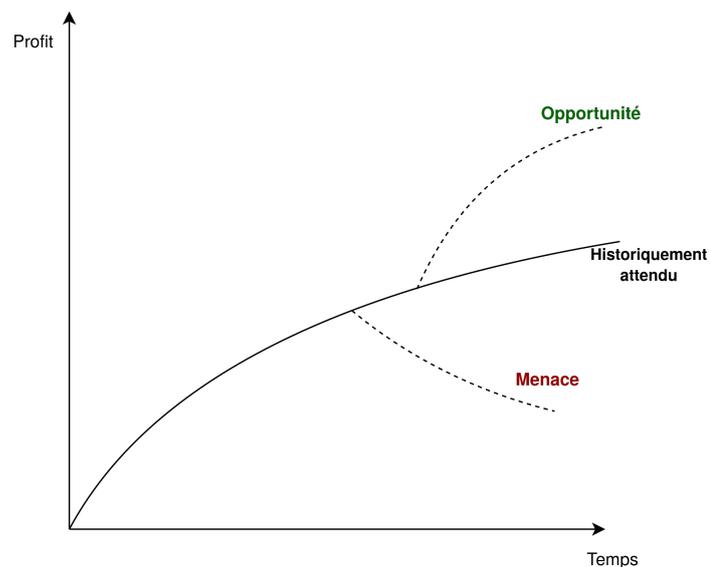


FIGURE 2.1 – Impact d'une menace ou d'une opportunité sur les profits d'une entreprise, extrait de [8].

associée à des informations vagues qui se développeront et se préciseront progressivement avec le temps. Cette progression peut être caractérisée par des états successifs, qui évaluent l'importance des signaux en fonction de leur intensité. Ansoff recommande alors une surveillance globale de l'environnement (*horizontal scanning*), comme le reprend Brion [31] où

1. Garcia-Nunes et al. [65] proposent une ontologie avec deux classes Menace et Opportunité. Les sous-classes de Menace sont les cinq forces de Porter, https://fr.wikipedia.org/wiki/Cinq_forces_de_Porter. Le modèle des cinq forces de Porter est un modèle élaboré en 1979 qui permet d'identifier les forces en concurrence dans une industrie : le pouvoir de négociation des clients, le pouvoir de négociation des fournisseurs, la menace de nouveaux entrants ou concurrents, la concurrence intra-sectorielle et la menace des produits de substitution. Les sous-classes de Opportunité correspondent au cadre d'analyse PESTEL qui distingue six facteurs d'influence : Politique; Économique, Sociologique, Technologique, Environnemental et Légal, https://fr.wikipedia.org/wiki/Analyse_PESTEL.

2.1 Signal faible : une notion multi-facettes

« le concept de signal faible (information vague, incomplète et imprécise porteuse de menace ou d'opportunité) initié par Ansoff (1976) est un thème récurrent dans la littérature de la veille ».

2.1.1 Description de la notion de signal faible : des définitions et des termes pluriels

La définition d'Ansoff est basée sur l'utilité d'un signal faible en l'identifiant comme un élément ayant un caractère anticipatif mais cette définition n'est pas suffisamment précise, il s'agit plus d'une métaphore. Par la suite, de nombreux auteurs reprendront ce travail afin de préciser son idée.

Depuis cinquante ans, la définition d'un signal faible a évolué. Avant 1980, la notion de signal faible faisait référence à des phénomènes émergents ayant un impact dans le futur. Dans les années 1980, les définitions s'intéressent aux sources mal définies et à leurs impacts. Au cours des années 1990, de nouveaux adjectifs sont apparus pour décrire les raisons pour lesquelles ces signaux sont si difficiles à détecter : petit, dynamique, périphérique. À partir des années 2000, les définitions ont commencé à faire référence aux indicateurs d'un phénomène (comme tendance) plutôt qu'aux phénomènes eux-mêmes. Dans la suite, nous présentons quelques définitions.

Ansoff et Mc Dowell, 1990 [9] « *Imprecise early indications about impending impactful events.* »

Godet, 1994 [71] « *A factor of change, hardly perceptible at present but which will constitute a strong trend in the future.* »

Coffman, 1997 [41] « *An idea or trend that will affect how we do business, what business we do, and the environment in which we will work.* »

Blanco et Lesca, 2003 [21] « *[...] weak signals announcing future major changes and to specify forthcoming events, their potential impact, importance and urgency.* »

Mevel, 2004 [137] « *Les signaux forts correspondent aux échanges d'informations opérationnelles nécessaires à l'activité de création de valeur tandis que les signaux faibles s'apparentent à des « bruits » dont la valeur n'est perçue qu'après un traitement approprié (individuel ou collectif).* » page 366

Macrae, 2007 [128] « *These doubts were produced through patterns of sensemaking that interrelated organizational incidents with broader frames of reference in ways that made weak signals meaningful, relevant and worthy of further attention.* »

Hiltunen, 2008 [82] « *Current oddities and strange issues that are thought to be key in anticipating futures changes in different environments.* »

Guillaume, 2008 [76] « *Les signaux faibles sont des signes ambigus, annonceurs, qui demandent une capacité de veille et de réponse à la surprise ou l'imprévu.* »

Kuosa, 2010 [113] « *Any observation which is totally surprising, amusing, ridiculous, or annoying to you.* »

Hiltunen, 2010 [83] « *They are today's clues and signs that provide us with hints of possible future events and trends.* » page 74

Saritas et Smith, 2011 [169] « *Early signs of possible but not confirmed changes that may be later become more significant indicators of critical forces.* »

Lesca et al., 2011 [121] « *Outliers that are likely to constitute weak signals. The interpretation of outliers can highlight anticipative warning, surprises, inflexions, ruptures, fractures, discontinuities.* »

Mendoça et al., 2012 [136] « *Weak signals refer to premature, incomplete, unstructured, and fragmented informational raw material, that can be scrutinised, compiled, analysed and converted into an indicator of potential change.* »

Escande et al., 2013 [58] « *Un signal faible est un évènement, une information, un indicateur, . . . non immédiatement intelligible, mais qui témoigne d'une dissonance dans la compréhension que l'on a d'un phénomène, d'un système ou d'une organisation. Cette dissonance, basée autant sur la confrontation avec le réel qu'à des expériences de pensée, peut être révélatrice d'un dysfonctionnement ou d'une dérive pour un système en cours d'exploitation, ou témoigner d'une potentialité jusque là ignorée.* »

Cette liste ne se veut pas exhaustive, elle est présentée ici pour montrer uniquement la diversité de la notion de signal faible, mais, de ces définitions, nous pouvons dire que les auteurs considèrent *les signaux faibles comme un facteur [71], un évènement ou groupe d'évènements [58], une idée [41], une tendance [41], une indication [9], une anomalie [82, 113, 121], une preuve [83] pouvant être collectés dans le présent et dont l'objectif est de « voir » une indication précoce qui pourrait constituer une forte tendance dans le futur.* Van Veen et Ort [183] ont analysé 152 articles, dont 68 donnent une définition de la notion de signal faible. Leur objectif était à partir de cette étude de proposer une définition unifiée. Ils ont proposé la définition suivante :

« A perception of strategic phenomena detected in the environment or created during interpretation that are distant to the perceiver's frame of reference – Une perception de phénomènes² stratégiques détectés dans l'environnement ou créés lors d'interprétation, éloignés du cadre de référence du récepteur ».

La notion de signal faible s'est développée dans différents domaines, tels que le traitement du signal, la théorie de l'information, la stratégie d'entreprise, la gestion de crise et la prévention de risques industriels. En raison de cette diversité de domaines, ils font l'objet d'un champ lexical riche. Plusieurs termes sont apparus comme « pressentiment », dans le domaine de la gestion de crise nous trouvons les termes « signal d'alarme ou signal d'alerte », « signal aberrant » ou encore « anomalie » ; dans le domaine de la prévention des risques les termes « signal précoce », « alerte précoce », « signal avant-coureur » ou « signal précurseur » sont utilisés de manière interchangeable sans distinction de sens. Dans ces deux derniers domaines, les signaux faibles sont vus comme des signaux d'alerte car ils sont étudiés sous l'angle de la menace.

Dans les définitions présentées ci-dessus, le signal faible est vu comme annonciateur d'un évènement et se place avant un signal fort. Un **signal fort** est facile à identifier car son impact est clair et il reste constant dans le temps. Le signal fort permet une évaluation précise de la situation, il est vu comme une preuve tangible d'un changement. Parmi le **bruit**, vu comme l'ensemble des signaux non pertinents pointant dans des directions incohérentes [136], l'étape de détection des signaux faibles est difficile. Pour nous aider dans cette étape, nous pouvons nous appuyer sur le concept de **précurseur d'évènement**, concept proche du signal faible, qui a émergé avec l'analyse des accidents technologiques. De manière générale, un précurseur est

2. Un phénomène est un fait observé, un évènement normal ou surprenant.

2.1 Signal faible : une notion multi-facettes

le facteur causal lié à un évènement important. Il s'agit de tout comportement, toute situation ou groupe d'évènements qui est un indicateur d'incidents futurs ou d'évènements consécutifs³. Finalement, nous distinguons la notion de wild card de celle de signal faible. Une **wild card** recouvre globalement un évènement surprenant, c'est-à-dire à faible probabilité de se produire, mais ayant un impact important. Les attentats du 11 septembre 2001 qui ont profondément et durablement modifié la situation politique dans le monde ainsi que les relations internationales sont une wild card. Plusieurs auteurs ont pointé le lien entre un signal faible et une wild card. Dans [154], Ponomareva et Sokolova ajoutent à la définition qu'une wild card peut être prédite à partir de l'analyse de signaux faibles. Deux mois avant les attentats du 11 septembre 2001, un agent du FBI alertait son siège que plusieurs individus originaires du Moyen-Orient s'entraînaient dans une école d'aviation mais ne souhaitaient apprendre ni à décoller, ni à atterrir. Ces signaux faibles n'ont pas été pris au sérieux, suscitant ensuite une polémique importante⁴. Magruk dans [129] cite, comme synonymes de wild cards, bifurcations, discontinuités et black swans.

2.1.2 Spécificités des signaux faibles et modèle tri-dimensionnel de Hiltunen

Les définitions présentées dans la section précédente sont de l'ordre de la macro-définition. Nous devons revenir aux spécificités du signal faible que nous avons trouvé au fil des définitions vues précédemment afin de rendre opératoire la notion de signal faible et ainsi pouvoir les exploiter.

Spécificités

Un signal est qualifié de faible car il est difficile à détecter étant noyé dans une multitude de données souvent sans aucun intérêt. Paradoxalement, un tel signal est d'autant plus faible qu'il peut annoncer quelque chose de très important si les experts métier sont capables de le percevoir et de l'interpréter. Plusieurs auteurs [120, 45] ont mis en avant les spécificités d'un signal faible que nous pouvons résumer par les qualificatifs suivants :

fragmentaire nous ne sommes pas face à des informations complètes sur l'évènement pouvant être anticipé, nous n'avons à notre disposition qu'un petit nombre de signaux à interpréter. À partir de leur interprétation, les experts métier devront se risquer à prendre des décisions. Dans les diverses définitions présentées dans la section précédente, nous trouvons aussi les adjectifs incomplet, imprécis, vague ;

signification apparente faible il n'existe pas de lien de cause à effet, le signal faible paraît peu parlant ou ambigu, il est sans signification et demande une interprétation de la part d'experts métier ;

faible intensité il est disséminé dans une multitude d'informations inutiles et un grand nombre de personnes passe à côté de cette information, il apparaît comme étant peu visible.

Le tableau 2.1 reprend les différentes spécificités d'un signal faible mises en regard des spécificités d'une information courante.

3. <https://www.nap.edu/read/11061/chapter/6#80>

4. https://www.liberation.fr/evenement/2004/09/11/les-signaux-manques-du-11-septembre_49209

Signal faible	Information courante
Fragmentaire, incomplet	Complète, entière
Équivoque, ambigu, signification apparente faible	Claire
Incertain, peu fiable	Certaine
Utilité faible	Utilité confirmée
Rare	Répandu, fréquent
Imprécis	Familière
Insolite, surprenant, bizarre	Courant
Imprévisible, non répétitif	Habituelle
Aléatoire, fortuit, flux faible, irrégulier	Fournie à flot régulier
Non structurée	Structurée

TABLE 2.1 – Spécificités d'un signal faible versus information courante, extrait de [120].

Dans [54], les auteurs remettent en cause le caractère imprévisible du signal faible en montrant qu'en réalité les experts métier ne sont pas surpris par la découverte du signal faible car ils avaient déjà intégré ce signal de façon tacite. Moijanen [141] utilise six aspects pour caractériser un signal faible. Trois sont relatifs à sa temporalité : 1) phénomène de transition, il est annonciateur et se place avant un évènement ; 2) accentuation du signal, il est repris par des sources différentes, il se diffuse et devient de plus en plus fort à l'approche de l'évènement et 3) sa durée de validité est donc courte. Les trois autres aspects concernent l'interprétation car c'est finalement l'analyse des signaux qui leur donne sens.

Modèle de Hiltunen

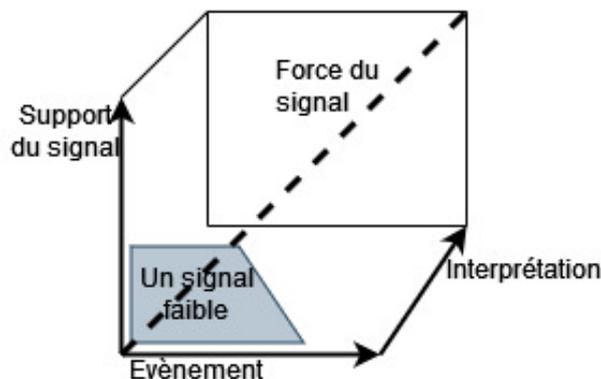


FIGURE 2.2 – Modèle tri-dimensionnel proposé par Hiltunen, extrait de [82].

Pour Hiltunen, les signes futurs peuvent indiquer de nombreux changements progressifs et en 2008, elle a suggéré un espace tri-dimensionnel [82] où : 1) signal correspond à un indicateur de visibilité, 2) évènement représente un indicateur de diffusion d'un signe futur, et 3) interprétation représente la compréhension du signe futur par son récepteur. Les signes peuvent être classés de signaux faibles à forts dans cet espace tridimensionnel : un signal faible a des niveaux faibles pour les dimensions signal et évènement et peut se transformer en un signal fort présentant des niveaux plus élevés pour ces deux dimensions. José Poças Rascão [159]

2.1 Signal faible : une notion multi-facettes

indique que la force du signal est une mesure importante car les signaux vont de faible à fort pour éventuellement devenir une tendance. Dans cet espace triadique, Hiltunen est la seule à mettre en évidence l'aspect cognitif du processus d'identification des signaux faibles où l'influence de la vie réelle et l'expérience de l'expert métier ne sont pas sans effets sur la façon dont il interprète les signaux faibles détectés. La figure 2.2 montre les trois dimensions des signes futurs proposées par Hiltunen.

Ce modèle a servi de cadre général dans de nombreux travaux présentés en section 2.2. Les dimensions signal et événement sont utilisées pour mesurer et quantifier les signaux faibles : la dimension signal pour mesurer la visibilité des signaux faibles qui ont une faible fréquence d'apparition et la dimension événement pour quantifier sa diffusion. La diffusion est mesurée par un taux de croissance du signal qui doit croître pour un signal faible.

Les caractéristiques et le modèle tridimensionnel de Hiltunen constituent un premier pas vers une description opératoire du signal faible, obligatoire dans le cadre d'une méthode de détection automatique des signaux faibles.

2.1.3 Cycle de vie d'un signal faible

Les signaux faibles étant décrits comme des indications ambiguës de perturbations à venir, on considère qu'il faut franchir une série de filtres avant d'aboutir à une prise de décision. Dès les années 1970, Ansoff, suivi entre autres par [78], [92] et [184], suggéra que les signaux faibles devaient passer trois filtres (voir figure 2.3) :

le filtre d'information ou de surveillance correspond à la capacité du signal faible à être détecté au milieu de toutes les autres informations perçues par un acteur.

le filtre de mentalité renvoie à la capacité du signal à être reconnu après avoir été détecté comme une information pertinente au regard de la situation en cours. Ce filtre est expliqué par de nombreux biais cognitifs qui font obstacle à la prise de décision. Un certain nombre de biais cognitifs [170], comme le biais de normalité⁵, le biais de confirmation⁶, le biais d'optimisme⁷, etc. peuvent expliquer pourquoi ces informations ne sont pas retenues. Ces biais sont individuels mais d'autres facteurs organisationnels peuvent aussi expliquer pourquoi les signaux faibles sont ignorés.

le filtre de pouvoir renvoie à la prise de décision une fois le signal détecté et sa pertinence reconnue. Les responsables en situation d'arbitrage peuvent décider de ne pas faire de ce signal une priorité malgré le risque encouru.

Plus récemment, un quatrième filtre, celui de la transmission qui renvoie au flux d'information à l'intérieur de l'organisation et qui se situe entre le filtre de mentalité et le filtre de pouvoir a été ajouté. En effet, les personnes qui reçoivent le signal et estiment en premier de son sens et de sa pertinence ne sont généralement pas celles qui ont le pouvoir de décision. Basé sur ces trois filtres, Brizon et al. [32] ont proposé une méthode de gestion des signaux faibles dans le domaine de la sécurité industrielle.

5. Le biais de normalité conduit les gens à nier ou à minimiser des avertissements relatifs à un danger.

6. Le biais de confirmation consiste à privilégier les informations confirmant ses idées préconçues, ce qui se traduit par une réticence à changer d'avis.

7. Le biais d'optimisme amène une personne à croire qu'elle est moins exposée à un événement négatif que d'autres personnes.

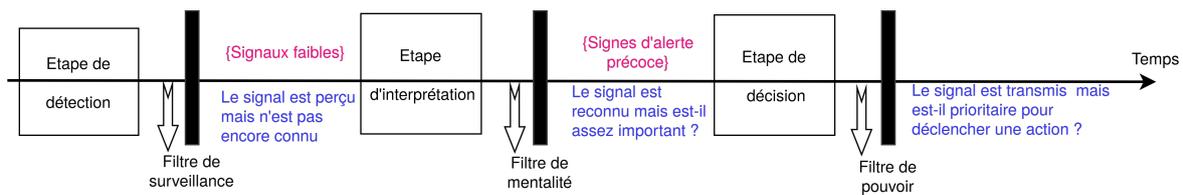


FIGURE 2.3 – Cycle de vie des signaux faibles.

Rossel [163] critique ce cycle de vie comme étant « *très linéaire et ne prenant pas en compte la complexité d'éléments perturbateurs* » et montre l'importance du filtre de pouvoir.

Pour conclure sur ces différentes définitions, nous rappelons qu'Ansoff a été le premier à définir les signaux faibles comme les premiers signes de changement possible mais non confirmés qui peuvent devenir plus tard des indicateurs d'opportunité ou de menace. Cette définition générale a été reprise par les autres chercheurs où les signaux faibles sont vus en tant que **matière première prédictive**. Les signaux faibles sont alors définis par leurs caractéristiques : ce sont des données fragmentées, rares, à peine visibles aujourd'hui, mais qui peuvent cacher une tendance. D'autres auteurs, comme Seidl [171] et Rossel [163], proposent une approche où les signaux faibles sont considérés comme une « *construction socio-cognitive de la réalité qui aide l'expert métier à forger un sens et à agir de manière significative sur la réalité* ».

Nous considérons qu'un signal faible se présente comme une donnée anodine mais dont l'interprétation que les experts métier en font peut déclencher une alerte. Cette alerte indique que pourrait survenir un évènement susceptible d'avoir des conséquences en terme d'opportunité ou de menace. Notre définition se place dans le modèle tri-dimensionnel de Hiltunen qui est un cadre général où les dimensions représentées sont subjectives.

Nous définissons un signal faible comme un signal peu visible et rare qui indique des changements progressifs, c'est-à-dire ayant une diffusion qui croît, pouvant aboutir à un évènement ^a.

a. McMinn et al. [135] définissent un évènement comme une chose importante qui se produit à un moment et à un endroit précis. Dans les Réseaux Sociaux Numériques, les évènements comme la détection de catastrophes naturelles, d'attaques terroristes, etc. provoquent un volume inhabituel de messages. Les travaux se sont donc axés sur la détection de « rafales de messages » [134].

Nous appliquons ces dimensions dans les Réseaux Sociaux Numériques où le signal est porté par les interactions entre les individus. Nous caractérisons alors un signal faible par un petit nombre d'interactions entre individus qui croît dans le temps. Les interactions entre individus sont vues comme des motifs particuliers.

2.2 Différentes méthodes d'identification d'un signal faible

Plusieurs études qualitatives faites avec des questionnaires ont été menées sur les signaux faibles pour analyser l'environnement des entreprises, aider à la prise de décisions gouvernementales ou dans les entreprises. Cette démarche ne sera pas développée dans cette thèse dont l'objectif est d'offrir un outil d'aide à la décision nécessitant un traitement rapide, donc automatique, de grande masse de données.

2.2 Différentes méthodes d'identification d'un signal faible

Devant être recherché dans un environnement sujet à des discontinuités [163], il est difficile de construire des méthodes permettant d'identifier automatiquement des signaux faibles. Pourtant, l'identification des signaux faibles est une problématique majeure qui a donné lieu à un grand nombre de recherches et différentes approches et applications ont été proposées. Pour être complète, une méthode d'identification des signaux faibles comprend deux étapes comme la montre la figure 2.3 : une première étape de détection suivie d'une étape d'interprétation, la décision finale de prendre en considération les signaux faibles revenant aux décideurs. Dans la suite, nous verrons que certaines méthodes s'arrêtent à l'étape de détection, ne proposant aucune aide aux experts métier pour l'interprétation des signaux faibles détectés.

La quasi majorité des méthodes d'identification des signaux faibles sont basées sur l'exploration de documents grâce à une analyse textuelle de mots-clés comme l'ont souligné Mühlroth et Grottke dans leur état de l'art [143]. Mühlroth et Grottke analysent quatre-vingt onze articles publiés dans cinquante-deux journaux entre 1997 et 2017. Ils observent que les documents peuvent être issus de média sociaux (Twitter, Weibo, Wikipedia ou de blogs), de publications scientifiques (articles, brevets), de sources Web (journaux en ligne, sites Web), le même constat est réalisé dans [99]. Ensuite vient le travail sur le texte avec le découpage en mots (tokenisation), la suppression des mots vides (*stop words*), la racination (*stemming*) ou la lemmatisation des tokens. Ces étapes classiques dans le traitement automatique des langues ne sont pas présentées dans ce chapitre. Un état de l'art sur cette problématique a été réalisé dans [101].

L'objectif est alors d'étudier le comportement des mots-clés au cours du temps en s'appuyant sur les critères de visibilité et de diffusion d'un signal faible. Ces deux critères sont traduits respectivement, par les métriques de fréquence d'apparition et de taux de croissance. Ces travaux sont détaillés dans le paragraphe "Détection des signaux faibles" de la section 2.2.1. Afin de faciliter l'interprétation des résultats, beaucoup de travaux ont aussi choisi de regrouper les mots-clés dans des thèmes. En effet, un mot-clé pris isolément est considéré comme une information trop fragmentaire pour permettre à l'expert métier de donner une interprétation pertinente. Deux grandes familles de techniques ont été utilisées pour construire les thèmes : 1) techniques de Traitement Automatique des Langues à partir de la page 26 et 2) techniques de Machine Learning à partir de la page 31. La figure 2.4 synthétise ce processus de détection et d'interprétation des mots-clés signaux faibles.

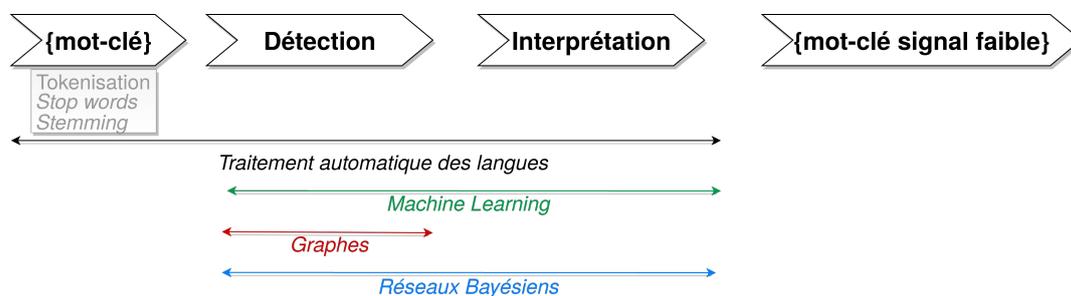


FIGURE 2.4 – Processus d'identification de mots-clés signaux faibles avec les quatre familles de techniques employées.

Une autre approche s'intéresse aux interactions entre mots-clés et utilise des outils de la théorie des graphes (centralité, coefficient de clustering) pour détecter des signaux faibles (voir section 2.2.3).

Enfin, la dernière catégorie de méthodes est spécifique au domaine de l'Intelligence Économique. Elles utilisent l'analyse d'impact réalisée par un réseau bayésien pour identifier parmi des documents des signaux faibles et leurs conséquences sur l'entreprise (voir section 2.2.4).

Nous avons choisi d'organiser cet état de l'art en fonction des techniques utilisées, nous aurions aussi pu l'organiser en fonction des objectifs visés comme 1) détecter les signaux faibles économiques dont l'objectif est trouver des changements qui se rapportent aux changements macro/micro-économiques dans l'environnement des entreprises; 2) détecter les signaux faibles technologiques se rapportant aux changements dans l'espace scientifique de Recherche et Développement; 3) détecter les signaux faibles dans les domaines politique et sociétal. Dans la suite, nous présentons les principaux travaux pour chacune des approches précédentes.

2.2.1 Méthodes basées sur les techniques de Traitement Automatique des Langues

Dans la suite, nous présentons des travaux basés sur le Traitement Automatique des Langues pour les étapes de détection et d'interprétation des signaux faibles.

Détection des signaux faibles

À partir de documents tels que des articles de journaux, des articles de recherche ou des tweets, des mots-clés sont extraits. La méthode de pondération TF-IDF (*Term Frequency-Inverse Document Frequency*), en permettant d'évaluer l'importance d'un mot contenu dans un document, est généralement utilisée pour les sélectionner. Afin d'identifier parmi eux des signaux faibles, les méthodes décrites ci-dessous reposent sur les deux critères suivants :

1. la visibilité d'un mot, évaluée par sa fréquence d'apparition;
2. la diffusion d'un mot, évaluée par son taux de croissance vu comme son évolution d'une période à l'autre.

Une application directe de ce principe a été proposée par Sun Hi Yoo et DongKyu Won [190]. Ils définissent les *signaux faibles* comme *des sujets émergents liés à des mots qui n'ont pas été sélectionnés comme mots-clés dans des articles de recherche*. Autrement dit, un mot qui a un taux de croissance inhabituel pourrait être fortement lié à des problématiques futures, peu familières et inhabituelles. Pour étudier le comportement dynamique de signaux faibles, les auteurs analysent des séries temporelles de mots issus de cinquante articles du *Journal of the Korean Ceramic Society* entre 2008 et 2012. La méthode proposée calcule l'occurrence de chaque mot dans chacun des articles, son occurrence annuelle et son taux annuel de croissance. La plateforme NetLogo⁸ de simulation à base d'agents est utilisée pour simuler le comportement dynamique de signaux faibles et ainsi confirmer les résultats trouvés. Juneseuk Shin [172] constate qu'indiquer les recherches à fort potentiel industriel ne suffit pas car les entreprises n'ont pas les compétences pour les développer. Toujours par une étude de la bibliographie, il propose alors d'identifier des recherches émergentes mais aussi de jeunes chercheurs capables de mettre en œuvre leurs industrialisations.

8. <https://ccl.northwestern.edu/netlogo/>

2.2 Différentes méthodes d'identification d'un signal faible

Charitonidis et al. [38] basent l'identification des signaux faibles sur la fréquence d'émission des tweets émis lors des émeutes de 2011 à Londres. Lorsqu'un changement dans la fréquence est détecté, les auteurs réalisent une analyse spatiale couplée à une analyse de sentiments pour détecter les basculements émotionnels. Les résultats montrent qu'il existe des signaux faibles caractérisés par un vocabulaire spécifique comme `riot`, `angry` et par une fréquence d'émission de tweets en hausse, ces signaux sont les premiers indicateurs d'émeutes qui se produiront autour des zones géographiques déterminées. De même, les auteurs dans [14] reprennent comme critères le vocabulaire utilisé dans les tweets et leur fréquence d'émission en hausse pour détecter des signaux avant-coureurs prédisant si un film sera ou non un succès au box-office.

Brynielsson et al. [34, 35] proposent une analyse sémantique du discours plus complexe afin d'identifier des personnes sur le point de commettre des actes de violence isolés à partir de messages qu'elles postent sur le Web. Ces personnes sont dites « loup solitaire » et sont considérées comme des signaux faibles d'actes de terrorisme potentiels. La condition est ici le niveau de radicalité de la personne. Leur approche consiste à analyser différents critères et à fusionner les résultats pour donner une solution globale. Les critères portent sur l'intention, la capacité et l'opportunité d'une personne à commettre un acte violent. Ces critères sont eux-mêmes décomposés en sous-critères. Pour chaque personne, les auteurs proposent une étape d'appariement (similarité dans l'alias, stylométrie, etc.) pour identifier une personne qui a plusieurs alias sur différents sites suivie d'une analyse sémantique de leur discours avec WordNet⁹ mais, le ton de la phrase (ironie, blague, etc.) peut conduire à des faux positifs et enfin une analyse du réseau des pages Web utilisés. Chaque personne x reçoit alors une note $I(x)$ reflétant son niveau de radicalité avec $I(x) = f(\{J(w)|w \in W \wedge A(x, w)\}, C(x))$ où $J(w)$ est la fonction d'intérêt pour un site Web w et W est l'ensemble des sites web, $C(x)$ la fonction d'analyse de tout le contenu posté par x et $A(x, w)$ est égal à 1 si x est actif sur le site w . Deux méthodes sont proposées pour trouver la fonction f :

- une moyenne pondérée mais un expert doit alors assigner un degré d'importance à chaque critère ;
- un réseau bayésien. Cependant, l'utilisation des réseaux bayésiens implique la création d'un réseau pour chaque loup solitaire ce qui est difficile à mettre en œuvre à grande échelle et le nombre de messages échangés sur les forums est aussi problématique à gérer.

Leur méthode a été intégrée en tant que prototype dans la plateforme Impactorium [178].

Yoon dans [191] a formalisé les critères de visibilité de mots-clés apparaissant dans des documents et leur diffusion au cours du temps avec deux métriques : 1) le degré de visibilité (DoV) représente la fréquence des mots-clés dans l'ensemble des documents ; 2) le degré de diffusion (DoD) représente la fréquence des documents. *Un mot-clé ayant une faible visibilité et un faible niveau de diffusion est considéré comme un signal faible.*

Les deux mesures sont définies formellement pour un mot-clé i et une période j , comme suit :

$$DoV_{ij} = \left(\frac{TF_{ij}}{NN_j} \right) \times (1 - tw \times (n - j)) \quad DoD_{ij} = \left(\frac{DF_{ij}}{NN_j} \right) \times (1 - tw \times (n - j))$$

avec

9. WordNet est une Base de Données lexicale <https://wordnet.princeton.edu/>

- TF_{ij} , fréquence du mot-clé i durant la période j ,
- DF_{ij} , fréquence du document dans lequel i apparaît durant la période j ,
- NN_j , nombre de documents durant la période j avec n le nombre de périodes
- et finalement tw représente une pondération pour prendre en compte le temps.

Yoon considère que les occurrences récentes d'un mot-clé suscitent plus d'intérêt que les mots-clés plus anciens et fixe tw à 0,05. Un taux de croissance de la fréquence élevé et croissant traduit la diffusion du mot-clé/document. Le taux moyen de croissance est calculé avec la moyenne géométrique donnée par $\bar{X} = \sqrt[n]{\prod_{j=1}^n x_j}$. Pour les statisticiens, la moyenne géométrique est moins sensible que la moyenne arithmétique aux valeurs les plus élevées d'une série de données et donne, par conséquent, une meilleure estimation de la tendance centrale des données. Zhan [192] utilise la méthode des moindres carrés pour calculer le taux moyen de croissance.

Griol-Barres et al. [75, 74] utilisent une troisième mesure, le degré de transmission (DoT) pour mieux évaluer l'importance des mots-clés. Ce degré prend en compte toutes les valeurs de h-index des journaux pour tous les textes où le mot-clé i est présent :

$$DoT_i = \sum HIndex_{journal}$$

Pour détecter les mots-clés signaux faibles, chaque métrique DoD et DoV est multipliée par leur DoT. Nous pouvons formuler les critiques suivantes concernant l'emploi du h-index : celui-ci ne donne pas nécessairement un classement exact de l'impact et surtout il désavantage les nouveaux journaux, car leurs résultats de publications et leurs taux de citation observés seront relativement faibles.

Organisation des mots-clés dans une matrice BCG : un premier pas vers l'interprétation

Une amélioration de ce principe consiste à fournir une cartographie des mots-clés, selon les deux critères précédents, aux experts métier afin de les aider dans l'interprétation des signaux faibles. Les mesures DoV et DoD sont utilisées pour construire respectivement la carte KEM (*Keywords Emergence Map*) et la carte KIM (*Keywords Issue Map*) qui sont des matrices BCG¹⁰. La figure 2.5 représente une matrice BCG divisée en quatre quadrants contenant les mots-clés. Dans le quadrant Signal faible, les mots-clés (respectivement documents) ont une faible fréquence mais un taux de croissance élevé, ce qui peut suggérer qu'ils vont augmenter rapidement dans le futur. Dans le quadrant Signal fort ou tendance les mots-clés (respectivement documents) ont une forte fréquence et un taux de croissance élevé. Le troisième quadrant, appelé signal latent, est caractérisé par des mots-clés (respectivement documents) ayant une faible fréquence et un faible taux de croissance; le quatrième quadrant, Signal bien connu, contient les mots-clés (respectivement documents) qui ont une forte fréquence mais un taux de croissance faible. Dans [74], les troisième et quatrième quadrants sont fusionnés et appelés Bruit. La carte KIM (*Keywords Issue Map*) représente le degré de diffusion des mots-clés *via* la fréquence des documents dans lesquels ils apparaissent tandis que la carte KEM (*Keywords Emergence Map*) indique la visibilité des mots-clés *via* leur fréquence d'apparition. Sur ces cartes, l'abscisse représente la fréquence moyenne du mot-clé (respectivement documents) et l'ordonnée fait référence au taux moyen de croissance de la métrique DoV (respectivement taux moyen de croissance de la métrique DoD).

10. La matrice BCG (*Boston Consulting Group*) est un outil d'analyse stratégique qui date de la fin des années 1960, elle représente la façon dont une organisation développe son modèle économique https://fr.wikipedia.org/wiki/Matrice_BCG.

2.2 Différentes méthodes d'identification d'un signal faible

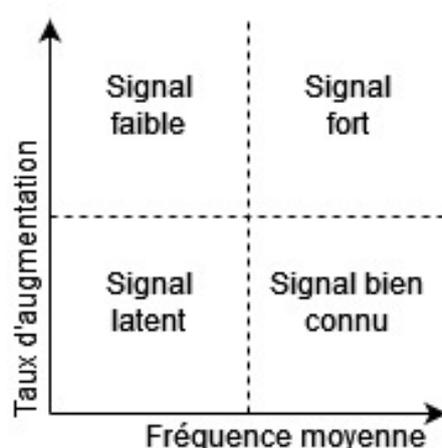


FIGURE 2.5 – Classification du signal dans une matrice BCG.

Yoon utilise des sites d'information et la base de données ProQuest¹¹ pour sélectionner des documents relatifs aux thèmes « panneau solaire » et « photovoltaïque », entre le 1^{er} janvier 2006 et le 31 mars 2011 et affirme que la méthode montre de meilleurs résultats que les experts humains lorsqu'il s'agit d'informations textuelles massives.

Ebadi et al. [52] reprennent la même démarche que Yoon dans le domaine de la recherche sur les missiles hypersoniques. Après avoir identifié les mots-clés signaux faibles grâce aux cartes KIM et KEM, ils étudient l'évolution de ces mots-clés sur trois périodes P1, P2 et P3. Ils montrent que parmi les signaux extraits, aucun ne suit un schéma sinusoïdal au cours du temps, c'est-à-dire « faible en P1 → Fort en P2 → Faible en P3 » ou « Fort en P1 → Faible en P2 → Fort en P3 », suggérant ainsi que les signaux en tant que modèles sinusoïdaux ne doivent pas être fréquents en recherche.

Article	Domaine d'application	Données utilisées
Park et Cho 2017 [147]	Réseau électrique	Articles scientifiques
Lee et al. 2018 [118]	Éthique en IA	Articles scientifiques
Griol-Barres et al. 2019 [75]	Énergie solaire	Journaux, Réseaux sociaux, Articles scientifiques
Krigsholm et al. 2019 [112]	Aménagement du territoire	Articles scientifiques
Kim et al. 2019 [103]	Harcèlement scolaire	Réseaux sociaux
Roh et al. 2020 [162]	Énergie nucléaire	Journaux
Griol-Barres et al. 2020 [74]	Téledétection	Journaux, Réseaux sociaux
Ebadi et al. 2022 [52]	Missiles hypersoniques	Articles scientifiques

TABLE 2.2 – Utilisation de la méthode développée par Yoon [191] dans divers travaux.

Le tableau 2.2 indique différents articles, leur date de publication et domaine d'application dans lesquels le travail de Yoon a été repris.

11. <http://search.proquest.com>

Interprétation des signaux faibles

L'un des avantages de cette méthode est de catégoriser automatiquement et dynamiquement les mots-clés. Les experts peuvent alors, sur la base des cartes, interpréter les résultats. Cependant, Lee et Park [118] puis Krigsholm et Riekkinen [112] soulèvent deux écueils : 1) le problème d'incertitude lorsqu'un même mot-clé est à la frontière de plusieurs quadrants dans une carte ou lorsqu'il est situé dans des quadrants différents pour les deux cartes ; 2) le problème d'interprétation qui se produit lorsque pour un mot-clé donné il existe plusieurs significations. De plus, les mots-clés signaux faibles sont, en général, des termes isolés qui ont perdu leur contexte, c'est-à-dire, les documents dans lesquels ils se trouvaient ainsi que les mots-clés avec lesquels ils étaient utilisés ce qui limite l'information lors d'une interprétation plus approfondie. Pour améliorer l'interprétabilité, les deux articles proposent de travailler avec des mots-clés regroupés par thèmes au lieu de mots-clés isolés, ce qui devrait selon eux augmenter la précision de la méthode. Leur hypothèse est qu'un signal faible est une information fragmentaire qui prise isolément est inutile mais combinée avec d'autres signaux faibles similaires peut amener à une nouvelle compréhension de l'environnement et aboutir à une nouvelle stratégie pour l'entreprise. De nombreux travaux ont alors choisi de travailler sur des clusters de mots-clés. *Les mot-clés signaux faibles sont donc des mots-clés appartenant à un seul et même cluster fortement cohérent (unitaire, nouveauté) et disjoint des autres (donc non reliés sémantiquement à d'autres clusters), le nombre d'occurrences de ces mots-clés est généralement faible et ces mots-clés sont présents dans peu de documents (rareté).*

Dans la suite, nous présentons plusieurs travaux qui utilisent différentes techniques de TAL pour regrouper les mots-clés : l'Allocation de Dirichlet Latente, l'Analyse Sémantique Latente et l'Analyse Formelle de Concepts.

Regroupement de mots-clés avec l'Allocation de Dirichlet Latente L'intérêt principal de l'utilisation de l'Allocation de Dirichlet Latente (LDA) consiste à inférer les thèmes d'un corpus de documents. Le résultat de la LDA est un modèle probabiliste décrivant : 1) comment de nombreux mots appartiennent à des thèmes et 2) comment les thèmes sont associés aux documents [23]. Dans le cadre de la recherche de signaux faibles, la LDA a été utilisée dans plusieurs travaux. Pour appliquer cette méthode deux problématiques doivent être résolues : 1) la détermination du nombre k de thèmes. Si le paramètre k est petit, la catégorisation est trop large et ne permet pas de trouver les signaux faibles. Si k est élevé, les mots peuvent être « sur-catégorisés », conduisant à une perte d'information due à une trop grande précision ; 2) la prise en compte de la temporalité des données.

Dans [132, 130, 131], Maitre et al. ont proposé d'utiliser la LDA combinée avec Word2vec pour détecter un cluster ou thème lié à un signal faible. Word2vec est une famille de modèles de plongement lexical (*word embedding*) créant des représentations vectorielles de mots, il est alors possible de définir la valeur de similarité entre deux mots.

Pour ces auteurs, *un signal faible est caractérisé par un petit nombre de mots par document, présents dans peu de documents, et sans rapport avec d'autres thèmes.* Ces trois caractéristiques représentent la rareté et l'anomalie du signal faible. Leur approche est basée sur un regroupement multi-niveaux de thèmes obtenu en faisant varier le nombre de clusters k . Les auteurs utilisent Word2vec pour trouver le paramètre k optimal en définissant deux indicateurs. Le premier indicateur mesure la similarité au sein d'un cluster (ils utilisent la similarité cosinus) et le second évalue la similarité entre les clusters (critère de cohérence). Ces deux critères

2.2 Différentes méthodes d'identification d'un signal faible

permettent de sélectionner un sous-ensemble de clusters cohérents et pertinents où au moins l'un d'entre eux est susceptible de contenir les mots du signal faible. Des notices de Wikipedia dans lesquels les auteurs ont ajouté des mots-clés signaux faibles sont utilisées comme corpus pour montrer la robustesse de leur méthode. Une faiblesse de leur approche est que les auteurs ne tiennent pas compte de l'aspect temporel des documents.

Zhan [192] utilise la LDA pour regrouper en thèmes les mots-clés signaux faibles et propose aussi d'étendre chaque thème avec des mots-clés similaires pour faciliter l'interprétation.

Prise en compte de l'évolution des thèmes Il est indispensable d'étudier l'évolution des clusters ou thèmes pendant une période de temps, par exemple, jour, semaine, mois. Suivre l'évolution des thèmes permet alors de faire des prédictions en se basant sur les critères de diffusion et d'amplification du signal faible. L'introduction de la dimension temporelle dans l'analyse des thèmes, nommée LDA dynamique, a été proposée par [22]. Les travaux suivants ont pris en compte la temporalité des données avec la notion de chaîne de thèmes (*topic chains*). Afin d'étudier les thèmes dans des données temporelles, les auteurs découpent les données en snapshots de durée fixe, et pour chaque snapshot S^i , la LDA est appliquée sur tous les documents publiés durant cet intervalle. On obtient alors, pour chaque snapshot S^i , un ensemble Z_i de thèmes. Puis l'étude de l'évolution des thèmes sur des snapshots consécutifs est réalisée. La proximité ou la force entre deux thèmes $z \in Z_i$ et $z' \in Z_{i+1}$ est évaluée par une mesure de similarité $\delta(z, z')$, une chaîne de thèmes se forme correspondant à la plus grande/petite valeur de δ comme illustré en figure 2.6.

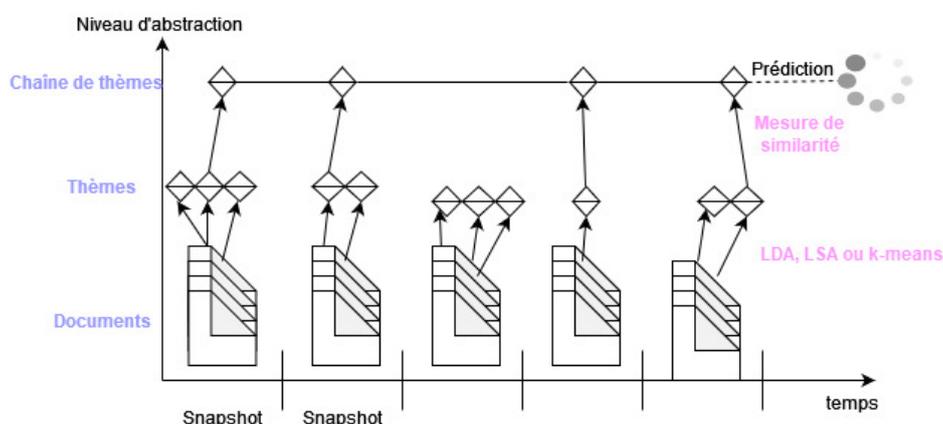


FIGURE 2.6 – Construction des chaînes de thèmes au cours du temps.

Pépin et al. [158] ont comparé sept mesures de similarité pouvant servir à construire une chaîne de thèmes : distances euclidienne, Jensen-Shannon, Jaccard, Hellinger, cosinus, Bhattacharyya, Kullback-Leibler. Les distances Jaccard, Hellinger, cosinus et Jensen-Shannon sont surtout sensibles si il existe beaucoup de chaînes de thèmes ; la distance Bhattacharyya présente un plateau suivi d'un brusque changement ; la distance Kullback-Leibler est presque linéaire sauf pour les grandes valeurs de chaînes et la distance euclidienne présente une fonction sigmoïde (courbe en S). Ils terminent leur étude par un cas sur des tweets concernant l'entreprise EDF. Une visualisation à l'aide de diagramme de Sankey permet de suivre l'évolution mensuelle de chaque thème et leurs relations au cours du temps, *via* la distance de Kullback-Leibler ou la distance euclidienne, et ainsi détecter des thèmes représentant le signal faible.

Dans [102], les auteurs appliquent la LDA sur des rapports d'études publiés par des instituts de recherche coréens sur dix ans, ils travaillent sur le titre, le résumé. Pour cela ils utilisent LDA-Vis¹² qui est un outil de visualisation des résultats de la LDA. LDAvis fournit une matrice BCG des thèmes qui permet à l'expert, comme vu à la page 24, de sélectionner les thèmes signaux faibles. Cet outil fournit aussi la divergence de Jensen-Shannon comme mesure de distance entre deux thèmes. Cette mesure leur permet de suivre, entre deux périodes consécutives, l'évolution de thèmes proches, c'est-à-dire ayant une faible distance entre eux. Un thème émergent ou signal faible a un faible rang en première période et voit son rang augmenter lors de la période suivante.

Tim Gutsche, dans [77], utilise la LDA et détermine le nombre k de thèmes avec la mesure de cohérence d'un thème c_v proposée par Röder et al. [161]. La distance de Hellinger sert à construire la chaîne de thèmes puis, comme Yoon, il propose une matrice BCG avec en abscisse la fréquence moyenne des mots pertinents et en ordonnée le taux de croissance moyen de $ARTF$, calculé avec la moyenne géométrique. $ARTF$ est la somme des fréquences des mots j les plus pertinents pour tous les thèmes d'une chaîne pour le snapshot S^i sélectionné (RTF_{ij}) et cette somme est divisée par le nombre de documents D_i dans le snapshot, soit $ARTF_{ij} = \frac{RTF_{ij}}{D_i}$.

Une façon d'évaluer l'évolution des thèmes est d'utiliser les fonctions logistiques à la place du taux de croissance calculé par une moyenne géométrique. En mathématiques, les fonctions logistiques sont les fonctions ayant pour expression : $f(t) = \frac{K}{1+ae^{-rt}}$ où K et r sont des réels positifs et a un réel quelconque. Pour $a > 0$, la courbe représentative a la forme d'un S ce qui fait qu'elle est parfois appelée sigmoïde. La fonction logistique a été utilisée pour montrer l'état d'avancement de la diffusion d'une innovation au cours de son cycle de vie.

Dans [56] et toujours avec l'utilisation de la LDA, El Akrouchi et al. appliquent leur méthode d'identification de mots-clés signaux faibles sur des articles du Web parus en décembre 2019 relatifs à la COVID-19 soit avant que l'épidémie mondiale commence. Pour valider leur approche, ils regardent leurs évolutions sur janvier et février 2020 qui correspondent au début de l'épidémie. Pour cela, ils ont proposé deux critères basés sur les fonctions logistiques pour évaluer l'évolution de la force du signal. La fonction *weakness* $WK(t)$ a pour objectif de filtrer les thèmes qui contiennent potentiellement des mots-clés signaux faibles. Les thèmes sélectionnés par la fonction *weakness* sont considérés comme des containers de signaux faibles où tous les mots associés à ce thème ne sont pas forcément des signaux faibles. La fonction *weakness* $WK(t)$ a trois paramètres : 1) $CC(t)$ centralité de proximité utilisant la distance de Hellinger entre un thème t et les autres thèmes; 2) $W(t)$ poids du thème t basé sur la mesure de cohérence c_v de Röder; 3) $AC(t)$ fonction d'auto-corrélation pour prendre en compte la temporalité, alors $WK(t) = \frac{W(t) \times CC(t)}{1+e^{-AC(t)}}$. La fonction *potential warning* $PW(i)$ se base sur la probabilité $\phi(i)$, obtenue par la LDA que le mot i appartienne au thème t et la fréquence normalisée de i dans t , $NF(i) : PW(i) = \frac{NF(i)}{1+e^{-(\phi(i) \times \log(\phi(i)))}}$. Pour faciliter l'interprétation des mots sélectionnés, il les enrichissent avec de nouveaux mots-clés. Ces nouveaux mots sont sélectionnés par l'application de Word2vec et la similarité cosinus est choisie comme mesure de distance. Dans [55], ces auteurs rajoutent une nouvelle fonction logistique pour sélectionner les mots choisis par $WK(t)$ et $PW(i)$. Ils appliquent ces trois fonctions à un corpus constitué de Web journaux parus entre 2006 et 2007 pour identifier des mots signaux faibles annonciateurs de la crise financière de 2008.

12. <https://cran.r-project.org/web/packages/LDAvis/README.html>, [173]

2.2 Différentes méthodes d'identification d'un signal faible

Enfinement, un autre exemple d'utilisation est proposé par Li et al. dans [125]. L'objectif est de prédire si une thématique de recherche sera industrialisée ou non. Pour cela, ils font une étude comparative entre le temps que met un thème à se diffuser dans la communauté scientifique *via* la construction de chaînes de citations d'articles scientifiques et le moment où cette thématique de recherche apparaît dans les brevets, c'est-à-dire, le moment où elle est entrée dans une phase d'industrialisation.

Le tableau 2.3 résume des travaux utilisant la LDA pour identifier les signaux faibles dans un corpus. Mal El Akrouchi et al. [57] proposent un état de l'art de ces méthodes.

Article	Détermination du nombre k de thèmes	Chaîne de thèmes	Visualisation chaînes de thèmes
Maitre et al. 2019 [132]	Word2Vec	NA	NA
Gutsche 2018 [77]	Mesure de cohésion de Röder et al.	Distance de Hellinger	Matrice BCG
Pépin et al. 2017 [158]	NA	Distance euclidienne ou de Kullback-Leibler	Diagramme de Sankey
Kim et al. 2019 [102]	LDAvis	Distance de Jensen-Shannon	Matrice BCG, Graphe
Li et al. 2020 [125]	Hierarchical Dirichlet Process	Chaîne de citations d'articles	Graphe

TABLE 2.3 – Identification des signaux faibles utilisant la LDA.

Regroupement de mots-clés avec l'Analyse Sémantique Latente L'Analyse Sémantique Latente (ou *Latent Semantic Analysis*, LSA) apporte une représentation de faible dimension des documents et des mots. Elle s'appuie sur une matrice qui décrit l'occurrence du mot dans le document (nombre brut ou normalisé par TF-IDF) et utilise ensuite une décomposition en valeurs singulières (SVD) pour réduire le nombre de mots tout en préservant leurs relations.

La méthode proposée par Thorleuchter et al. repose sur la formulation d'une hypothèse par des experts. L'hypothèse correspond à la survenue d'un évènement dans le futur : dans [180], l'exemple choisi est que la demande des hôpitaux en oxygène pur va augmenter en Europe et dans [181] l'hypothèse est que les besoins en énergie renouvelable vont augmenter en Allemagne. Les mots utilisés pour formuler l'hypothèse servent à extraire des mots-clés de différentes sources (documents, sites Web, ...). Une matrice creuse A de rang r est construite où les lignes correspondent aux m mots et les colonnes aux n sources ($r \leq \min(m, n)$), chaque cellule de la matrice contient la fréquence d'apparition du mot dans la source. Malgré le petit nombre de sources, cette matrice a un grand nombre de mots et les valeurs sont souvent à zéro car les mots ne sont pas distribués de façon égale dans les sources. Une décomposition en valeur singulière (SVD) est appliquée pour réduire le rang r de la matrice à k ($k < r$). À l'issue de la SVD, une matrice A est approximée par $A \approx A_k = U_k \Sigma_k V_k^T$. Le résultat de la décomposition en valeurs singulières conduit à la création de k clusters permettant de voir comment les mots (respectivement les sources) sont liés entre eux grâce à l'identification de *patterns* textuels. Les signaux faibles sont représentés par les *patterns* peu fréquents mais ayant une forte relation avec l'hypothèse donnée. La valeur de k est importante, car k doit être

suffisamment grand pour considérer tous les signaux faibles et suffisamment petit pour éliminer les signaux forts. Cette méthode présente deux inconvénients : 1) elle repose entièrement sur la formulation de l'hypothèse et ; 2) la valeur de k est issue de tests empiriques.

Bouktaib et al. [27] créent des thèmes en utilisant trois méthodes : 1) LDA, 2) LSA et 3) l'algorithme k-means après avoir représenté chaque mot par un vecteur avec Word2vec. Le nombre de thèmes est fixé à $k = \sqrt{\frac{n}{2}}$ où n est le nombre de mots présents dans le corpus, les mots les plus fréquents ont été éliminés auparavant. L'étape suivante consiste à éliminer les thèmes redondants en fusionnant des thèmes précédemment obtenus. Deux thèmes donnés par deux des trois méthodes sont fusionnés si la distance obtenue par l'indice de similarité Jaccard est supérieure à un seuil donné. Sur les thèmes obtenus, les auteurs calculent un taux de croissance comme proposé par Yoon et al. [191] pour sélectionner les mots-clés signaux faibles. Leur méthode est validée sur un corpus composé d'articles scientifiques issus de IEEExplorer et ACM Digital library ainsi que sur des brevets déposés à l'office des brevets et marques des États-Unis (USPTO).

Organisation des mots-clés avec l'Analyse Formelle de Concepts Deux travaux présentent une approche d'alerte précoce pour prédire le crime organisé dans le cadre du projet ePOLICE¹³ : Brewster et al. [29] et Andrews et al. [7] prennent comme exemple la lutte contre la traite des personnes et l'esclavage moderne. Les deux travaux posent comme postulat que *la présence et/ou l'émergence de la criminalité existe dans le contenu généré par les citoyens* c'est-à-dire dans les réseaux sociaux, et ils considèrent un signal faible comme ayant *une valeur peu tangible . . . [étant] un indicateur isolé qui a le potentiel d'être symptomatique d'une variété de phénomènes*. Les mots-clés extraits de tweets correspondent au vocabulaire fourni par l'Office des Nations Unies contre la drogue et le crime¹⁴ et ces mots-clés sont considérés comme des signaux faibles potentiels. L'Analyse Formelle de Concepts (AFC) [64] est utilisée pour les organiser en fonction de propriétés. Les propriétés choisies sont la proximité temporelle et/ou géographique entre mêmes activités criminelles. Si le nombre de tweets contenant ces mots-clés sont émis dans une même zone géographique et dans un laps de temps court alors ils seront considérés comme étant du signal faible. Une interface utilisateur montre sur une carte géographique les endroits où les signaux faibles ont été détectés. L'ACF comporte deux avantages : la visualisation en temps réel des hiérarchies d'objets et la découverte de relations entre les objets. Même si l'AFC présente des avantages, elle demande l'intervention humaine dans des situations de sous-compréhension ou de sur-compréhension. La première est causée par l'absence ou l'insuffisance de connaissance, ce qui entraîne des faux positifs. La deuxième est résultat d'une trop grande connaissance du terrain et de l'influence trop forte des propriétés, qui ne laissent pas émerger de nouvelles tendances. De plus, de nombreux tweets ne possèdent pas certaines propriétés, ce qui augmente le bruit. L'expert métier doit alors déterminer les objets et leurs propriétés, et cela peut conduire à une fausse interprétation. De surcroît, l'AFC présente aussi une complexité de calcul polynomial.

13. early Pursuit against Organized crime using enviroNmental scanning, the Law and IntelligenCE systems <https://cordis.europa.eu/project/id/312651>

14. <https://www.unodc.org/unodc/fr/index.html>

2.2 Différentes méthodes d'identification d'un signal faible

2.2.2 Méthodes basées sur des algorithmes de Machine Learning

Les techniques de Machine Learning ont été rarement appliquées pour la détection des signaux faibles, en revanche nous les avons rencontrées plus fréquemment dans l'étape d'interprétation. Une troisième méthode utilisant la p-valeur est aussi présentée ici.

Détection de signaux faibles

Deux méthodes très différentes des précédentes ont été proposées pour détecter des signaux faibles. La première méthode considère qu'un signal faible est une bizarrerie caractérisée par une valeur inhabituelle, l'autre se place dans le domaine industriel et cherche à identifier des paramètres à surveiller car ils sont des précurseurs d'accident. Ces méthodes se caractérisent aussi par le fait qu'elles ne proposent pas d'étape d'interprétation.

Identification de valeurs inhabituelles Kim et Lee [104] ont proposé une approche reposant à la fois sur l'identification de valeurs inhabituelles et sur une visualisation par matrice BCG. Ils donnent la définition suivante, proche de celle de Lesca et al. [121] : *Un signal faible est un mot-clé rare ou inhabituel (outliers) et qui n'est pas lié avec les sujets existants (cohésion), il est à ce titre nouveau.* Pour la rendre opératoire, ils utilisent l'algorithme LOF (*Local Outlier Factor*) [28], qui est une méthode de détection d'anomalie non supervisée. L'algorithme LOF identifie les valeurs aberrantes locales grâce à une comparaison de la densité d'un point observé par rapport à ses k voisins les plus proches. S'il existe une différence entre le point observé et ses voisins, le point est considéré comme une anomalie. Son avantage est de pouvoir identifier les valeurs aberrantes même si les données ne sont pas uniformément distribuées et ont des motifs incohérents car il travaille localement. Nous notons deux inconvénients à l'utilisation de cet algorithme. La définition de la valeur pour k n'est pas simple et influence directement le résultat final. En fait, la meilleure valeur de k peut varier en fonction de la taille ou de la qualité du corpus. De plus, l'algorithme conserve toutes les données à analyser en mémoire ce qui peut devenir problématique pour traiter de gros corpus.

Les auteurs ont pris comme cas d'étude la recherche dans le domaine de la réalité virtuelle où un mot-clé est considéré comme nouveau si il n'est pas trouvé dans les brevets et comme rare si il apparaît peu dans les articles de recherche. Ainsi, les auteurs travaillent sur deux corpus : des données issues de brevets et des données issues d'articles de recherche. À partir de ces deux corpus, deux matrices "documents/mots-clés" sont construites avec comme valeur la fréquence normalisée du mot-clé dans le document qui est soit un brevet soit un article de recherche. Pour chaque matrice et chaque mot-clé la valeur LOF est calculée. Pour évaluer si un mot-clé est un signal faible, une matrice BCG est construite en utilisant comme axes ces deux valeurs LOF. La matrice est divisée en quatre quadrants où deux seuils sont proposés pour le découpage : 1) top n des valeurs LOF ou 2) la moyenne des valeurs LOF. Un mot-clé est un signal faible si il a ses deux valeurs LOF élevées.

Détection de précurseurs d'évènement Ackley et al. [1] ont déterminé par des scores d'importance des paramètres critiques pour les phases d'approche et d'atterrissage des avions, ces paramètres sont vus comme des précurseurs d'évènements indésirables et sont donc susceptibles de prédire un accident. Ils ont utilisé la méthode de sélection séquentielle arrière (*Sequential Backward Selection*, SBS) pour sélectionner les paramètres critiques puis ils effectuent une classification des paramètres critiques à l'aide des forêts aléatoires (*random forest*).

SBS commence avec l'ensemble des paramètres et à chaque itération le paramètre le plus mauvais est supprimé. L'avantage de SBS est qu'elle prend en considération l'interaction d'un paramètre avec l'ensemble des paramètres. De façon similaire, Lee et al. [116] ont également utilisé les forêts aléatoires pour identifier les précurseurs liés à deux événements de sécurité aérienne ; tout comme [24] qui utilise l'apprentissage multi-instances.

Détection de signaux faibles avec des tests statistiques Les auteurs, dans [95], estiment qu'il se forme naturellement trois sous-ensembles lors de l'analyse de données de grande dimension comme celles produites par les technologies à haut-débit en biologie. Ces trois sous-ensembles sont : signaux forts, bruit et mixte où les signaux faibles se mélangent avec le bruit. L'identification de ses trois sous-ensembles est basée sur le classement de la p-valeur¹⁵ en étudiant les faux négatifs au lieu des faux positifs. L'utilisation de la p-valeur est très largement remise en cause [186, 6], une des recommandations est que les conclusions scientifiques ne devraient pas être fondées uniquement sur le fait que la p-valeur se trouve au delà ou non d'une valeur seuil. Harington et al. [80] conseillent pour pouvoir utiliser la p-valeur d'avoir un protocole d'étude avec des méthodes d'ajustement pour faire des comparaisons multiples. Dans ce cadre, les auteurs de cet article proposent un protocole de sélection *Adaptive False Negative Control* (AFNC)¹⁶ pour conserver les signaux faibles dans le sous-ensemble mixte :

1. les p-valeurs sont ordonnées ;
2. le point qui sépare les signaux que l'on ne peut pas distinguer (ceux ayant des p-valeurs faibles) des signaux qui sont du bruit est trouvé ;
3. les signaux faibles sont choisis en utilisant l'ajustement de Bonferroni qui permet de corriger le seuil de signification lors de comparaisons multiples. Il s'agit de l'ensemble des signaux qui contient le moins possible de faux positifs.

Interprétation des signaux faibles

Des méthodes utilisent des techniques de Machine Learning pour regrouper les mots-clés ou suivre l'évolution des clusters dans le temps. Une fois les clusters construits, les critères de visibilité et de diffusion sont utilisés comme précédemment pour détecter et interpréter les signaux faibles.

Algorithmes de clustering non hiérarchiques Dans la suite, nous présentons trois travaux qui ont utilisé des algorithmes de clustering non hiérarchiques. Avec le clustering non hiérarchique ou partitionnement, les individus sont répartis dans k clusters, pour une valeur de k fixée et chaque individu n'appartient qu'à un seul cluster.

Algorithme k-means Dans le domaine de la lutte contre la criminalité, Shyam Varan Nath [144] utilise la méthode *k-means*¹⁷ pour regrouper les crimes similaires c'est-à-dire ayant les mêmes caractéristiques (type de crime, *modus operandi*, sexe de la victime, lieu, date,

15. La p-valeur est utilisée pour quantifier le seuil à partir duquel les résultats d'un test sont jugés fiables dans le cadre d'une hypothèse nulle. L'hypothèse selon laquelle on fixe a priori un paramètre de la population à une valeur particulière s'appelle hypothèse nulle.

16. Le code source de AFNC est disponible à <https://github.com/zjdaye/AFNC>

17. <https://fr.wikipedia.org/wiki/K-moyennes>

2.2 Différentes méthodes d'identification d'un signal faible

etc.). Une représentation dans l'espace et le temps de ces clusters est fournie pour permettre aux forces de police d'analyser les tendances, de prédire les prochains crimes mais aussi de visualiser la formation de petits clusters qui sont des signaux faibles annonciateurs de futurs *hotspots*.

Algorithme des k-médoïdes L'algorithme des k-médoïdes est un algorithme de partitionnement plus robuste vis-à-vis des données aberrantes (*outliers*) que celui des k-means car il n'utilise pas de moyennes qui sont sensibles aux valeurs aberrantes. Dans [142], les auteurs utilisent cet algorithme et un ensemble de mots-clés signaux faibles comme point de départ. Pour un corpus donné, chaque document j est vu sous la forme d'un vecteur $d_j = (s_{j1}, s_{j2}, \dots, s_{jm})$ où s_{ji} est une valeur qui lie le mot i au document j . Cette valeur peut être l'indication de présence/absence ou la fréquence de l'occurrence du mot i dans le document j . Un mot dans l'ensemble des signaux faibles fourni est choisi comme médoïde et l'algorithme des k-médoïdes est alors appliqué pour regrouper les mots du corpus avec le mot signal faible médoïde. La distance de Jaccard est utilisée pour détecter les mots du corpus les plus proches du mot-clé signal faible.

Ce travail se distingue des autres par le fait qu'un ensemble de mots signaux faibles doit être fourni pour pouvoir appliquer la méthode.

Carte de Kohonen Kim et al. [105] proposent une méthode en trois étapes pour déterminer les signaux faibles :

1. regroupement en clusters ou thèmes des mots-clés en utilisant les cartes de Kohonen (*Self-Organizing feature Map*). Les cartes de Kohonen forment une classe de réseau de neurones artificiels fondée sur des méthodes d'apprentissage non supervisées [109]. L'algorithme regroupe les observations en classes selon une notion de voisinage, c'est-à-dire les mots-clés ayant des fréquences d'apparition dans les documents proches forment un cluster. Cet algorithme diffère des précédents par la mise à jour des clusters voisins, où les clusters deviennent des neurones activables ;
2. classification des clusters de mots-clés selon leur fréquence en *short*, *mid* ou *long term* grâce à une visualisation sous la forme d'une carte à cases ou *tree map*. Les cartes à cases permettent de visualiser des données hiérarchisées en arborescence. S'inspirant de la méthode de Yoon [191], deux cartes à cases sont construites, une pour estimer la visibilité d'un mot-clé en utilisant la fréquence moyenne d'apparition du mot dans tous les documents et l'autre sa diffusion en utilisant les fréquences d'apparition des documents qui contiennent ce mot-clé.
3. évaluation de l'influence d'un mot-clé sur un autre. Les relations entre mots-clés, déterminées par des mesures de similarité, permettent d'évaluer leur influence. Les auteurs utilisent la similarité cosinus dans leur article.

Algorithmes de clustering hiérarchiques Yue Ning et al. [145] ont présenté une approche pour l'identification des signaux faibles à l'aide d'un apprentissage multi-instances imbriqué (*nested Multiple Instance Learning*, n-MIL) où les labels ne sont pas disponibles au niveau instance, mais seulement au niveau du sac d'instances (un sac est un ensemble d'instances). Au niveau instance, la probabilité qu'un article de journal publié un jour donné soit lié à l'évènement cible est obtenue grâce à l'emploi d'une fonction logistique. Les probabilités des articles

parus sur une journée sont ensuite agrégées, et enfin, les probabilités sur un certain nombre de jours avant l'événement sont agrégées ensemble, créant une structure imbriquée. Les articles, avec des probabilités élevées et ayant influencé la décision du classifieur, sont alors considérés comme précurseurs de l'évènement prédit. Les auteurs ont montré, à travers trois jeux de données, que leur méthode était capable de prédire des manifestations, vues comme un évènement, dans différentes villes d'Amérique latine.

Évolution des thèmes avec la régression linéaire Des techniques de Machine Learning ont aussi été utilisées pour suivre l'évolution des thèmes. Huang et al. [89] n'utilisent plus des distances entre snapshots (voir [158]) mais un modèle de régression linéaire. Généralement, évaluer la nouveauté d'un mot consiste à mesurer la différence entre la fréquence prévue du mot et sa fréquence réelle, qui est généralement fait avec la fonction z-score¹⁸. Cependant, parce que le thème auquel le mot appartient est apparu dans les snapshots précédents, et que ce thème reçoit plus d'attention dans le snapshot courant que dans les précédents (c'est-à-dire qu'il présente une tendance croissante), la fréquence réelle du terme est forte alors que sa fréquence prévue est faible et, par conséquent, sa nouveauté est en fait sur-évaluée. Pour pallier ce problème, les auteurs utilisent la régression linéaire pondérée localement (LWR). LWR est un algorithme bien adapté car il consiste à faire de la régression linéaire par parties, c'est-à-dire, ici par snapshots. Ensuite l'évolution des nouveaux thèmes est vue comme la résolution d'un problème d'optimisation. La méthode de direction alternative des multiplicateurs (*Alternating Direction Method of Multipliers*, ADMM¹⁹) est utilisée en prenant en paramètre la probabilité de nouveauté du thème et la probabilité de sa disparition.

2.2.3 Méthodes basées sur les graphes

Quelques méthodes ont utilisé des outils basiques de la théorie des graphes, leur particularité est qu'elles laissent l'interprétation à la charge des experts métier.

Un graphe est un ensemble de points nommés sommets ou nœuds, reliés ou non par des arêtes. Formellement, un graphe $G = (V, E)$ est représenté comme suit :

1. $V = \{v_1, v_2, \dots, v_n\}$ l'ensemble de sommets/nœuds qui représentent les entités ou les individus qui interagissent entre eux ;
2. $E = \{e_1, e_2, \dots, e_m\}$ l'ensemble des arêtes qui représentent une connexion ou une interaction entre les nœuds, $e_i = (v_i, v_j) \in E$ est une arête qui relie les nœuds v_i et v_j .

$|V|$ est le nombre total de sommets appelé ordre, $|E|$ est le nombre total d'arêtes appelé taille, Δ est le degré maximum du graphe et D sa densité.

Le degré d'un sommet v_i , noté $d(v_i)$ est égal au nombre d'arêtes qui le relie aux autres sommets, c'est le nombre de ses voisins : $d(v_i) = |(v_i, v_j)|, (v_i, v_j) \in E, \forall v_j \in V$. La densité D est le rapport entre le nombre d'arêtes $|E|$ et le nombre d'arêtes possibles. Dans un graphe non orienté simple, la densité est donnée par : $\frac{2|E|}{|V|(|V| - 1)}$.

Un graphe orienté ou dirigé est un graphe dont les arêtes ont une direction. Dans ce cas nous ne parlons plus d'arêtes mais d'arcs. Un arc a une origine et une extrémité. Un graphe étiqueté

18. $z(x) = \frac{y-\mu}{\sigma}$ où y représente la valeur de la variable x dans le snapshot courant, μ sa fréquence moyenne dans les snapshots précédents et σ sa variance.

19. https://fr.wikipedia.org/wiki/Algorithme/_des/_directions/_alternees

2.2 Différentes méthodes d'identification d'un signal faible

ou pondéré (orienté ou non) est un graphe dont les arêtes sont affectées d'étiquettes (nombre, mot, lettre, symbole, etc.). Le graphe est pondéré quand les étiquettes sont des nombres réels positifs appelés poids.

Kwon et al. [114] utilisent la centralité d'intermédiarité (*betweenness centrality*) et les arbres couvrants de poids minimal (*Minimum Spanning Tree*, MST)²⁰ pour détecter les signaux faibles. Les auteurs construisent la matrice de co-occurrences entre mots-clés qui représentent les produits et services fournies par des sociétés. Cette matrice est vue comme un graphe où

- la centralité d'intermédiarité de chaque nœud est calculée; l'importance du rôle de diffuseur d'un nœud dans l'ensemble du graphe est ainsi mis en évidence. En conséquence, un signal faible apparaît comme le nœud ayant la plus petite valeur de centralité d'intermédiarité;
- le graphe étant grand, l'arbre couvrant minimal offre une visualisation du graphe plus compact.

Dans [148], les auteurs utilisent la centralité d'intermédiarité pour les arcs²¹ afin de détecter des opportunités technologiques à partir d'un graphe orienté de citations bibliographiques allant de 2006 à 2012. Les liens avec une valeur de centralité croissante peuvent être considérés comme des liens importants menant à des opportunités technologiques.

Dotsika et al. [50] cherchent à identifier des mots-clés indicateurs de technologies potentiellement disruptives. Leur étude porte sur sept domaines (impression 3D, Big Data, Bitcoin, technologies Cloud, IoT, MOOC et réseaux sociaux). Pour chacun des domaines, les mots-clés d'articles de recherche publiés en juin 2015 sont utilisés car ils sont considérés comme étant représentatifs du contenu de l'article. Un graphe de co-occurrences est construit où les nœuds sont les mots-clés et il existe un lien entre deux mots-clés s'ils apparaissent dans le même article. Les auteurs appliquent ensuite sur chacun des sept graphes des mesures classiques comme le degré moyen, la densité, le diamètre, le coefficient de clustering, les communautés avec Louvain qui permet de trouver des thèmes. Les sept graphes présentent les mêmes propriétés : un coefficient de clustering élevé, une faible densité (la plupart des mots-clés ne sont pas liés), une distribution de degré suivant une loi de puissance. Puis une analyse de la position des nœuds dans le graphe est faite avec les trois mesures classiques de centralité : centralité de degré, centralité d'intermédiarité et centralité de proximité. Les mesures de centralité correspondent ici à la popularité des mots-clés/thèmes et à l'influence qu'ils exercent sur les tendances. Le tableau 2.4 interprète les mesures deux à deux en regard de la notion de tendance, les cellules colorées en rouge correspondent aux mots-clés potentiellement annonceurs de tendances.

Bisson et al. [19] réalisent une étude qualitative, en utilisant la méthode de Delphes, pour identifier les facteurs de changements liés au marché du lait. La méthode de Delphes est une méthode qualitative qui consiste à interroger des experts avec une série de questionnaires. Les experts sont invités à revoir leurs réponses précédentes en tenant compte des positions des autres. Cette étude est confirmée par une étude quantitative qui exploite des mesures basiques sur les graphes : degré entrant et sortant, densité et 3- cliques.

20. Étant donné un graphe non orienté connexe dont les arêtes sont pondérées, un arbre couvrant de poids minimal de ce graphe est un arbre couvrant, c'est-à-dire un arbre qui connecte tous les sommets ensemble, dont la somme des poids des arêtes est minimale, c'est-à-dire de poids inférieur ou égal à celui de tous les autres arbres couvrants du graphe.

21. nombre de plus courts chemins qui traversent un arc.

	Faible degré de centralité	Faible centralité d'intermédiation	Faible centralité de proximité
Fort degré de centralité		Mot-clé populaire et fréquent où les liens le contournent	Mot-clé populaire vu comme une niche, intégré dans un cluster thématiquement éloigné du reste du graphe
Fort degré d'intermédiation	Mot-clé peu fréquent avec peu de liens mais importants pour les flux		Mot-clé vu comme une niche et monopolisant des liens entre des tendances fortes et marginales
Fort degré de proximité	Mot-clé central et peu fréquent liant des thèmes principaux	Mot-clé central et connu apparaissant sur beaucoup de chemins	

TABLE 2.4 – Détection des signaux faibles avec des mesures de centralité.

Certains chercheurs se sont intéressés aussi à l'identification de patterns spécifiques dans les réseaux, appelés motifs, qui pourraient être considérés comme des précurseurs d'évènements. Marco Baiesi [17] a présenté une méthode qui étudie les corrélations entre des graphes issus des tremblements de terre, en utilisant des outils sur la théorie des graphes. Après chaque réplique, un graphe qui représente un maillage de la terre, est construit où les nœuds sont les évènements ressentis et les arêtes leurs liens. Il mesure la distance entre les nœuds du graphe ainsi que leur coefficient de clustering. Il constate que des motifs simples tels que les triangles, constituent un type intéressant de précurseurs d'évènements majeurs car ils ont été trouvés dans les trois tremblements de terre étudiés.

D'autres approches ont étudié la détection et le rôle des motifs dans des évènements critiques tels que l'analyse de crimes [44] et la détection d'attaques dans un réseau de télécommunication [97].

2.2.4 Méthodes basées sur les réseaux bayésiens

Dans le domaine de l'intelligence économique²², l'objectif est de préfigurer les tendances du marché ou les évolutions d'un secteur d'activité. De fait, l'environnement, les marchés, les concurrents, les clients, les influenceurs mais aussi la technologie doivent être pris en compte pour identifier les signaux faibles. Ces signaux faibles permettent alors d'anticiper les risques, de saisir les opportunités et de réfléchir aux futurs axes de développement de l'entreprise. L'analyse d'impact est utilisée pour identifier les signaux faibles et les conséquences potentielles d'un changement. L'analyse d'impact s'appuie sur les réseaux bayésiens. Un réseau bayésien est un modèle graphique probabiliste représentant les relations entre un ensemble de variables aléatoires sous la forme d'un graphe orienté acyclique.

Seonho Kim et al. [107, 106] présentent un système appelé NEST (*New and Emerging Signals of Trends*) qui combine clustering et analyse d'impact pour identifier des signaux faibles. L'approche est composée de quatre étapes :

22. L'intelligence économique est une gestion de l'information et de la connaissance dans le but d'améliorer la compétitivité [25].

2.2 Différentes méthodes d'identification d'un signal faible

1. collecte de données par un groupe d'experts qui propose des documents, contrôle la non-duplication, vérifie l'opportunité et l'exactitude de l'information. Ce processus garantit une certaine qualité et cohérence des signaux évalués ;
2. regroupement des documents pour trouver de l'information similaire en utilisant l'outil KnowledgeMatrix²³. Chaque cluster est considéré comme un unique thème, nommé manuellement ;
3. analyse des thèmes à l'aide d'un tableau de bord permettant d'identifier les thèmes signaux faibles. La visibilité d'un thème est estimée par :
 - un indice d'évaluation conceptuelle, comme par exemple la portée de l'influence du thème : si le thème est local puis devient national alors son impact augmente ;
 - et une analyse d'impact grâce à un réseau bayésien qui estime l'impact des documents du cluster entre eux. L'objectif de l'analyse d'impact est d'évaluer les conséquences positives et/ou négatives d'un document sur le thème. La figure 2.7 présente le tableau de bord relatif au thème « interdiction des sacs en plastique dans les supermarchés » avec en abscisse le temps et en ordonnée l'impact. Le réseau bayésien se compose de cinq nœuds ayant pour label la distribution de probabilités conditionnelle $P(x|pa(x))$ avec $pa(x)$ les nœuds prédécesseurs de x ainsi que leur indice d'évaluation conceptuelle dans l'encadré en bas de figure. Dans la figure, le nœud A est le plus ancien et a un impact faible. Le nombre de tableaux de bord est égal au nombre de clusters ou thèmes, ce qui signifie que la méthode devient de plus en plus complexe avec l'augmentation de leur nombre et de leur taille.
4. évaluation des signaux faibles par le groupe d'experts en utilisant la méthode de Delphes.

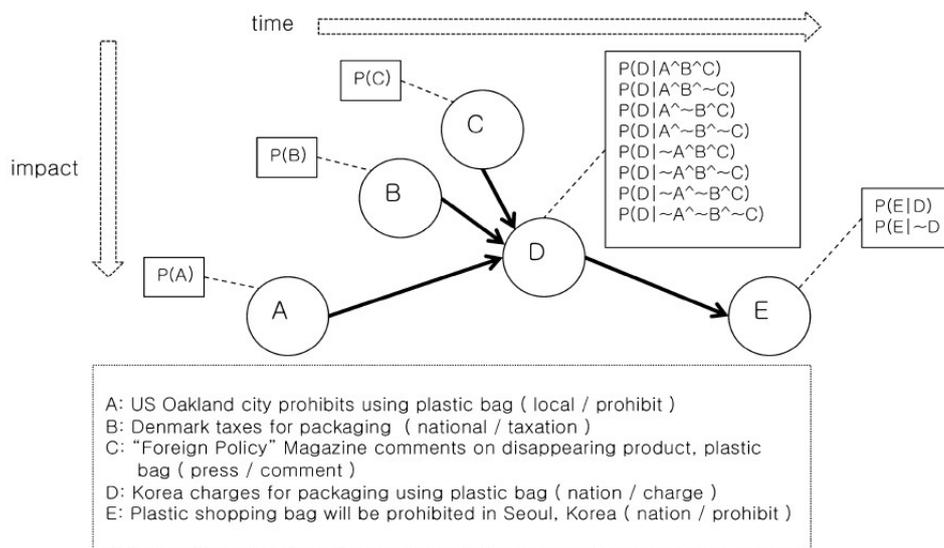


FIGURE 2.7 – Tableau de bord d'identification des signaux faibles, extrait de [107].

L'une des principales forces de NEST est le mécanisme mis en place pour garantir la qualité de l'ensemble de données créées. Mais NEST repose sur un groupe d'experts dans chacune de ses étapes et renvoie uniquement les signaux considérés comme potentiellement pertinents par les

23. Outil développé en scientométrie http://mirian.kisti.re.kr/km/km_en.jsp

experts. Cependant, les signaux faibles sont souvent négligés par les experts, et si l'ensemble des documents n'est pas assez vaste, le système peut être « aveugle » aux changements.

Bisson et al. [20] reprennent comme cas d'étude la prédiction du prix du lait en France qui est particulièrement volatile (voir page 35). Il s'agit d'anticiper les changements du marché grâce à une analyse d'impact des facteurs pouvant exercer une influence sur le prix, perçus comme des signaux d'alerte. L'analyse est réalisée *via* un réseau bayésien où différents facteurs environnementaux, politiques, santé sont pris en considération.

2.3 Synthèse et conclusion

La recherche sur les signaux faibles est largement influencée par les travaux d'Ansoff commencés dans les années 1970 [8]. En fonction des auteurs et des domaines, des synonymes comme pressentiment, signal d'alarme ont été proposés mais aussi des nuances dans les définitions avec l'emploi de différents adjectifs associés à signal comme faible, précoce, critique. En effet, les signaux faibles peuvent être utilisés dans de nombreux domaines, allant de la détection d'anomalie dans un système complexe comme un avion, jusqu'à la protection des individus avec la prévention de crimes, de harcèlement, mais aussi dans la prise de décisions et l'anticipation dans le cadre de la planification stratégique des entreprises en utilisant une démarche de retour d'expérience. Dans beaucoup de travaux, la notion de signal faible est considérée comme tellement commune qu'il n'existe pas de définition. En synthétisant l'ensemble des définitions proposées nous pouvons définir *un signal faible comme une donnée anodine qui fournit une indication sur des événements à venir ou émergents pouvant avoir des répercussions significatives sur le système*. Le modèle tri-dimensionnel de Hiltunen [82] à la fin des années 2000 a introduit l'importance d'un signal et la *gradation du signal de faible à fort*. Il a aussi mis en avant sa *rareté* et sa discordance avec le contexte courant. Ce modèle a permis, en mettant en lumière des caractéristiques des signaux faibles, de donner une définition opératoire de cette notion.

Dans ce chapitre, à partir de l'étude de la littérature sur le sujet, nous avons présenté des méthodes d'identification des signaux faibles. Pauline Rousseau et al. [165] ont aussi proposé un état de l'art sur les signaux faibles et les différentes méthodes d'identification. Comme nous avons pu le constater, l'immense majorité de ces méthodes travaillent sur des documents qu'elles analysent afin d'identifier des mots-clés comme étant des signaux faibles. Les méthodes que nous avons décrites sont basées :

- sur la fréquence d'apparition des mots-clés comme mesure de la visibilité du signal et sur le taux de croissance de cette fréquence comme mesure de la diffusion du signal ;
- sur le regroupement de mots-clés en thèmes où un signal faible se trouve dans un seul et même thème fortement cohérent et disjoint des autres avec un nombre d'occurrences de ces mots-clés généralement faible. Le regroupement en thèmes permet aux experts métier une meilleure interprétation. La construction des thèmes se fait soit à l'aide de techniques issues du Traitement Automatique des Langues soit à l'aide de techniques issues du Machine Learning.

D'autres méthodes, tout en travaillant toujours sur des mots-clés, se distinguent : l'une exploite la caractéristique d'anomalie du signal faible, les autres exploitent les relations entre les mots-clés sous la forme d'un graphe de co-occurrences mais utilisent des mesures basiques issues

2.3 Synthèse et conclusion

de la théorie de graphes pour détecter les mots-clés signaux faibles. Finalement, le domaine de l'Intelligence Économique se démarque car l'analyse d'impact est utilisée afin de déterminer les facteurs critiques à surveiller. La croissance du volume, la nature et la qualité des données ont favorisé la construction d'approches automatiques. Irimia et al. ont montré dans [93] que les méthodes automatiques de détection de signaux faibles sont aussi fiables que la détection manuelle réalisée par un expert métier. Elles ont pour avantage, par rapport à un humain, de pouvoir analyser de gros volumes de données maintenant disponibles.

Les Réseaux Sociaux Numériques (Facebook, Twitter, etc.), les blogs, les Webs journaux sont devenus des chambres d'écho à forte influence qui propagent rapidement de l'information entre des groupes sociaux importants. Les entreprises, les organismes gouvernementaux peuvent obtenir, à partir de ces données et en « temps réel », une vue de ce qui est susceptible de devenir important. Les travaux portent sur la popularité des messages, l'influence des utilisateurs, et l'émergence de thèmes de discussion mais peu de travaux concernent l'identification des signaux faibles. Comme les données issues des réseaux sociaux se composent de textes courts, par exemple 280 caractères maximum dans un tweet, et contiennent souvent des abréviations et des fautes d'orthographe, nous estimons que ces caractéristiques ne permettent pas d'utiliser les méthodes exploitant les mots-clés et leur regroupement en thèmes que nous avons présentées précédemment.

Un Réseau Social Numérique est souvent modélisé par un graphe d'interactions. Cette représentation permet de faire l'analyse des réseaux afin d'en extraire des caractéristiques. Par exemple, Azaza dans [15] propose une modélisation du réseau Twitter comme un réseau multiplexe hétérogène prenant en compte à la fois le contenu des tweets et les interactions entre les utilisateurs. Cette représentation d'un Réseau Social Numérique nous conduit à faire l'hypothèse que nous pouvons exploiter des éléments de la topologie du réseau pour identifier des signaux faibles. Des travaux utilisant la théorie des graphes [17, 44, 97] ont aussi conforté notre hypothèse selon laquelle les graphlets, qui sont des motifs particuliers, peuvent être des précurseurs d'évènements. Nous voulons aussi proposer des outils d'interprétation des signaux faibles plus complets qu'un regroupement en thèmes afin de pouvoir utiliser **la notion de signal faible comme un outil d'aide à la décision**. Nous considérons un signal faible comme une donnée d'apparence anodine mais dont l'interprétation faite par les experts métier peut déclencher une alerte. Le déclenchement de l'alerte indique que pourrait survenir un évènement susceptible d'avoir des conséquences importantes en termes d'opportunités ou de menaces.



Les chapitres suivants décrivent notre méthode BEAM qui permet de détecter et interpréter des signaux faibles dans un réseau d'interactions comme un réseau social de type Twitter ou Facebook. Le chapitre 3 est consacré à la détection des signaux faibles, c'est-à-dire, comment reconnaître qu'une information se présente comme un signal faible. Le chapitre 4 est dédié à l'interprétation des signaux faibles découverts, c'est-à-dire, comment un signal faible peut constituer un signal d'alerte précoce utile à l'organisation. Finalement, le chapitre 5 est consacré aux différentes expérimentations mises en œuvre, leur objectif est de montrer la robustesse de BEAM et la reproduction des résultats.

Deuxième partie

Contributions

BEAM : ÉTAPE DE DÉTECTION DES SIGNAUX FAIBLES

Sommaire

3.1	Graphlets	45
3.1.1	Définitions des notions de graphlets et d'orbites	45
3.1.2	Énumération des graphlets	47
3.1.3	Choix de l'algorithme pour l'énumération des graphlets	50
3.2	Préparation des données	52
3.2.1	Présentation des données brutes	52
3.2.2	Nettoyage et filtrage de données : construction du corpus d'étude	53
3.2.3	Structure et temps : construction de snapshots de graphes	54
3.3	Signature d'un signal faible	56
3.3.1	Mise en place de l'outillage nécessaire à la détection des signaux faibles	56
3.3.2	Estimation du renforcement du signal : diffusion et amplification	58
3.3.3	Identification des précurseurs	59
3.4	Détection des signaux faibles	61
3.5	Confirmation par une méthode statistique : cross-correlation	62
3.6	Synthèse et conclusion	65

ANSOFF, dans [9], explique qu'un signal faible contient des informations partielles disponibles au moment où une réponse doit être apportée. Ces informations doivent être complétées avant que le signal devienne fort et ait un impact sur l'entreprise. Ainsi, l'identification d'un signal faible doit pouvoir annoncer un événement futur, sa nature (opportunité ou menace), son impact potentiel et le délai avant son apparition. Le processus de réalisation de ces étapes a été décrit par Ansoff comme une réponse graduée par amplification des signaux faibles par rapport au niveau d'information. L'objectif de notre méthode BEAM est d'établir un processus systématique de détection et d'interprétation des signaux faibles en utilisant des données que nous modélisons sous la forme d'un graphe d'interactions temporelles, telles que

des informations provenant des Réseaux Sociaux Numériques. BEAM met en place une méthode quantitative afin d’automatiser le processus de détection des signaux faibles et base la partie interprétation sur des méthodes qualitatives offrant des informations supplémentaires aux experts métier pour leur permettre de prendre des décisions.

Notre méthode BEAM est basée sur un *pipeline* standard de traitement de données qui comprend la collecte et l’exploitation des données, avant la détection des signaux faibles, comme illustrée dans les étapes un à quatre de la figure 3.1 et détaillée dans la suite de ce chapitre.

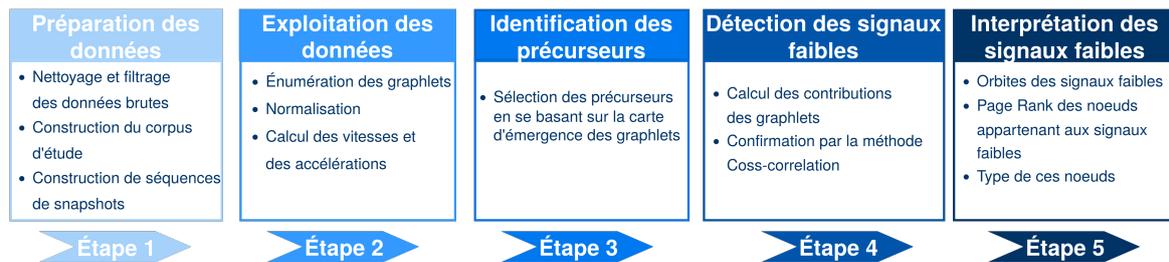


FIGURE 3.1 – Les grandes étapes de notre méthode BEAM.

Dans la première étape, nous traitons les données brutes collectées, et construisons le corpus de l’étude qui est ensuite divisé en snapshots de même durée. Dans la deuxième étape, nous exploitons les données du corpus d’étude, en appliquant des algorithmes et des mesures d’analyse de la topologie du réseau pour chaque snapshot. En effet, notre hypothèse est que la topologie du réseau joue un rôle important dans la propagation de l’information. Il a été montré que les graphlets, qui sont des petits *patterns ou motifs*, étaient de bons résumés de la variabilité des interactions dans les réseaux sociaux [174]. Nous avons donc décidé d’utiliser les **graphlets comme description opératoire pour détecter les signaux faibles** dans un graphe d’interactions temporelles. En effet, les graphlets présentent des caractéristiques généralement associées aux signaux faibles. Ils sont :

- fragmentaires et peu visibles car ce sont de petits sous-graphes ;
- peu significants, en effet pris isolément un sous-graphe d’au plus cinq nœuds ne signifie pas grand-chose dans la masse de données produites par les réseaux sociaux ;
- interprétables par les experts métier au moyen de leurs formes prédéfinies et de leurs orbites.

En se basant sur leur énumération, les graphlets permettent de détecter des précurseurs et dans la quatrième étape, nous définissons des critères pour qualifier les précurseurs identifiés en signaux faibles. Finalement nous avons une étape d’interprétation des signaux faibles décrite dans le chapitre 4. Les graphlets laissent une place à l’interprétation par des experts métier, gommant ainsi l’effet « boîte noire » que pourrait avoir une méthode entièrement automatisée. Toutes ces étapes peuvent être itérées à différents niveaux : 1) les étapes deux à cinq sont itérées sur chaque snapshot jusqu’à ce que les signaux faibles deviennent des signaux forts ou de faux signaux d’alerte ; 2) la détection des signaux faibles et leur interprétation peut remettre en cause le corpus d’étude et le processus reprend alors à la première étape avec la modification du corpus d’étude.

Dans ce chapitre, nous présentons en section 3.1 les graphlets et leurs algorithmes d’énumération puis la partie détection des signaux faibles de notre méthode BEAM.

3.1 Graphlets

3.1 Graphlets

Les graphlets sont des types de motifs particuliers dans un réseau, ils ont une taille allant de deux jusqu'à cinq nœuds (trente types de graphlets) choisis parmi les nœuds d'un grand graphe. Grâce à leurs tailles et à leurs formes prédéfinies, ils sont faciles à interpréter par des experts métier.

3.1.1 Définitions des notions de graphlets et d'orbites

Un sous-graphe est considéré comme un motif s'il présente une caractéristique particulière ou s'il est en quelque sorte exceptionnel. La notion de motif a été définie par Milo et al. en 2002 [140], les motifs sont basés sur l'idée que *l'on trouve dans des réseaux représentant un large éventail de phénomènes naturels (Réseaux Sociaux, circuits électriques, connexions entre neurones, réseaux biochimiques) des modules [motifs] qui définissent des fonctions spécifiques.* Les motifs sont de petits sous-graphes partiels qui sont statistiquement sur-représentés dans les réseaux biologiques comparés à un réseau aléatoire utilisé comme référence. Des superfamilles de motifs présentant des caractéristiques communes ont été mis à jour [139]. Par exemple, dans un réseau de liens hyper-textes et dans les réseaux sociaux, la triade  est sur-représentée alors que la triade  est sous-représentée. Le problème avec les motifs est que le choix des réseaux aléatoires peut affecter les résultats d'où la notion de graphlets introduite pour la première fois par Nataša Pržulj [157] en biologie moléculaire et notamment dans le cadre de l'étude des interactions entre protéines.

Graphlets Les graphlets d'un graphe $G = (V, E)$ sont l'ensemble de ses sous-graphes de 2 à 5 nœuds, induits connectés non isomorphes.

Les graphlets peuvent être employés sans référence à un réseau aléatoire. Ceux sont des sous-graphes induits alors que les motifs sont des sous-graphes partiels.

En théorie des graphes, un sous-graphe induit est un sous-ensemble des nœuds du graphe d'origine et de **toutes** leurs arêtes présentes dans le graphe d'origine. Un isomorphisme de deux graphes G et G' est une correspondance entre les ensembles de nœuds de G et de G' , de sorte que si deux nœuds sont adjacents dans G , ils sont adjacents dans G' c'est-à-dire que chaque sommet a exactement les mêmes voisins dans les deux graphes. En d'autres termes, deux graphes sont isomorphes si ce sont les mêmes graphes mais « dessinés » différemment. Formellement, deux graphes $G = (V, E)$ et $G'(V', E')$ sont isomorphes si il existe une bijection $\phi : V \rightarrow V'$ avec $(u, v) \in E \iff (\phi(u), \phi(v)) \in E' \forall (u, v) \in V$. La figure 3.2 montre deux graphes isomorphes.

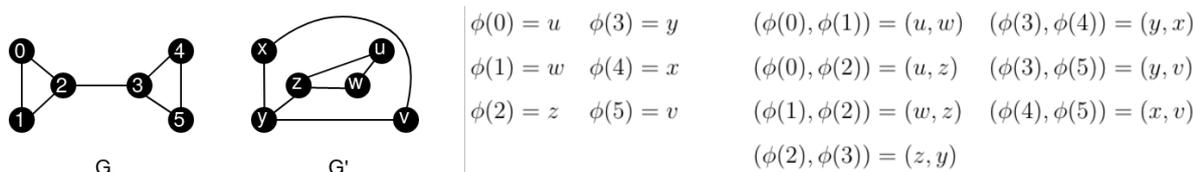


FIGURE 3.2 – Deux graphes G et G' isomorphes et leur bijection ϕ .

Il existe trente graphlets jusqu'à cinq nœuds, notés de G_0 à G_{29} : le graphlet $G_0 \rightsquigarrow$ de taille 2,

deux graphlets de taille trois qui sont $G_1 \dashrightarrow$ et $G_2 \triangle$, six graphlets de taille quatre et vingt-un graphlets de taille cinq.

Orbites Un élément essentiel des graphlets est les orbites [156]. Un automorphisme d'un graphe G est une permutation de l'ensemble de ses sommets telle que pour tous sommets $u, v \in V$, une arête relie u à v si et seulement si une arête relie $\phi(u)$ à $\phi(v)$. On dit que deux sommets u et v d'un graphe G sont équivalents si et seulement si il existe un automorphisme de G vers lui-même qui envoie u sur v . On appelle orbites les classes d'équivalence des graphlets. Si u est un nœud du graphe G alors $Orbite(u) = \{v \in V | v = \phi(u)\}$. Le degré des nœuds est ici généralisé à un vecteur de soixante-treize coordonnées (O_0 à O_{72}) représentant les orbites des trente graphlets. Ils sont vus comme les positions ou rôles occupés par les nœuds des graphlets. Les graphlets de deux jusqu'à cinq nœuds sont présentés dans la figure 3.3, avec leurs orbites correspondantes numérotées de 0 à 72; dans un même graphlet, les nœuds appartenant à une même orbite (même couleur) sont interchangeable. Par exemple, le graphlet G_4 qui est en forme d'étoile $\begin{matrix} \bullet \\ | \\ \bullet \\ / \backslash \\ \bullet \end{matrix}$, possède deux positions, la première est centrale (orbite O_7) occupée par un sommet, et la deuxième est périphérique (orbite O_6) et partagée par les trois autres sommets.

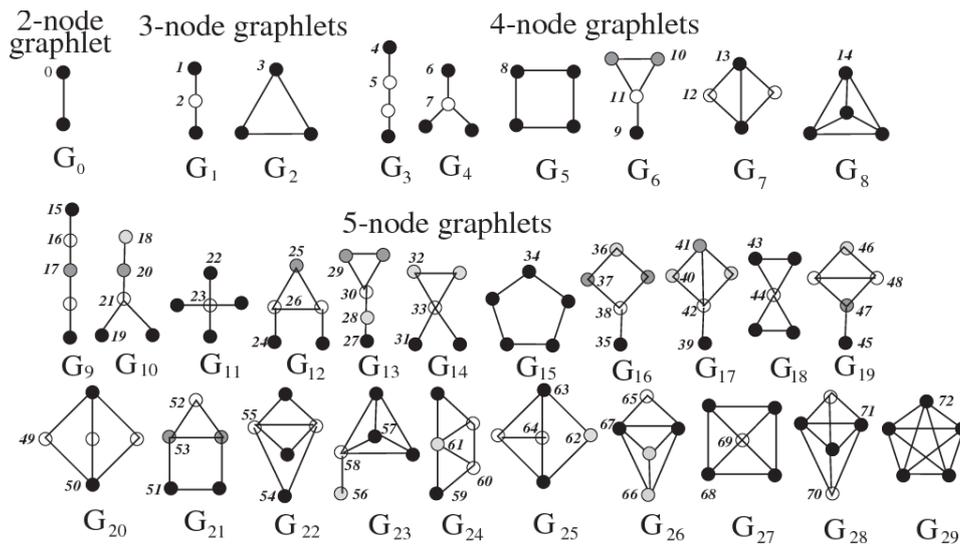


FIGURE 3.3 – Représentation des trente graphlets et des soixante-treize orbites allant de 2 à 5 nœuds.

Les graphlets ont aussi été étendus aux graphes pondérés [174], graphes orientés [11], graphes multiplexes [48], graphes temporels [91],[12]. La figure 3.4 montre les quarante-neuf graphlets orientés jusqu'à la taille quatre et leurs cent quarante-huit orbites.

Comme le montre le tableau 3.1, l'inconvénient des graphlets orientés est leur explosion en nombre qui rend difficile à la fois leur énumération et leur interprétation. Cela a été confirmé par une expérimentation menée dans le cadre d'un projet tuteuré de Master 2 Informatique parcours Bases de Données - Intelligence Artificielle ¹.

1. Cette expérimentation portait sur 700 000 tweets émis entre le 3 et le 5 juillet 2012 et relatifs à la découverte du Boson de Higgs. Le jeu de données est disponible sur <https://snap.stanford.edu/data/higgs-twitter.html>. Le 4 Juillet 2012 le CERN annonce avoir identifié le Boson de Higgs. Pour énumérer les graphlets orientés, le choix s'est porté sur le logiciel GT-scanner, <https://www.dcc.fc.up.pt/~daparicio/software.html>. En moyenne,

3.1 Graphlets

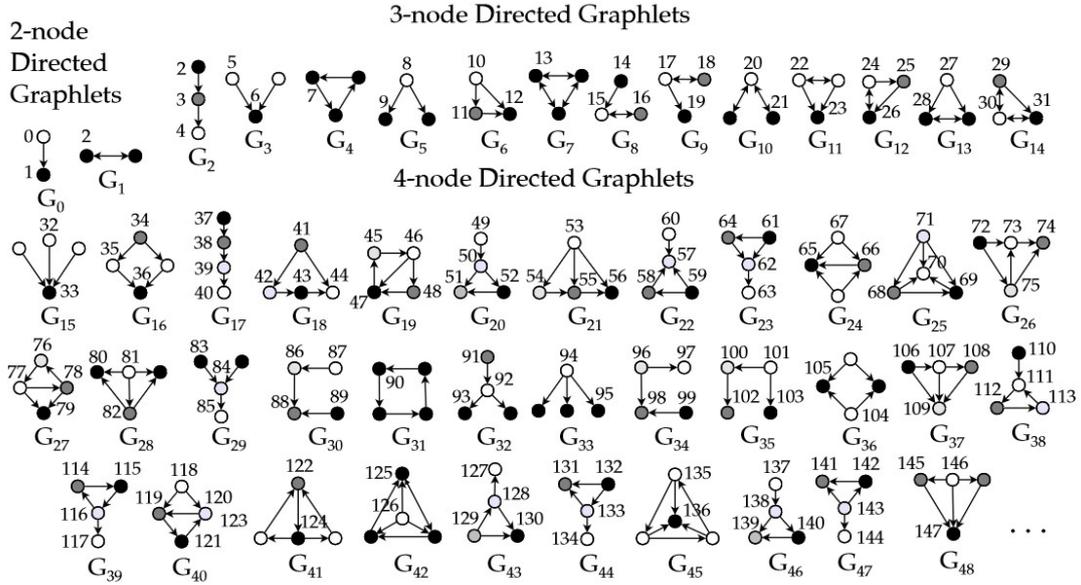


FIGURE 3.4 – Extrait de graphlets orientés jusqu'à la taille quatre et leurs orbites, extrait de [10].

Taille	Graphe non orienté		Graphe orienté	
	$ G_k $	$ O_k $	$ G_k $	$ O_k $
2	1	1	2	3
3	3	4	15	33
4	9	15	214	730
5	30	73	9 578	45 637
6	142	480	1 540 421	9 121 657

TABLE 3.1 – Nombre de graphlets non orientés et orientés ainsi que leurs orbites respectives en fonction de leur taille.

En annexe A, nous présentons des compléments sur les graphlets : mesures définies sur les graphlets et utilisation des graphlets dans différents domaines connexes aux signaux faibles comme la diffusion de l'information, la viralité, la prédiction de tendances et d'anomalies.

3.1.2 Énumération des graphlets

De nombreux algorithmes et méthodes ont été élaborés pour énumérer les motifs [94] puis les graphlets. L'énumération des graphlets de taille k présente une complexité en $O(|V| \times \Delta^{k-1})$ où $|V|$ est le nombre de sommets et Δ le degré maximum du graphe. Les nombreux algorithmes d'énumération de graphlets ont eu pour objectif de réduire cette complexité. Un état de l'art sur l'énumération des graphlets a été réalisé par Ribeiro et al. en 2019 [160], dans lequel ils ont donné un aperçu des algorithmes existants et mis en évidence leurs principaux avantages et limites. Ils fournissent une description des algorithmes et de leurs implémentations en donnant des informations sur leur précision avec les algorithmes d'énumération exacts (ESU/-

110 graphlets orientés été identifiés comme signaux faibles par snapshot d'une heure. GT-scanner n'énumérant pas les orbites, l'interprétation était extrêmement difficile.

FANMOD, RAGE, Orca) et les algorithmes d'énumération approximatifs (ESA, RAND-ESU) ainsi que leur temps d'exécution. L'énumération exacte des graphlets consiste, pour toutes les instances² de sous-graphes, à les compter et les catégoriser c'est-à-dire à déterminer les classes d'isomorphisme.

Méthodes d'énumération classiques

Les premières méthodes dénombrent d'abord tous les sous-graphes ayant k nœuds et seulement après elles catégorisent chaque sous-graphe trouvé.

Milo et al. [98] ont proposé *mfinder*³, un algorithme pour compter les motifs. *mfinder* est un algorithme de *backtracking* récursif appliqué à chaque arête du graphe. *mfinder* commence par choisir une arête qui est le premier motif du graphe constitué des deux sommets de l'arête. À chaque itération, il ajoute un nouveau sommet situé à l'extrémité d'une arête reliée au motif du sous-graphe généré et ainsi de suite jusqu'à obtenir k nœuds connectés. Il s'arrête lorsque chaque arête a été explorée comme sous-graphe à deux nœuds. Par exemple, dans un réseau avec seulement trois nœuds a , b et c entièrement connectés, c'est-à-dire une clique, *mfinder* trouve six instances de sous-graphes : $\{a, b, c\}$, $\{a, c, b\}$, $\{b, a, c\}$, $\{b, c, a\}$, $\{c, a, b\}$ et $\{c, b, a\}$. Pour éviter de compter la même instance de sous-graphe plusieurs fois, *mfinder* utilise *nauty*⁴, un outil d'isomorphisme pour obtenir une représentation canonique des instances du sous-graphe, dans l'exemple les six instances ont une classe canonique $\{a, b, c\}$. En pratique, *mfinder* stocke la première instance de la classe canonique dans une table de hachage et, lorsqu'une répétition de l'instance est trouvée, il n'augmente pas sa fréquence, l'inconvénient est que *mfinder* effectue des calculs redondants.

ESU (Enumerate SUBgraphs) [188] améliore *mfinder* en ne comptant jamais le même sous-graphe deux fois, et en ne les stockant pas tous dans une table de hachage.

ESU utilise la notion de voisinage d'un nœud : $N(u)$ correspond aux voisins du nœud u et $N_{exc}(u, V)$ le voisinage exclusif de u avec $N_{exc}(u, V) = \{v | v \in N(u), \forall w \in V, v \notin N(w)\}$. De plus chaque nœud u est identifié par un numéro unique $L(u)$ qui sert de racine à l'énumération de l'ensemble des sous-graphes connexes le contenant. Contrairement à l'algorithme *mfinder* qui commence par une arête, l'algorithme ESU commence par un nœud u , puis il explore ses voisins non encore visités pour construire tous les sous-graphes possibles ne contenant que des nœuds d'indice supérieur à celui de la racine. Il utilise deux ensembles VS et VE qui contiennent l'ensemble des nœuds candidats à l'extension. Ils sont initialisés par $VS = \{u\}$ et $VE = N(u)$. Ensuite, pour chaque nœud v appartenant à VE , v est retiré de VE et ajouté dans VS si le sous-graphe n'est pas déjà présent et VE est re-calculé comme suit $VE = VE \cup \{z \in N_{exc}(v, VS) | L(z) > L(u)\}$. Ce processus est répété jusqu'à ce que VS comporte k nœuds. À la fin du processus, ESU effectue des tests d'isomorphisme pour évaluer la catégorie de chaque sous-graphe. L'outil *FanMod*⁵ [189] énumère les motifs à l'aide de l'algorithme *Rand-ESU*, il comporte une interface graphique qui permet de configurer les paramètres de l'algorithme comme la taille des motifs.

2. Nous utilisons le terme instance pour désigner une occurrence individuelle ou une apparition d'un motif/graphlet.

3. <https://www.weizmann.ac.il/mcb/UriAlon/download/network-motif-software>

4. <http://users.cecs.anu.edu.au/~bdm/nauty/>

5. <https://bio.tools/fanmod>

3.1 Graphlets

Méthodes analytiques

Dans les méthodes d'énumération analytiques, une matrice d'équations linéaires entre les orbites des graphlets est construite, les équations sont résolues en utilisant les méthodes traditionnelles de l'algèbre linéaire.

Orca [88] compte les orbites de chaque nœud à partir d'une liste d'équations décrivant les relations qui existent entre le nombre d'apparition de ces orbites : pour un nœud du graphe, le nombre de ses orbites appartenant au graphlet de taille k est déduit des orbites appartenant aux graphlets de taille $k - 1$ et de la connaissance des liens entre ses voisins et les sommets qui sont à une distance de deux. Un exemple d'équation est :

$$2O_9 + 2O_{12} = \sum_{y,z|x,z \in N(y)G[\{x,y,z\}] \simeq G_1} c(y, z)$$

avec $c(y, z) = |N(y) \cap N(z)|$ et $G[\{x, y, z\}] \simeq G_1$ signifie qu'il s'agit d'un chemin à trois nœuds. La figure 3.5 illustre cette formule. Les lignes pleines représentent le graphlet G_1 et les lignes pointillées représentent son extension vers un graphlet de taille 4 (G_6 ou G_7) avec w , le nœud commun à y et z .

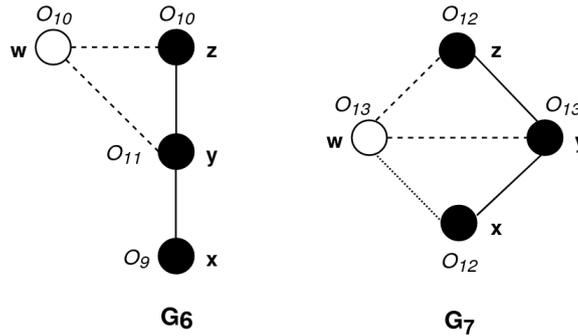


FIGURE 3.5 – Relations entre les orbites O_9 et O_{12} et le graphlet G_1 .

L'ensemble des équations pour les graphlets de tailles quatre et cinq est donné dans [87]. Orca a une complexité de $O(|E| \times \Delta)$ pour une énumération de graphlets jusqu'à quatre nœuds, et une complexité de $O(|E| \times \Delta^2)$ pour une énumération jusqu'à cinq nœuds.

ESCAPE [152] est un autre type d'approche analytique. ESCAPE est basé sur le paradigme « diviser pour régner » qui identifie des petits motifs comme des triangles, des chemins dans chaque sous-graphe que l'on veut énumérer. Si on choisit correctement la décomposition, il est alors possible de décrire un ensemble de formules pour calculer la fréquence de chaque sous-graphe. Pinar et al. décrivent uniquement les formules pour les graphlets de taille cinq. L'algorithme RAGE [133] fait partie de cette catégorie, RAGE est très efficace pour les grands graphes mais est limité aux graphlets à quatre nœuds.

Une limite des méthodes analytiques est qu'elles ne renvoient que le nombre de graphlets, elles ne peuvent pas être utilisées quand on a besoin non seulement des graphlets mais aussi des instances de graphlets.

Au fil des années, d'autres approches ont été proposées pour paralléliser l'énumération des graphlets. Par exemple, Milinković et al. [138] ont proposé une extension d'Orca à l'architecture GPU.

Le tableau 3.2 résume les différents algorithmes présentés. Nous avons marqué la dernière colonne du tableau par des étoiles ** pour les algorithmes ESU/FANMOD et RAND-ESU, puisque que leur complexité théorique n'est pas abordée dans les travaux de la littérature.

Méthode	Algorithme	Énumération	k restriction	Orbites	Complexité
Classique	mfinder (2002)	exacte	aucune	✗	$O(V ^{ V })$
	ESU/FANMOD (2005)	exacte	aucune	✗	**
	RAND-ESU	approximative	aucune	✗	**
Analytique	RAGE (2012)	exacte	≤ 4	✓	$O(E \times \Delta \times E ^2)$
	Orca (2014)	exacte	≤ 5	✓	$O(E \times \Delta^2)$

TABLE 3.2 – Résumé des algorithmes présentés d'énumération de graphlets.

Nous avons présenté la notion de graphlets et quelques algorithmes pour leur énumération. Dans la suite, nous allons décrire les critères sur lesquels nous nous sommes appuyés pour choisir l'algorithme d'énumération des graphlets dans BEAM, notre choix est confirmé par une étude expérimentale de l'algorithme choisi, Orca.

3.1.3 Choix de l'algorithme pour l'énumération des graphlets

Pour choisir l'algorithme le plus approprié pour compter les graphlets et les orbites dans les graphes étudiés, nous avons défini quatre critères :

1. l'énumération exacte des graphlets jusqu'à cinq nœuds ;
2. l'énumération des orbites ;
3. une complexité acceptable ;
4. la disponibilité du code source.

Le premier critère assure l'exhaustivité des graphlets. Le deuxième critère assure l'interprétabilité des résultats par l'étude de la forme et du rôle des nœuds dans les graphlets. Les deux autres critères garantissent que la méthode proposée est réalisable.

En se référant au tableau 3.2, le premier critère élimine l'algorithme RAGE et le deuxième critère élimine les algorithmes d'énumération classique qui ne fournissent aucun renseignement sur les orbites. Afin de valider le choix d'Orca, nous avons effectué une analyse expérimentale pour évaluer la complexité de son implémentation.

Analyse expérimentale d'Orca La complexité temporelle d'Orca peut varier en fonction de l'implémentation spécifique et de la densité du graphe en entrée. En général, le temps de traitement de l'algorithme croît comme une fonction polynomiale de la taille des données, et non à un rythme exponentiel. Pour mesurer les performances et le temps de réponse d'Orca, nous avons envisagé deux types d'expériences : une qui fixe le nombre de nœuds et qui augmente le nombre d'arêtes ; et l'autre qui fixe le nombre d'arêtes et qui augmente le nombre de nœuds.

Dans le premier cas, nous avons généré des graphes aléatoires ayant un nombre de nœuds fixé à 200, en augmentant le nombre d'arêtes de 100 jusqu'à obtenir une densité égale à 1. La figure 3.6 représente le temps de réponse d'Orca en fonction de la densité des graphes étudiés. Dans cette figure, nous remarquons qu'il existe des seuils. Tant que la densité du graphe est

3.1 Graphlets

inférieure à 0,4, le temps de réponse est inférieur à 10 secondes, pour une densité comprise entre 0,4 et 0,6, le temps de réponse passe de 10 à 40 secondes (le temps est multiplié par quatre), et pour une densité égale à 0,85, le temps de réponse est de 80 secondes.

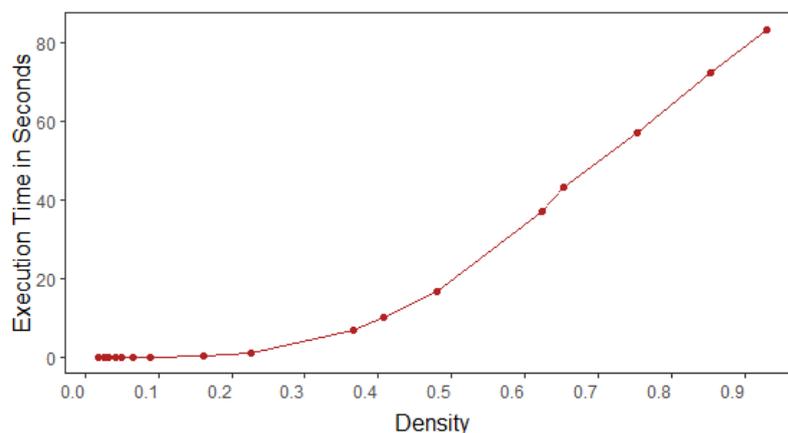


FIGURE 3.6 – Temps de réponse d’Orca avec des graphes de 200 nœuds dont la densité croît.

Pour le deuxième type d’expérience, nous avons conçu un ensemble expérimental mesurant le temps de réponse d’Orca sur des graphes ayant le même nombre d’arêtes mais en faisant varier le nombre de nœuds jusqu’à atteindre 80% du nombre d’arêtes. Nous avons décidé de prendre comme nombre d’arêtes : 2 500, 5 000, 10 000 et 100 000 respectivement. Ces quatre valeurs ont été choisies car l’application de la méthode BEAM sur plusieurs jeux de données de différentes tailles a montré que les graphes dans les snapshots ont en moyenne 5 000 arêtes. Le tableau 3.3 contient un extrait des propriétés des graphes utilisés dans l’expérience. La première colonne contient le nombre d’arêtes fixé à 5 000 et à 10 000, la deuxième est le nombre croissant de nœuds, la troisième et la quatrième colonnes représentent respectivement la densité des arêtes et le degré maximal des nœuds. La dernière colonne montre le temps de réponse d’Orca en millisecondes. Nous avons distingué en rouge les valeurs les plus élevées, et en bleu les valeurs les plus faibles. Nous remarquons que plus la densité est faible, plus le temps d’exécution est court. Par ailleurs, même si le graphe a plus de nœuds et d’arêtes (par exemple le graphe ayant 4 000 nœuds et 5 000 arêtes), le degré maximal des nœuds demeure faible par rapport au nombre d’arêtes (égal à 9), ce qui révèle la présence de nœuds isolés conduisant à un temps de réponse court.

Ces deux expériences confirment le comportement théorique de l’algorithme : le temps de réponse dépend de la densité du graphe.

Nous concluons qu’Orca répond aux quatre critères requis, son code source est disponible sur le lien suivant :

https://rdr.io/github/alan-turing-institute/network-comparison/src/R/orca_interface.R

Pour la méthode BEAM, nous avons décidé de travailler sur des graphes non orientés non pondérés, qui sont en plus les types de graphes traités en entrée de l’algorithme Orca que nous avons choisi. Dans la suite nous présentons l’étape de détection de BEAM.

Arêtes	Nœuds	Densité	Degré max	Temps écoulé (en millisecondes)
5 000	500	0.04	36	118
	600	0.027	31	85
	1 500	0.004	17	23
	2 400	0.002	13	16
	3 500	0.0008	10	14
	4 000	0.0006	9	13
10 000	1 000	0.02	35	258
	1 500	0.009	25	110
	3 300	0.002	16	45
	5 200	0.0007	13	32
	7 000	0.0004	11	29
	8 000	0.0003	11	28

TABLE 3.3 – Extrait de l’expérience menée pour mesurer le comportement d’Orca sur des graphes dont le nombre d’arêtes est fixé.

3.2 Préparation des données

Pour atteindre l’objectif de notre méthode, la préparation des données en entrée et leur pré-traitement en vue de leur exploitation est une étape primordiale. Dans la suite, nous décrivons la phase préparatoire (filtrage et traitement) jusqu’au processus d’exploitation et d’analyse des données.

3.2.1 Présentation des données brutes

La méthode BEAM s’applique à tous types de données qui peuvent se modéliser par un grand réseau d’interactions. Les données issues de l’activité d’un Réseau Social Numérique comme Twitter et Facebook, d’un réseau de télécommunication ou encore de transactions financières peuvent être vues comme des graphes. Chaque interaction prend la forme d’un lien entre deux entités apparaissant au déclenchement de l’interaction.

La méthode BEAM prend en entrée des données sous la forme d’une liste d’interactions où chaque ligne représente un tuple à trois composantes ayant la forme (u, v, t) , où u et v sont les identifiants des entités en contact (soit par exemple des comptes des utilisateurs de Twitter, ou bien deux hashtags qui se trouvent dans le même tweet), t détermine le moment auquel l’interaction a eu lieu. Le temps peut prendre différents formats comme une chaîne de caractères ou un timestamp epoch⁶, etc. Le tableau 3.4 montre un exemple d’interactions. Si plusieurs interactions ont eu lieu au même moment, nous trouvons plusieurs lignes ayant la même valeur sur la composante t dans la liste des interactions. Dans ce tableau, les deux premières lignes représentent des interactions entre les entités 1 et 2 à deux dates différentes ($t = 1643207148$ et $t = 1643207149$). Les quatre dernières lignes du fichier représentent quatre interactions existantes entre des paires différentes d’entités pour le même temps ($t = 1643207150$).

6. Nombre de secondes écoulées depuis le 1er janvier 1970 à 00 h ; par exemple le "26/01/2022 15 :25 :48" correspond au timestamp 1643207148.

3.2 Préparation des données

u	v	t
1	2	1643207148
1	2	1643207149
2	3	1643207149
1	3	1643207150
2	1	1643207150
2	3	1643207150
2	4	1643207150

TABLE 3.4 – Exemple d’interactions.

3.2.2 Nettoyage et filtrage de données : construction du corpus d’étude

Le corpus global est constitué de la liste brute des interactions avant qu’elles ne soient traitées et filtrées. En se basant sur cette liste brute et sur le contexte de l’étude, il est possible de réduire les données de ce corpus en précisant des critères pour ne sélectionner que les données qui correspondent aux critères choisis en collaboration avec des experts métier. Dans le cadre du projet Cocktail, nous travaillons cette étape en collaboration avec une équipe regroupant des chercheurs en communication et en sciences humaines et sociales. Les critères de filtrage peuvent être sous la forme d’une liste de hashtags ou de comptes Twitter qui correspondent à un sujet d’intérêt. Cette phase est importante car l’identification des signaux faibles n’a de sens que dans un contexte bien défini, et la qualité des données filtrées détermine la fiabilité du processus décisionnel.

Une fois les données filtrées selon les critères choisis, elles sont transformées en un nouvel ensemble qui correspond au corpus de l’étude. Généralement, le corpus de l’étude comprend un nombre d’interactions inférieur à celui du corpus global. Lorsque nous faisons une identification des signaux faibles *a posteriori*, la fin de la période de l’étude doit être déterminée. La figure 3.7 illustre la phase de construction du corpus de l’étude à partir du corpus global des données.

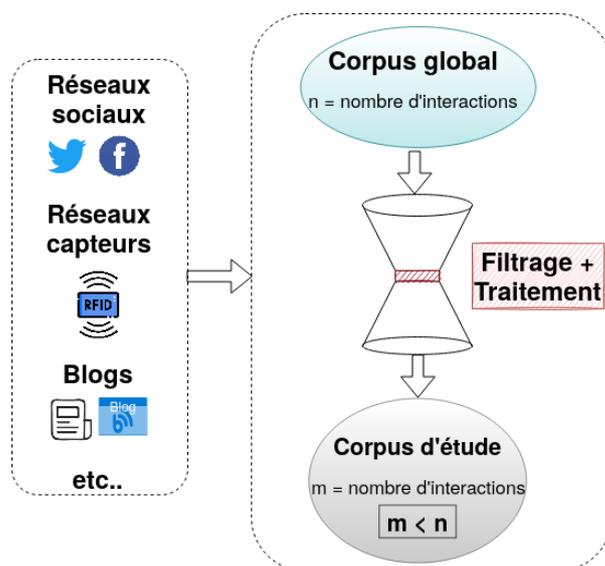


FIGURE 3.7 – Construction du corpus de l’étude à partir des données brutes.

Formellement, les données du corpus d'étude regroupent les interactions temporelles entre un ensemble de nœuds au cours du temps sur une période $T = [\alpha, \beta]$,

$$\mathfrak{X} = \{(u, v, t) \mid t \in T \text{ et } u, v \in V\},$$

tel que $(u, v, t) \in \mathfrak{X}$ indique que u interagit avec v à l'instant t , ces données sont ordonnées sur le temps T .

3.2.3 Structure et temps : construction de snapshots de graphes

Ces interactions temporelles (u, v, t) sont souvent étudiées soit comme une série temporelle dans laquelle la dimension structurelle est oubliée, soit comme un graphe dans lequel la dimension temporelle est omise. Ceci permet de tirer parti du large ensemble de méthodes à disposition pour analyser ces deux objets mais ils représentent mal la nature à la fois temporelle et structurelle des interactions et provoquent des pertes d'information. De nombreux travaux ont été menés pour enrichir ces approches. Certains chercheurs les étudient à l'aide d'une séquence temporelle de graphes statiques, d'autres avec des graphes augmentés qui intègrent l'information temporelle, d'autres encore les étudient en tant que flots de liens [85]. La figure 3.8 synthétise ces différentes représentations et l'annexe B présente en détail les notions de graphes augmentés et flots de liens.

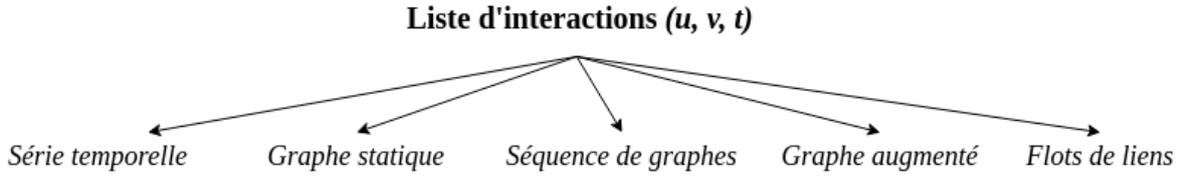


FIGURE 3.8 – Représentations possibles à partir d'une liste d'interactions à trois composantes.

Notre méthode de détection des signaux faibles reposant sur la topologie du réseau et le temps étant un élément déterminant, nous avons choisi de représenter les interactions temporelles sous la forme d'une séquence de $s \in \mathbb{N}$ graphes statiques $\mathfrak{G} = \{S^i \mid i \in \{1, \dots, s\}\}$ où S^i , appelé snapshot i , est le graphe non orienté et non pondéré contenant toutes les interactions qui se sont produites entre les instants $t_i = \alpha + i\Delta t$ et $t_{i+1} = \alpha + (i+1)\Delta t$, Δt est une durée constante pour tous les snapshots représentant un jour, une heure, trente minutes, dix minutes, etc. Le but de Δt est alors de connecter des nœuds en fonction du temps, de telle sorte que deux snapshots consécutifs S^i et S^{i+1} soient Δt -adjacents.

À partir des interactions présentées en haut de la figure 3.9 et correspondant au graphe étiqueté dans la figure B.1 de l'annexe B, nous illustrons l'évolution des nœuds et des liens dans des snapshots consécutifs, $S^1, S^2 \dots S^s$ avec $\Delta t = 4$ la durée de chaque snapshot. Nous remarquons qu'il y a eu des changements dans la structure des sous-graphes représentant ces snapshots. Par exemple, une nouvelle arête (B, D) est apparue dans S^2 et les arêtes (A, C) , (C, D) et (B, D) qui existaient dans S^2 , ont disparu dans le snapshot S^3 ainsi que le nœud C . Formellement,

$$S^i = (V_i, E_i) \text{ tel que } \begin{cases} V_i = \{u_i \mid (u_i, v_i, t) \in \mathfrak{X} \text{ et } t \in [t_i, t_{i+1}[] \cup \\ \quad \{v_i \mid (u_i, v_i, t) \in \mathfrak{X} \text{ et } t \in [t_i, t_{i+1}[] \\ E_i = \{(u_i, v_i) \mid (u_i, v_i, t) \in \mathfrak{X}, t \in [t_i, t_{i+1}[] \} \end{cases}$$

3.2 Préparation des données

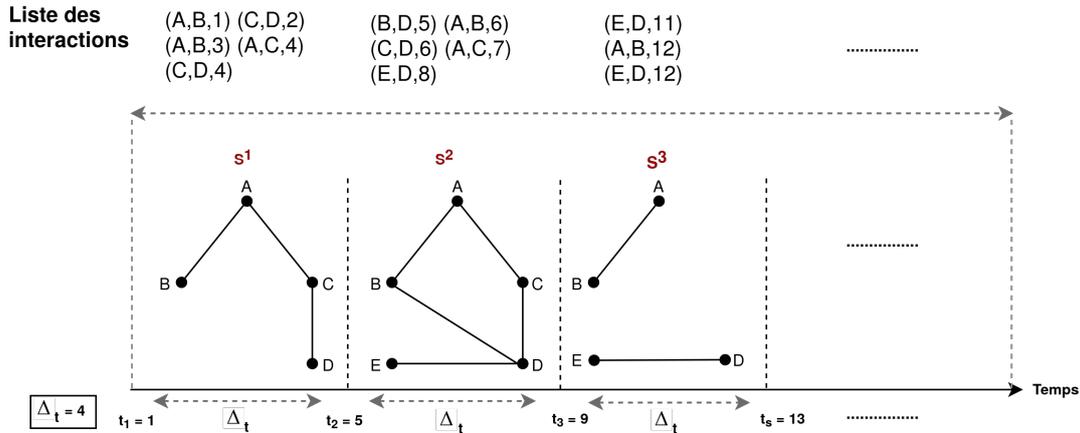


FIGURE 3.9 – Représentation des interactions temporelles sous forme de s snapshots.

où u_i, v_i sont les nœuds u et v dans le snapshot S^i .

Choix de la durée du snapshot Une fois le corpus d'étude construit, il est divisé en snapshots (sous-graphes) de même durée Δt . Le choix de la valeur de Δt est un compromis entre trois facteurs : 1) le volume des données du corpus, 2) la densité des liens dans les sous-graphes des snapshots et 3) le délai nécessaire aux experts métier pour réaliser l'interprétation des signaux faibles détectés. En effet, les petits snapshots risquent de « passer à côté » des signaux faibles, alors que de grands snapshots ou un sous-graphe dense demandant un temps d'exécution d'Orca important ne laisseront pas le temps aux experts métier d'interpréter les signaux et de donner l'alerte. A contrario, si le sous-graphe associé à un snapshot présente une faible

densité, alors il contiendra peu de graphlets complexes comme les graphlets fermés G_{28}  ou G_{29}  qui peuvent fournir beaucoup d'information lors de l'étape d'interprétation.

Pour éclairer les experts métier sur le choix de la valeur de ce paramètre, nous avons réalisé deux expérimentations décrites en annexe C. Ces expérimentations portent sur des jeux de données collectés dans le cadre du projet Cocktail.

La première expérimentation porte sur le jeu de données Lubrizol, dont les résultats de la méthode BEAM sont présentés en section 5.1.1. L'objectif de cette expérimentation est de mesurer l'impact de la taille des snapshots sur un corpus de taille restreinte : le corpus d'étude contient 845 nœuds et 1 141 liens pour une densité de 0.0032. Nous avons fait varier Δt entre dix, quinze, trente et soixante minutes sur une période d'une heure. Quelque soit la valeur de Δt , deux graphlets signaux faibles sont détectés dans tous les snapshots de l'étude. Pour cette expérience, nous avons constaté que les snapshots de trente minutes renvoient les graphlets signaux faibles détectés aussi dans les autres snapshots. L'étape d'interprétation des instances a validé les utilisateurs correspondants comme porteurs de signal faible.

La deuxième expérimentation porte sur le jeu de données Game of Thrones (GOT), dont les résultats de la méthode BEAM sont présentés en section 5.3. L'objectif de cette expérimentation est de mesurer l'impact de la taille des snapshots sur un corpus de taille volumineuse : le corpus d'étude contient 226 554 nœuds et 270 825 liens pour une densité de 0.00005. Cette expérimentation a montré que les snapshots de durée égale à dix minutes renvoient les graphlets signaux faibles détectés dans les snapshots correspondant aux autres durées, et que des

durées comprises entre quarante et soixante minutes sont coûteuses en temps d'exécution, ce qui réduit le temps d'interprétation de l'expert métier. L'étape d'interprétation a confirmé les résultats obtenus avec l'étude des instances de graphlets.

En conclusion, nous préconisons pour Δt une valeur de trente minutes, pour un corpus volumineux comme GOT, l'expert métier peut décider de réduire Δt si l'énumération des graphlets par Orca demande trop de temps.

3.3 Signature d'un signal faible

Notre objectif consiste à **décrire les signaux faibles au moyen d'une signature sous la forme d'une propriété quantifiable (une grandeur)** qui caractérise les signaux faibles et permet leur détection dans le bruit [69].

Nous présentons dans cette section une description des signaux faibles à l'aide de la topologie du réseau en utilisant comme critères la **visibilité**, la **diffusion** et l'**amplification** du signal. Nous nous appuyons sur le modèle tri-dimensionnel proposé par Hiltunen en 2008 [82] présenté en sous-section 2.1.2. La figure 3.10, inspirée du modèle de Hiltunen, illustre ces trois dimensions. La **rareté** mais aussi les changements lents au cours du temps sont les principales caractéristiques des signaux faibles. Ainsi, le temps est l'élément déterminant à prendre en compte dans la transformation du signal.

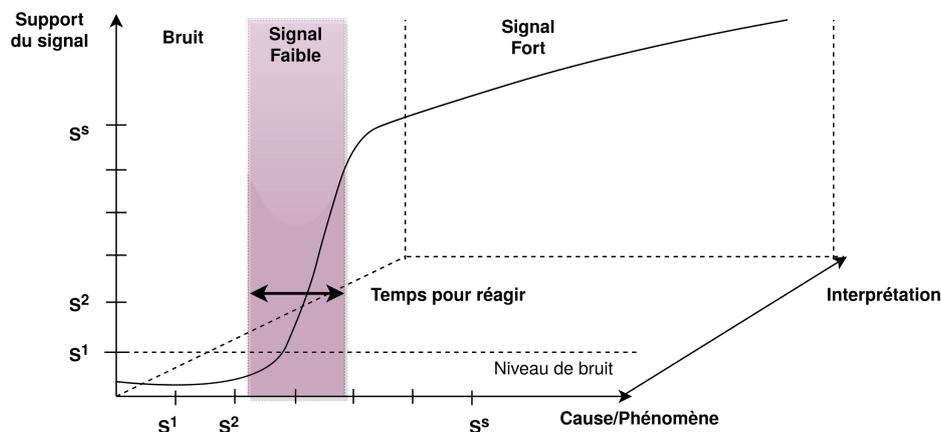


FIGURE 3.10 – Renforcement du signal inspiré du modèle tri-dimensionnel de Hiltunen.

3.3.1 Mise en place de l'outillage nécessaire à la détection des signaux faibles

La description opératoire des signaux faibles est basée sur le nombre de graphlets apparaissant dans chacun des snapshots. Dans la suite, nous utilisons le terme graphlet pour désigner chaque type parmi les trente, ce terme ne représente pas une instance de graphlet.

3.3 Signature d'un signal faible

Énumération des graphlets

Après l'exécution d'Orca, chaque snapshot S^t est représenté sous la forme de trente composantes d'un vecteur numérique $(G_0^t, G_1^t, \dots, G_{29}^t)$, où G_x^t est le nombre de graphlets de type x dans le snapshot S^t , le tableau 3.5 en présente un exemple.

Snapshot	G_0	G_1	G_2	G_3	G_4	G_{29}
S^1	18	25	5	32	24	10
S^2	26	56	15	35	30	5
....
S^s	80	120	32	56	35	0

TABLE 3.5 – Exemple des trente graphlets énumérés pour les s snapshots de l'étude.

Normalisation

Nous appliquons une procédure de normalisation sur le nombre des graphlets afin de ramener leurs valeurs à une magnitude particulière. Même si les snapshots ont la même durée, le nombre de nœuds et de liens correspondants diffère d'un snapshot à un autre (par exemple, certains snapshots contiennent peu de liens, tandis que d'autres en contiennent des milliers). Cette étape est d'une grande importance car elle ne doit pas masquer les signaux faibles mais les rendre comparables à d'autres. La procédure choisie est celle proposée par D. Goldin et P. Kanellakis [72] dans laquelle ils étudient la similarité entre deux requêtes posées sur une base de données temporelles. Une requête renvoie une séquence X de nombres réels (x_1, \dots, x_n) . Deux réels a, b définissent une transformation $T_{a,b}$ sur X en mettant en relation chaque x_i avec $a \times x_i + b$. \bar{X} représente la forme normale de X , calculée par :

$$\bar{X} = T_{\sigma, \mu}^{-1}(X) = T_{\frac{1}{\sigma}, -\frac{\mu}{\sigma}}(X)$$

où $\mu(\bar{X}) = 0$ et $\sigma(\bar{X}) = 1$, μ étant la moyenne et σ la déviation standard.

En appliquant cette procédure de normalisation pour chacun des snapshots S^t où s est le nombre de snapshots, chaque composante G_x^t de son vecteur avec $x \in \{0, \dots, 29\}$, est normalisée par :

$$\overline{G_x^t} = \frac{G_x^t - \mu(G_x)}{\sigma(G_x)}$$

avec $\mu(G_x)$ la moyenne de chaque graphlet G_x pour tous les snapshots, donnée par :

$$\mu(G_x) = \frac{1}{s} \sum_{t=1}^s G_x^t$$

et $\sigma(G_x)$, la déviation standard calculée par :

$$\sigma(G_x) = \sqrt{\frac{\sum_{t=1}^s (G_x^t - \mu(G_x))^2}{s - 1}}$$

Les valeurs normalisées sont utilisées dans les calculs suivants.

3.3.2 Estimation du renforcement du signal : diffusion et amplification

Nous développons l'hypothèse que certains graphlets sont des précurseurs d'évènement potentiels tout comme les cliques le sont pour les communautés. Nous définissons un précurseur d'évènement comme étant un fait observable et clair présent dans un processus opérationnel d'une organisation et causé par des facteurs existants dans le processus [110].

Les évolutions des vitesses et des accélérations sont des caractéristiques quantitatives qui permettent d'évaluer la diffusion et l'amplification du signal. Nous les utilisons pour identifier des précurseurs d'évènements parmi les graphlets. Une fois les précurseurs potentiels trouvés, il faut encore valider le fait qu'il s'agit de signaux faibles pour ensuite comprendre leur rôle.

À partir des valeurs normalisées obtenues, l'évolution de toutes les composantes \overline{G}_x^t est étudiée *via* leur vitesse d'apparition et leur accélération. Notre objectif est de mettre en évidence les graphlets qui **émergent** avant les autres.

Pour chaque snapshot et chaque graphlet G_x , nous calculons sa vitesse comme étant la différence entre la valeur normalisée du graphlet dans le snapshot S^{t+1} et la valeur normalisée de ce même graphlet au snapshot S^t :

$$\overline{V}_x^t = \overline{G}_x^{t+1} - \overline{G}_x^t \quad \forall x \in \{0, \dots, 29\}$$

L'accélération est aussi calculée de la même manière en faisant la différence entre les vitesses :

$$\overline{A}_x^t = \frac{\Delta \overline{V}_x}{t} = \overline{V}_x^{t+1} - \overline{V}_x^t \quad \forall x \in \{0, \dots, 29\}, t = 1 \text{ les snapshots sont de même durée}$$

Nous obtenons alors une matrice numérique représentant pour chaque snapshot S^t , la valeur normalisée des graphlets \overline{G}_x^t , leur vitesse \overline{V}_x^t , et leur accélération \overline{A}_x^t . Cette matrice est présentée dans le tableau 3.6 qui illustre un exemple des valeurs de certains types de graphlets par snapshot. À noter que les vitesses ne peuvent être calculées qu'à partir du snapshot S^2 , et les accélérations à partir du snapshot S^3 .

Snapshot	Graphlet	\overline{G}_x^t	\overline{V}_x^t	\overline{A}_x^t
S^1	G_1	-0.952	NA	NA
S^1	G_2	-0.222	NA	NA
S^2	G_1	-0.666	-0.121	NA
S^2	G_2	0.456	0.678	NA
S^3	G_1	-0.786	0.938	1.059
S^3	G_2	0.758	0.302	-0.376
S^4	G_1	0.152	0.975	0.037
S^4	G_2	0.758	-0.315	-0.617
....
S^s	G_{29}	0.503	0.129	0.225

TABLE 3.6 – Exemple des valeurs normalisées des graphlets, de leur vitesse et accélération pour les snapshots de la période d'étude.

La figure 3.11 résume les résultats obtenus à partir des caractéristiques topologiques des graphes pour la découverte des précurseurs.

3.3 Signature d'un signal faible

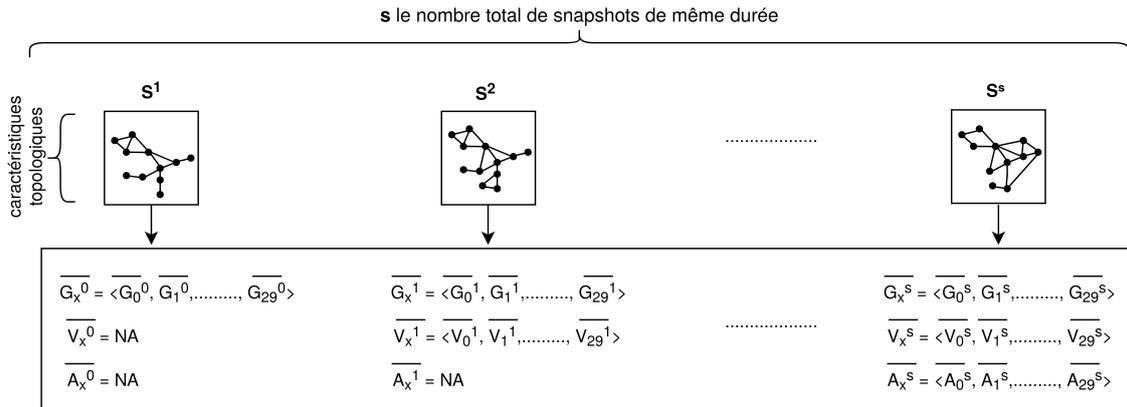


FIGURE 3.11 – Résumé des calculs sur les graphlets, des vitesses et des accélérations pour les snapshots de l'étude.

3.3.3 Identification des précurseurs

Dans un premier temps, nous présentons le principe d'identification des précurseurs puis une visualisation sous la forme de carte d'émergence afin d'aider les experts métier à identifier les précurseurs parmi les graphlets.

Principe

L'identification des précurseurs se fait soit par rapport à un top k soit par rapport à un seuil. L'objectif étant d'identifier les graphlets qui émergent et se diffusent plus rapidement que les autres, ces valeurs sont déterminées par rapport aux valeurs de vitesses et d'accélérations des graphlets.

La première possibilité consiste pour chacun des s snapshots S^t à :

- classer leurs vitesses $\overline{V}_0^t, \overline{V}_1^t, \overline{V}_2^t, \dots, \overline{V}_{29}^t$ par ordre décroissant ;
- fixer une valeur top k pour laquelle les k graphlets ont les vitesses les plus élevées. De la même façon, nous fixons un top k pour le critère accélération des graphlets.

Pour El Akrouchi et al. [56], les signaux faibles ne forment pas plus de 20 % de l'information ce qui est conforme au principe de Pareto, ce qui fixerait la valeur de k à 6 dans BEAM.

La seconde possibilité consiste pour chacun des s snapshots S^t à fixer un seuil égal par exemple à la moyenne des vitesses et à sélectionner les vitesses supérieures ou égales à cette valeur, $\overline{V}_x^t \geq \mu(\overline{V}^t)$, un seuil semblable est fixé pour les accélérations.

Visualisation des précurseurs à l'aide des cartes d'émergence

Nous nous appuyons sur l'approche de Hiltunen dans laquelle elle considère deux types de précurseurs : *early information* ou information préalable, et *first symptoms* ou premier symptôme. Le premier représente une nouvelle information apparue soudainement comme l'annonce d'un nouveau produit ou d'une invention, le deuxième type représente un changement remarquable mais difficile à interpréter. Nous utilisons une carte d'émergence découpée en quatre zones ou quadrants (n'ayant pas forcément la même taille) en fonction de la valeur choisie pour le top k ou pour le seuil. Le modèle de cette carte est présenté en figure 3.12.

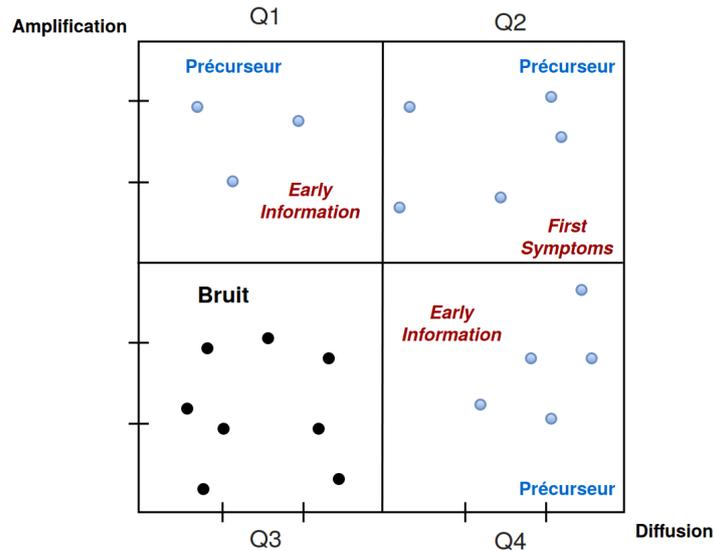


FIGURE 3.12 – Structure des cartes d'émergence de graphlets.

Cette carte, dans laquelle nous positionnons les graphlets, représente en abscisse la diffusion du signal mesurée par la vitesse des graphlets, et en ordonnée son amplification mesurée par l'accélération des graphlets. Nous retrouvons les deux types de précurseurs considérés par Hiltunen dans les zones Q1, Q2 et Q4 de la carte. Ces zones contiennent des graphlets ayant 1) une grande vitesse et une petite accélération i.e. Q4, 2) une petite vitesse et une grande accélération i.e. Q1, 3) des valeurs élevées pour ces deux critères i.e. Q2. Si un graphlet se trouve dans les zones Q1 et Q4 de la figure, nous le considérons comme *early information*, tandis que s'il se trouve dans la zone Q2, nous le considérons comme *first symptoms* car les valeurs pour sa vitesse et son accélération sont plus élevées. Les graphlets situés dans ces trois zones sont des précurseurs d'évènements car ce sont des faits observables et remarquables par leurs vitesses et/ou accélérations. La zone bruit⁷, i.e. Q3, correspond aux graphlets ayant des vitesses et des accélérations très petites voire négligeables.

La figure 3.13 montre un exemple de cartes d'émergence des graphlets pour quatre snapshots consécutifs, chacun ayant une durée Δt égale à dix minutes et où les cartes sont découpées en utilisant un seuil égal à la moyenne des vitesses et des accélérations. Dans le premier snapshot, correspondant à la première partie à gauche de la figure, nous ne trouvons qu'un graphlet dans le quadrant Q2. Par contre, pour les trois snapshots qui le suivent, nous remarquons que le nombre des graphlets dans le quadrant Q2 augmente. Les graphlets situés dans les quadrants Q1, Q2 et Q4 de ces cartes, correspondant aux zones hachurées en bleu, sont sélectionnés comme les précurseurs du snapshot. Le graphlet G_0 , composé de deux nœuds et d'un lien, ne sera pas considéré comme précurseur puisqu'il est inclus dans tous les autres graphlets.

7. Le bruit représente une information peu claire qui apparaît de manière aléatoire mais qui n'a pas de sens. Mendonça et al. [136] voit le bruit comme l'ensemble des signaux non pertinents pointant dans des directions incohérentes.

3.4 Détection des signaux faibles

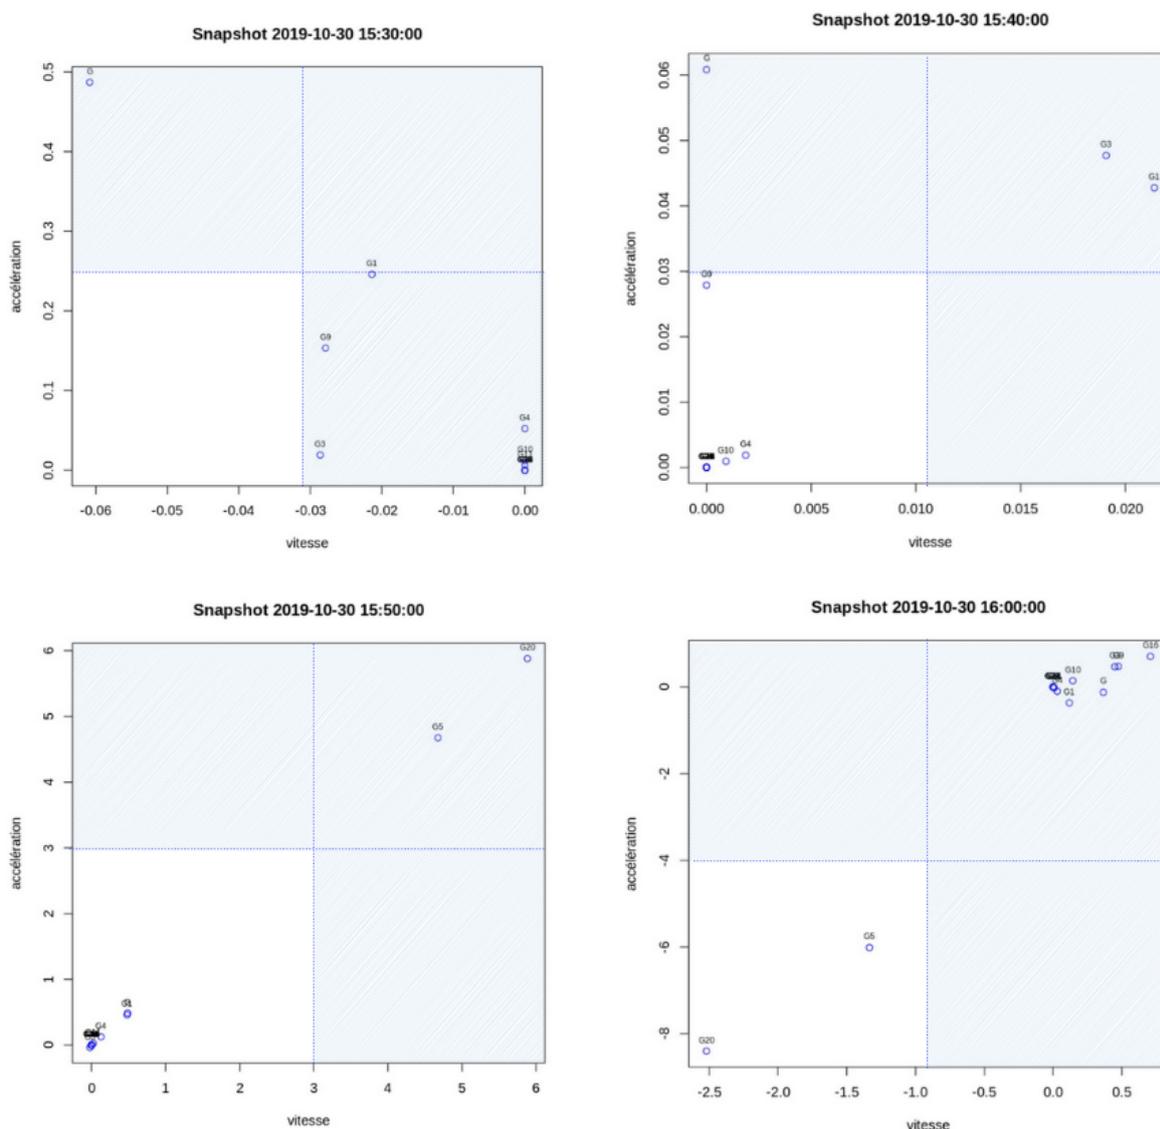


FIGURE 3.13 – Exemple de quatre cartes d'émergence de graphlets.

3.4 Détection des signaux faibles

L'objectif de cette étape est de qualifier les graphlets de signaux faibles. Pour cela, nous nous appuyons sur le critère de **rareté**. Ce critère est estimé par un ratio mesurant la contribution de chacun des trente graphlets au nombre total de graphlets.

Nous proposons deux calculs pour le ratio : un ratio local qui ne prend en considération que le snapshot courant et un ratio global qui prend en compte tous les snapshots. Le nombre de graphlet G_x^t dans le snapshot S^t choisi est divisé par le nombre total de graphlets pour ce snapshot :

$$R_{Local}(G_x) = \frac{G_x^t}{T_{Local}(G)} \quad \forall x \in \{0, \dots, 29\}, T_{Local}(G) = \sum_{x=0}^{29} G_x^t$$

Pour le calcul du ratio global, le nombre total de graphlet G_x dans l'ensemble des s snapshots

étudiés est divisé par le nombre total de graphlets pour ces s snapshots :

$$R_{Global}(G_x) = \frac{\sum_{t=1}^s G_x^t}{T_{Global}(G)} \quad \forall x \in \{0, \dots, 29\}$$

Où $T_{Global}(G) = \sum_{t=1}^s (\sum_{x=0}^{29} G_x^t)$, avec s le nombre de snapshots traités.

Les ratios résultants $R_{Local}(G_x)$, $R_{Global}(G_x)$ sont classés en ordre croissant, pour sélectionner les signaux faibles. Les signaux faibles étant rares, ce sont ceux qui contribuent le moins, c'est-à-dire ceux ayant les ratios les plus faibles. Nous choisissons les k graphlets contribuant le moins.

Les ratios permettent une classification des graphlets en quatre catégories présentées dans le tableau 3.7. Cette classification montre que nous conservons les Vrais Positifs et introduisons les Faux Négatifs comme signaux faibles.

	Signal faible	\neg Signal faible (bruit, signal fort)
Précurseur	Vrai Positif	Faux Positif
\neg Précurseur	Faux Négatif	Vrai Négatif

TABLE 3.7 – Classification des graphlets dans quatre catégories.

Les Vrais Positifs sont des graphlets précurseurs ayant une faible contribution. Les Faux Positifs sont des graphlets qui ont été identifiés comme précurseurs, mais qui ne sont pas en réalité des signaux faibles, ils doivent être éliminés à la fin de cette étape. Les Vrais Négatifs correspondent à des graphlets qui ne sont ni précurseurs ni signaux faibles, et les Faux Négatifs ne sont pas identifiés comme précurseurs mais ayant une faible contribution sont considérés comme signaux faibles. Nous notons que le maintien de certains Faux Positifs pourrait aider les experts métier à examiner d'autres informations latentes.

3.5 Confirmation par une méthode statistique : cross-correlation

Dans le chapitre 2, nous avons défini un signal faible comme un signal peu visible, rare qui indique des changements progressifs pouvant aboutir à un évènement. L'objectif de cette étape est de fournir aux experts métier des « débuts de preuves » qui ne réfutent pas (assurent, garantissent) les graphlets identifiés comme signaux faibles. Cette étape ne peut s'exécuter qu'après la survenue d'un évènement car nous voulons justifier les propriétés intrinsèques de BEAM à travers l'étude d'une dépendance entre les graphlets et un évènement dans le corpus d'étude, mais aussi estimer l'éventuel décalage dans le temps de cette dépendance. Nous considérons un évènement comme une situation dans laquelle le nombre d'interactions atteint sa valeur maximale. Nous proposons une méthode statistique, la cross-correlation, associée à un outil de visualisation. Afin de confirmer les graphlets en signaux faibles, nous devons avoir une dépendance avec un décalage négatif.

Présentation de la cross-correlation

Dans cette étape, nous travaillons sur les interactions modélisées par une série temporelle. Une série temporelle X est une séquence de n valeurs qui se produisent dans un ordre successif sur

3.5 Confirmation par une méthode statistique : cross-correlation

une certaine période de temps : $X = (x_i)_{1 \leq i \leq n} = (x_1, x_2, \dots, x_n)$ [39]. Une série temporelle peut être corrélée avec elle-même (auto-correlation) ou avec une autre série (cross-correlation ou corrélation croisée).

La notion de cross-correlation a été développée dans deux domaines différents : le traitement du signal et les statistiques. Dans le domaine des statistiques, la cross-correlation est une méthode quantifiant le degré de similarité entre deux séries numériques [46]. Dans cette méthode, il est courant de décaler la courbe d'une série par rapport à l'autre, le nombre de valeurs, indiqué par l , pour lesquels la série est décalée est appelé décalage.

Formalisation Le coefficient de corrélation est une mesure comprise entre -1 et +1, quantifiant comment deux séries varient ensemble. Une valeur positive élevée indique que les deux séries varient fortement ensemble, une valeur positive faible signifie qu'elles varient ensemble, mais qu'il existe une déviation, tandis qu'une valeur négative élevée indique qu'elles varient dans des directions opposées, mais toujours linéairement.

Soient n observations sur deux séries temporelles $X = (x_1, x_2, \dots, x_n)$ et $Y = (y_1, y_2, \dots, y_n)$ sur une même période. Les observations des deux séries sont considérées comme une réalisation finie d'un processus bivarié discret. Le coefficient de cross-correlation ρ des deux séries X et Y , à un décalage l est défini avec :

$$\rho_{xy}(l) = \frac{\sum_{i=1}^n (x_i - \bar{x}) \times (y_{i-l} - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \times \sqrt{\sum_{i=1}^n (y_{i-l} - \bar{y})^2}} \quad (3.1)$$

Dans cette équation, x_i est la i ème observation de la première série et y_{i-l} est la i ème - l observation de la deuxième série (décalage de l par rapport à la première série), \bar{x} et \bar{y} représentent les moyennes calculées pour chacune des séries. Le numérateur correspond à la covariance entre X et Y , le dénominateur correspond au produit entre les déviations standards des deux séries, étant toujours supérieur au numérateur, la valeur de la corrélation ne dépassera pas 1. La covariance montre si deux variables ont tendance à se déplacer dans la même direction, tandis que le coefficient de corrélation mesure l'importance de cette relation sur une échelle normalisée, entre -1 et +1 [39].

Application à BEAM

Dans le cadre de notre méthode BEAM, nous avons utilisé la cross-correlation pour démontrer si il existe une relation entre les graphlets signaux faibles et un évènement potentiel dans les données étudiées. La première série X correspondant aux données du corpus de l'étude, contient le nombre d'interactions entre les entités dans les s snapshots de la période étudiée. La deuxième série $Y_x = (G_x^1, G_x^2, \dots, G_x^s)$ contient le nombre de fois où un graphlet G_x apparaît dans les s snapshots de la même période.

D'après le calcul du coefficient ρ , nous formulons les hypothèses que

- lorsque le décalage l est positif, X prédit Y_x ;
- lorsque le décalage l est négatif, Y_x prédit X .

Le graphlet G_x corrélé avec X d'un décalage négatif l est confirmé comme signal faible.

Interprétation des résultats : corrélogramme De nombreuses techniques de visualisation en statistiques existent pour aider à révéler ou expliquer les relations entre les variables, telles

que les *biplots* [63], les *factor pattern plots* ou les structures canoniques [61], etc. Pour visualiser les matrices de corrélations, les corrélogrammes sont utilisés, où un corrélogramme est une représentation graphique du coefficient de corrélation à chaque décalage [62]. Cette représentation met en avant la valeur maximale de cross-corrélation, se trouvant au décalage où les séries temporelles sont les plus similaires.

Prenons l'exemple de deux séries temporelles X et Y_x correspondant respectivement au nombre des interactions et au nombre d'apparition d'un graphlet G_x dans vingt-deux snapshots. Les valeurs de ces séries sont données par :

$X = (18, 3, 2, 6, 4, 8, 6, 2, 31, 36, 28, 15, 54, 26, 96, 95, 35, 82, 151, 177, 111, 81)$.

$Y_x = (3, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 9, 84, 1448, 374, 60, 270, 2178, 1114, 399, 95)$.

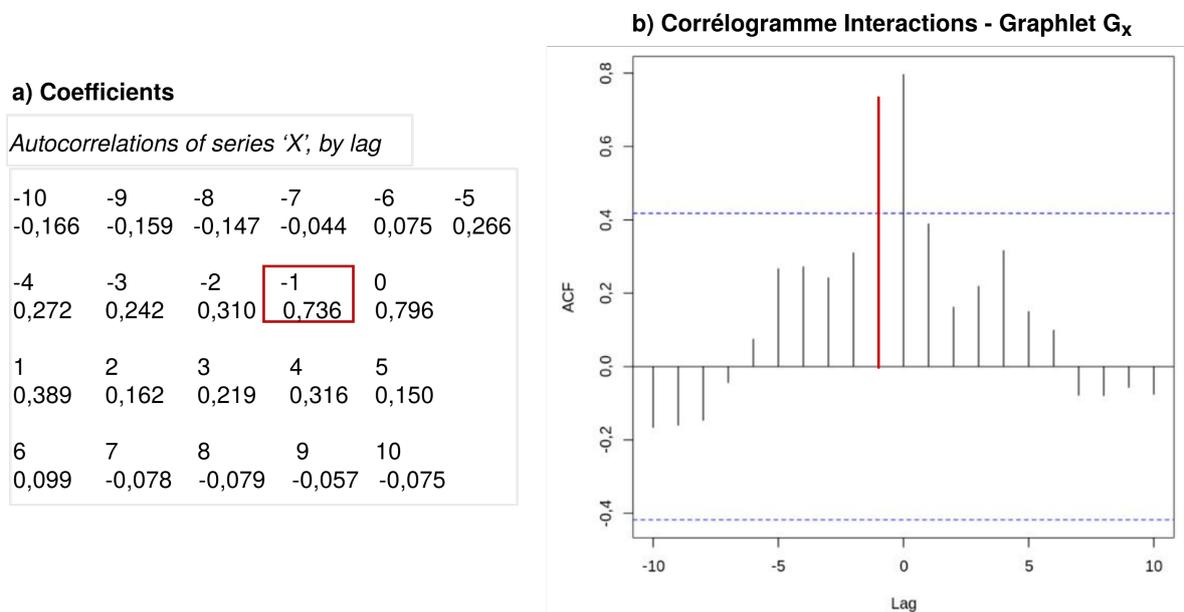


FIGURE 3.14 – Corrélogramme montrant une corrélation positive avec un décalage négatif entre X et Y_x [33].

La figure 3.14 illustre la corrélation⁸ entre Y_x et X . Dans la partie b), l'axe des abscisses du corrélogramme représente le décalage du temps, et celui des ordonnées la valeur du coefficient ρ notée par ACF pour *Auto Correlation Function*. La ligne du décalage $l = 0$ correspond à l'évènement et est considérée le point repère du corrélogramme. Nous nous intéressons à observer les coefficients des décalages tel que $l \neq 0$, pour vérifier si le graphlet précède l'évènement. La plus grande valeur du coefficient ρ à $l = -1$ (égale à $+0.736$ en rouge) correspond à une corrélation d'un décalage égal à la durée d'un snapshot entre la série du graphlet, et celle des interactions. Une corrélation avec $\rho > 0$ et $l < 0$ indique que Y_x précède (ou prédit) X de l , le graphlet G_x est alors confirmé comme signal faible.

8. implémentée avec le package *tseries* du langage R : <https://www.rdocumentation.org/packages/tseries/versions/0.1-2/topics/ccf>

3.6 Synthèse et conclusion

Dans ce chapitre, nous nous sommes fixés comme objectif de détecter les signaux faibles parmi un grand volume de données. Pour cela, nous fournissons une signature sous la forme d'une propriété quantifiable qui caractérise le signal faible. Nous utilisons les graphlets comme outil opérationnel pour établir cette signature qui représente les quatre caractéristiques que nous avons choisies pour décrire un signal faible : sa faible visibilité, sa diffusion et son amplification au cours du temps et finalement sa rareté. Le tableau 3.8 fournit une description de ces caractéristiques du point de vue conceptuel et opérationnel.

Dimension/Critère	Définition conceptuelle	Définition opérationnelle
Visibilité	Nombre/fréquence	Nombre de graphlets dans chaque snapshot
Diffusion	Vitesse	Vitesse des graphlets calculée par rapport à leur nombre
Amplification	Accélération	Accélération des graphlets calculée par rapport à leur vitesse
Rareté	Contribution	Contribution de chaque graphlet par rapport au nombre total des graphlets (calcul de ratio)

TABLE 3.8 – Définitions conceptuelle et opérationnelle des critères caractérisant les signaux faibles.

La détection décrite dans ce chapitre est résumée dans la figure 3.15 et sous forme algorithmique en annexe F. Dans la première étape, les données issues d'interactions entre des entités dans un intervalle de temps donné sont filtrées et utilisées pour construire le corpus de l'étude. Ces données sont découpées en snapshots de même durée. Les étapes 2 à 4 de BEAM sont la détection proprement dite des signaux faibles, dans laquelle nous cherchons à estimer les caractéristiques retenues pour les signaux faibles, avec les graphlets. Pour un snapshot donné S^i , le nombre des graphlets est calculé à l'aide de l'algorithme Orca, et ensuite normalisé pour aboutir à des valeurs comparables sans masquer les signaux faibles. À partir des valeurs normalisées des graphlets, leurs vitesses et accélérations sont calculées. Ces trois mesures sur les graphlets sont utilisées comme marqueurs de visibilité, de diffusion et d'amplification du signal. Des valeurs élevées pour ces mesures, représentant une émergence rapide du signal, permettent de sélectionner une liste de graphlets précurseurs. Le critère de rareté est ensuite estimé par un ratio exprimant la contribution des graphlets dans les signaux faibles. Il permet de qualifier les graphlets en signaux faibles.



Dans le chapitre suivant, nous présentons les outils que nous mettons à disposition des experts métier pour l'interprétation des signaux faibles détectés.

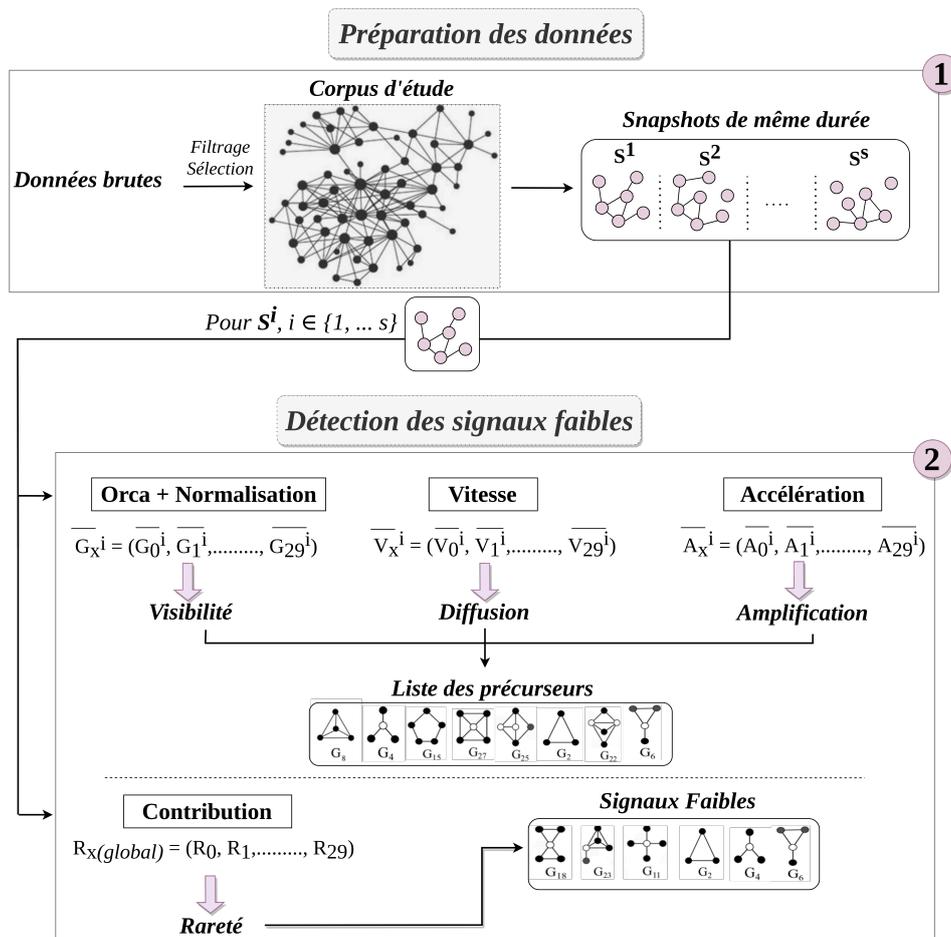


FIGURE 3.15 – Résumé de l'étape de détection de la méthode BEAM.

BEAM : ÉTAPE D'INTERPRÉTATION DES SIGNAUX FAIBLES

Sommaire

4.1	Points de vue pour interpréter les signaux faibles	68
4.1.1	Point de vue séquence de snapshots	68
4.1.2	Point de vue snapshot	70
4.1.3	Point de vue nœud	72
4.2	Visualisation de données	73
4.3	Implémentation d'un <i>Proof of Concept</i>	75
4.4	Synthèse et conclusion	79

"When people stumble onto the truth they usually pick themselves up and hurry about their business". – Winston Churchill

A PRÈS avoir détecté les signaux faibles et donc passé le filtre de surveillance, l'objectif de ce chapitre est d'aider les experts métier à décider si le signal faible peut constituer un signe d'alerte précoce.

Nous appelons **signe d'alerte précoce** un signal faible dont l'interprétation des experts métier donne à penser que pourrait se produire un évènement susceptible d'avoir une grande utilité pour l'organisation [119].

Dans ce chapitre, le rôle des experts métier est prépondérant : ils doivent décider de la pertinence de la relation entre le signal faible et une menace ou une opportunité pour l'organisation. Il s'agit d'une étape non entièrement automatique requérant une expertise métier et permettant de franchir le filtre de mentalité. À l'issue de cette étape, les experts métier devront être en capacité de décider si les signaux faibles doivent être transmis aux décideurs.

Les signaux faibles détectés par les étapes développées au chapitre 3 constituent des informations fragmentées donc ils sont difficiles à interpréter. Cependant, combiner les signaux faibles avec des éléments contextuels ou des connaissances permettra de leur donner un sens et une utilité pour éclairer les prises de décision des experts métier et des décideurs.

Dans la suite, nous avons élaboré des tableaux de bord que nous proposons aux experts métier. Ceux-ci offrent plusieurs points de vue avec différentes visualisations des signaux faibles.

4.1 Points de vue pour interpréter les signaux faibles

Nous proposons une approche macroscopique pour comprendre le contexte large des éléments apparaissant dans les signaux faibles : centralité des nœuds pour déterminer leur influence, communauté pour déterminer leur position dans le graphe, puis nous passons progressivement à une approche mésoscopique permettant de mieux comprendre les éléments composant les graphlets signaux faibles. Nous passons ici des graphlets signaux faibles aux instances de graphlets signaux faibles. Nous considérons alors les relations entre les nœuds, mais aussi des caractéristiques propres aux nœuds comme leur nom, leur type, mais aussi leur rôle dans les graphlets signaux faibles. Le rôle d'un nœud est caractérisé par son orbite ou sa position dans les graphlets. Orca énumérant les orbites de chacun des nœuds, nous pouvons identifier les nœuds dans les graphlets signaux faibles ainsi que leurs rôles comme centraux, intermédiaires ou périphériques. Enfin, une approche microscopique permet une analyse qualitative et non quantitative comme les deux précédentes approches. Cette approche permet aux experts métier de zoomer sur des moments de controverse, d'explorer des questionnements spécifiques.

Ces approches peuvent être appliquées suivant à différents niveaux de granularité : séquence de snapshots, snapshot et nœud. Dans la suite nous développons ces trois points de vue et nous indiquons comment ils sont mis en œuvre.

4.1.1 Point de vue séquence de snapshots

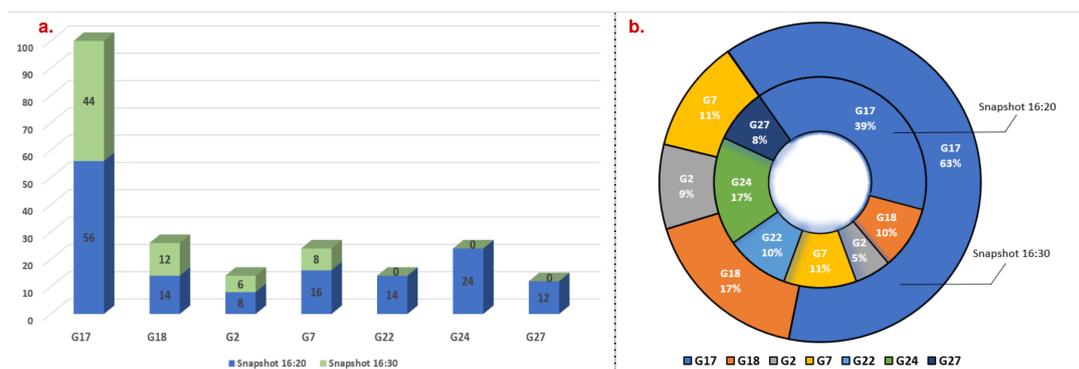


FIGURE 4.1 – Deux représentations de l'évolution du nombre de graphlets entre deux snapshots consécutifs.

L'expert métier peut réaliser une analyse sur une séquence de snapshots, elle permet de suivre les signaux faibles à travers l'évolution des graphlets. Par exemple, l'expert peut voir

- disparaître ou émerger des signaux faibles de plus en plus complexes (de trois à cinq nœuds);
- un possible début de formation de communautés quand BEAM identifie des graphlets signaux faibles en forme de chaîne au snapshot S^t puis des graphlets ayant une forme fermée dans les snapshots suivants.

4.1 Points de vue pour interpréter les signaux faibles

Par exemple, la figure 4.1 illustre deux représentations du nombre de graphlets signaux faibles pour deux snapshots consécutifs. À gauche, les bâtons bleus (respectivement verts) de l'histogramme représentent leur nombre dans le snapshot S^t (respectivement S^{t+1}), à droite ces mêmes données sous la forme d'un diagramme en secteurs.

Nous proposons également d'agréger les données dans un cube pour permettre aux experts d'effectuer des analyses multi-dimensionnelles. Un cube organise les données en une ou plusieurs dimensions, chacune déterminant une mesure d'intérêt. Chaque dimension est formée par un ou plusieurs attributs et chaque attribut peut prendre différentes valeurs. Cette modélisation est souvent adoptée dans le domaine de l'informatique décisionnelle qui désigne des techniques pour piloter une activité et aider à la prise de décision [49]. Le cube de données de la figure 4.2 est un vecteur à trois dimensions $C(N, O, S)$ où N représente la dimension nœud, O l'orbite et S le snapshot. Ce cube contient les informations sur le nombre de fois où les nœuds apparaissent dans les orbites des graphlets signaux faibles sur une séquence de snapshots. Par exemple, la cellule grise dans cette figure indique que le nœud N_2 apparaît neuf fois dans l'orbite O_{40} du graphlet G_{17} au snapshot S^1 . À partir de ce cube, nous donnons la possibilité de vérifier si un nœud appartient toujours à la même orbite, quelles sont ses différentes orbites au cours du temps ou quelle est la nature des orbites (centrales, périphériques, etc.).

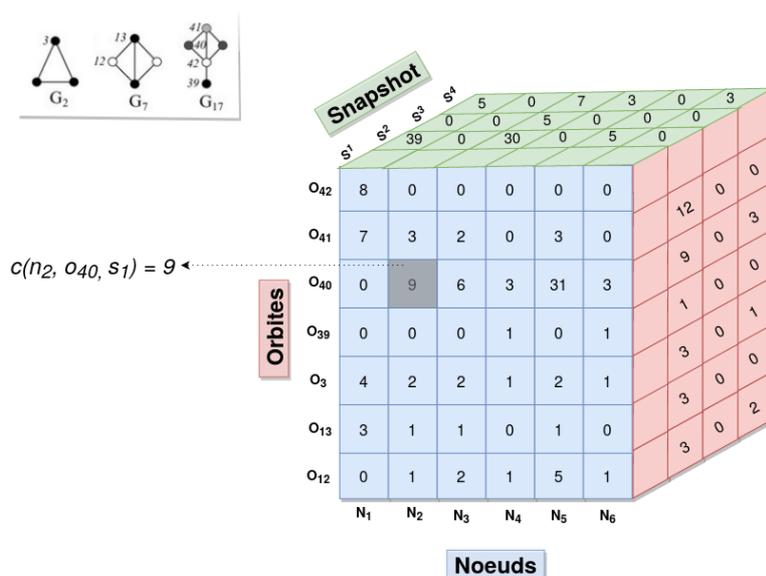


FIGURE 4.2 – Représentation des données à l'aide d'un cube.

Ce cube supporte les mêmes opérations que celles proposées sur les cubes OLAP (*OnLine Analytical Processing*), notamment l'agrégation selon une ou plusieurs dimensions (par exemple snapshot et nœud), la sélection de dimensions particulières et d'autres fonctions analytiques [73]. Nous proposons aux experts métier un ensemble de requêtes sur la base de données relationnelle. L'agrégation dans un cube est réalisée à l'aide de l'opérateur `ROLLUP` ajouté dans la clause `GROUP BY` de la requête SQL. `ROLLUP` permet de générer des sous-totaux pour les attributs spécifiés plus une ligne supplémentaire représentant le total global. Sur le cube de la figure 4.2, la requête donnée en 4.1 utilise la clause `ROLLUP` pour renvoyer la fréquence d'apparition des nœuds par snapshot (sous-total), et la fréquence de tous les nœuds dans tous les snapshots (total).

```

SELECT Snapshot, Noeud, SUM(frequence) as Frequence
FROM Cube
GROUP BY ROLLUP (Snapshot, Noeud)
ORDER BY Snapshot, Noeud;

```

Listing 4.1 – Requête d'agrégation utilisant la clause ROLLUP sur le cube de données.

Cette requête regroupe les données selon les combinaisons suivantes : {(Snapshot, Noeud), (Snapshot), ()}, le tableau 4.1 montre un extrait de son résultat. Les lignes marquées en bleu indiquent la fréquence d'apparition par snapshot, et la ligne marquée en rouge donne la fréquence totale sans agrégation.

Snapshot	Nœud	Frequence
S^1	N_1	22
S^1	N_2	16
.....
S^1	<i>NULL</i>	105
S^2	N_1	56
S^2	N_2	16
.....
S^2	<i>NULL</i>	199
.....
<i>NULL</i>	<i>NULL</i>	521

TABLE 4.1 – Extrait du résultat d'une requête avec la clause ROLLUP sur le cube de données de la figure 4.2.

Des requêtes utilisant la clause CUBE, génèrent des agrégations en fonction de toutes les combinaisons possibles entre les dimensions spécifiées dans la clause. Par exemple, remplacer la clause ROLLUP de la requête 4.1 par la clause CUBE dans la requête précédente revient à regrouper les données selon les combinaisons suivantes : {(Snapshot, Noeud), (Snapshot), (Noeud), ()}.

4.1.2 Point de vue snapshot

L'expert métier peut réaliser une analyse par snapshot avec des approches macroscopique et microscopique qui l'orienteront vers des éléments descriptifs pertinents.

Au niveau macroscopique, l'expert métier a la possibilité d'explorer à gros grains les signaux faibles détectés dans le snapshot. Ces éléments représentent pour un snapshot donné, le nombre de graphlets, d'orbites ou encore la liste des nœuds dans les graphlets comme l'illustre le tableau 4.2. De manière générale, les nœuds peuvent appartenir à plusieurs graphlets. Ceci confirme l'idée qu'un seul nœud peut jouer plusieurs rôles en même temps, comme le nœud N_9 qui occupe une orbite périphérique dans le graphlet G_{27} , et une orbite centrale dans le graphlet G_{11} .

4.1 Points de vue pour interpréter les signaux faibles

Graphlet	Orbite	Forme	Nœuds
G_2	O_3		N_1, N_2, N_3, N_4
G_{27}	O_{68}		N_5, N_6, N_8, N_9
	O_{69}		N_7
G_{11}	O_{22}		$N_6, N_8, N_{11}, N_{10}, N_{12}$
	O_{23}		N_9

TABLE 4.2 – Approche macroscopique d’un snapshot.

Nous permettons ensuite à l’expert métier de passer à une analyse plus fine avec une approche microscopique dans laquelle nous nous intéressons aux instances de graphlet ou d’orbite. Ce niveau d’analyse est utilisé pour étudier les relations entre les nœuds qui appartiennent à une instance de graphlet, afin de mettre en évidence leur nature et leur position au sein de l’instance. À ce niveau, un nœud appartient à une seule instance de graphlet et d’orbite.

Nous utilisons une base de données graphe *Neo4j* pour l’étude des instances de graphlets et d’orbites. Les données du corpus d’étude sont téléchargées depuis le fichier CSV correspondant dans la base, et chaque nœud a pour label (étiquette) le numéro des snapshots dans lesquels il apparaît. Donc la taille de la base graphe peuplée par le fichier CSV correspond à celle des données du corpus. Nous avons implémenté des requêtes *Cypher* sur la base *Neo4j*, où les experts métier filtrent les nœuds appartenant à une instance particulière d’un graphlet signal faible détecté dans un snapshot. Un exemple de requête est donné dans le listing 4.2.

```
MATCH (u1) -- (u2) -- (u3) -- (u4)
WHERE NOT ((u1) -- (u4))
AND NOT ((u1) -- (u3))
AND NOT ((u2) -- (u4))
RETURN * LIMIT 2
```

Listing 4.2 – Requête *Cypher* sélectionnant deux instances du graphlet G_3 .

Cette requête retourne deux instances du graphlet $G_3 \leftrightarrow \leftrightarrow$. Dans la clause `MATCH` est décrit le graphlet que nous voulons sélectionner, les conditions ajoutées dans la clause `WHERE` permettent de sélectionner certains liens entre les nœuds (et non pas la totalité des liens existants). Si l’expert souhaite visualiser une seule instance de ce graphlet, des conditions comme la clause `LIMIT 1` ou bien le nom d’un nœud particulier seront rajoutées. Le résultat d’une requête *Cypher* peut prendre trois formes : un graphe, un tableau et un tableau ASCII, comme illustré dans la figure 4.3. La forme graphe de la figure est une vue centrée sur deux instances du graphlet G_3 retournées par la requête précédente, où deux nœuds appartiennent à l’orbite O_5 (placés au milieu) et l’orbite O_4 périphérique est occupée par les nœuds restants. Dans cette visualisation, nous retrouvons l’orientation des relations et les nœuds sont coloriés par rapport à leur label, c’est-à-dire par rapport au(x) snapshot(s) dans le(s)quels ils se trouvent. Il est possible de changer la couleur choisie par défaut. La visualisation sous les deux formes

de tableau permet de présenter les résultats comme en relationnel. Ici, il s'agit de mettre en avant les propriétés portées par les nœuds et les relations. Nous voyons que ces deux types de visualisation sont complémentaires.

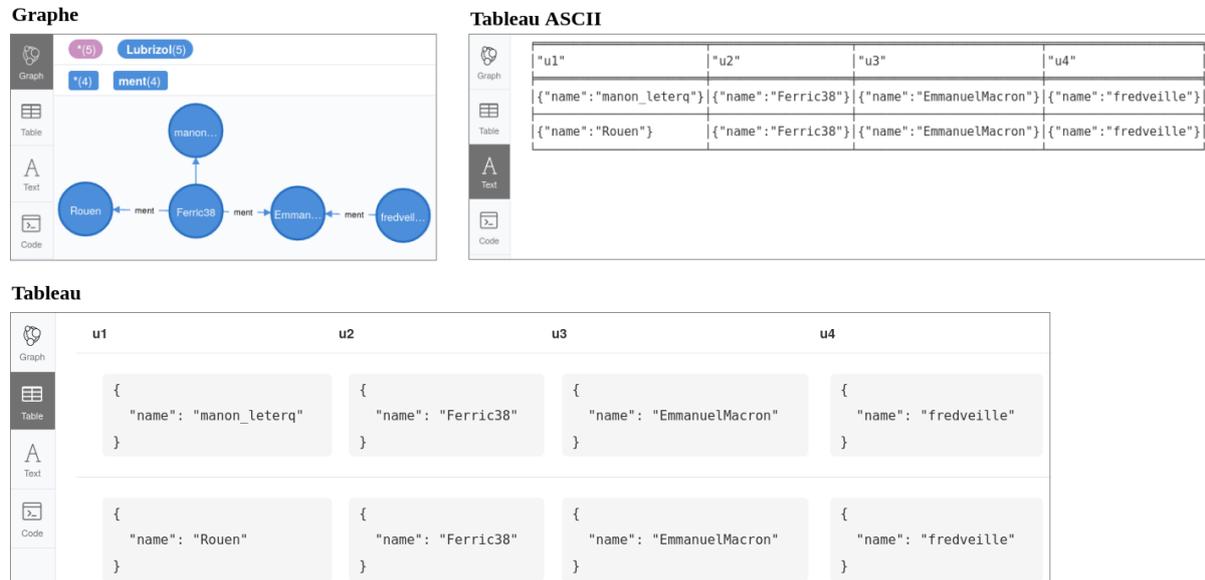


FIGURE 4.3 – Trois formes différentes pour visualiser des instances de graphlets sur la base Neo4j.

4.1.3 Point de vue nœud

Un troisième point de vue que nous considérons dans BEAM est centré nœud, son objectif est de limiter le nombre d'éléments à analyser grâce à leurs propriétés. Ces propriétés peuvent être obtenues à l'aide d'un regroupement en communautés ou d'un classement du nœud par rapport aux autres nœuds en fonction de critères topologiques.

Communautés Notre objectif est d'utiliser les communautés pour découvrir des relations potentielles entre les nœuds qui appartiennent aux graphlets signaux faibles. Ces relations peuvent être intra ou inter-communautés, ce qui permet aux experts métier d'expliquer leur rôle dans le réseau social.

Le regroupement en communautés se fait par des algorithmes de détection de communautés [18]. La détection de communautés consiste à trouver des groupes de nœuds ayant une forte densité de liens. Les communautés peuvent être un groupe de parents, de camarades de classe, de collègues, d'amis, ... Il existe plusieurs approches pour détecter les communautés dans les graphes, nous avons choisi d'utiliser l'algorithme Louvain pour l'étape d'interprétation de BEAM. Louvain est un algorithme agglomératif hiérarchique basé sur l'optimisation de la modularité du graphe, créé par Blondel et al. en 2008 [26]. Sa complexité est linéaire car il s'exécute en $O(|V|\log|V|)$ et permet donc de détecter des communautés sur des graphes de grande taille.

Nous l'utilisons à la fois sur une séquence de snapshots et sur le graphe du corpus d'étude mais pas sur un seul snapshot car dans celui-ci le nombre de nœuds est très petit rendant l'identification de groupes denses impossible.

4.2 Visualisation de données

Classement des nœuds Le classement des nœuds, les uns par rapport aux autres est une fonctionnalité essentielle qui traduit l'influence du nœud dans le réseau. Nous utilisons l'algorithme PageRank [30] pour mesurer la centralité des nœuds dans un snapshot, dans une séquence de snapshots, ou dans le graphe d'origine. Cela apporte aux experts des informations sur la position d'un nœud particulier par rapport aux autres, ce qui peut montrer son influence ou son rôle dans les signaux faibles identifiés par notre méthode.

Visualisation Nous offrons deux possibilités pour visualiser ces deux types d'information : une forme tabulaire illustrée dans le tableau 4.3 et une forme graphe présentée dans la figure 4.4. La première colonne du tableau représente un extrait des nœuds du graphe global qui sont ici des comptes utilisateurs sur Twitter, les deux colonnes suivantes concernent la communauté auquel appartient le nœud : numéro et couleur reprise dans la figure 4.4 de la communauté détectée par Louvain. La dernière colonne correspond au classement de chaque utilisateur dans sa communauté par rapport à son score PageRank. En effet, l'algorithme PageRank [30] peut être utilisé pour mesurer la centralité des nœuds dans le graphe global, ou dans chaque communauté.

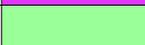
Utilisateur	Numéro Communauté	Couleur	Classement PageRank
AiphanMarcel	1		1
BFMTV	2		1
franceinfo			2
CNEWS			3
Prefet76	3		1
gouvernementFR			2
DuPouvoirDachat	4		1

TABLE 4.3 – Exemple de la visualisation point de vue nœud sous forme de tableau.

Dans la figure 4.4, les mêmes informations que dans le tableau 4.3 sont reprises : les communautés sont distinguées par des couleurs différentes, les mêmes que dans le tableau 4.3 et la taille des nœuds est proportionnelle à leur score PageRank. Nous trouvons par exemple que la communauté en bleu clair regroupe des journalistes, celle en vert foncé des médias, celle en violet des institutions gouvernementales, . . .

Étude du nœud dans le monde réel Une étape supplémentaire est l'étude du nœud dans le monde réel. Par exemple, si nous traitons des données issues de Twitter, un nœud peut être un utilisateur qui est un journaliste, un compte officiel d'un média, un acteur, un fan, . . . Comme nous avons accès au(x) tweet(s) publié(s) par cet utilisateur, l'expert métier peut réaliser une étude qualitative de leur contenu.

4.2 Visualisation de données

La visualisation de données permet de résumer de manière graphique les éléments quantitatifs sur les signaux faibles obtenus dans l'étape de détection et de croiser les données entre elles

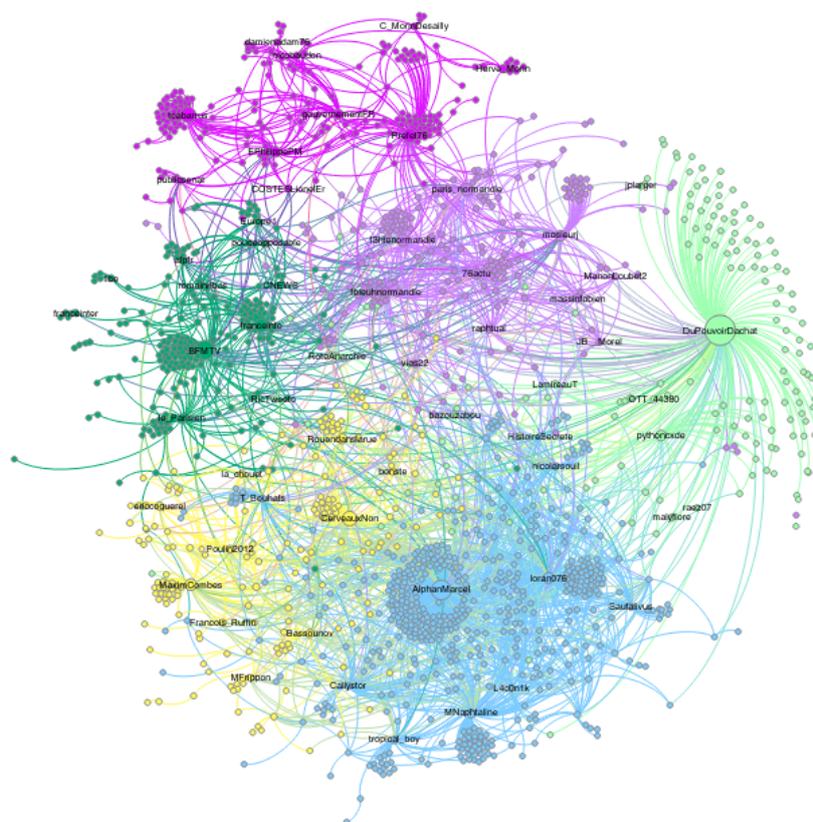


FIGURE 4.4 – Exemple de la visualisation point de vue nœud sous forme de graphe.

pour mettre en évidence leurs relations. Dès 1999, Rouibah et al. [164] ont montré l'importance d'avoir une aide visuelle lors de l'interprétation des signaux faibles. Ils ont proposé un outil, « Puzzle », guidé par l'idée générale qu'une carte ou un puzzle qui organise visuellement les signaux faibles, considérés comme des pièces du puzzle, aiderait les experts métiers à analyser les signaux faibles et à formuler des hypothèses. Cette idée nous semble fondamentale car les experts métier doivent prendre des décisions rapides et un large panel de visualisation peut les aider. Comme synthétisé en figure 4.5, nous offrons plusieurs types de visualisation :

1. la représentation **tabulaire** est réalisée par des requêtes analytiques *SQL* écrites sur la base de données relationnelle *PostgreSQL*. Elle est valable pour les trois points de vue et permet de visualiser les données dans les approches macroscopique et microscopique ;
2. la représentation **graphe**, valable pour tous les points de vue, est effectuée par des requêtes *Cypher* écrites sur la base de données *Neo4j* ;
3. la visualisation en **histogramme ou diagramme en bâtons** est valable pour tous les points de vue ;
4. la visualisation en **diagramme en secteurs** est disponible pour tous les points de vue cités ;
5. le **cube de données** est une visualisation d'une séquence de snapshots. Les dimensions peuvent être les nœuds, les orbites, les graphlets et les snapshots ;
6. Le **diagramme en radar** est disponible pour une séquence de snapshots et peut être appliqué entre deux nœuds ;

4.3 Implémentation d'un Proof of Concept

7. Le **diagramme de Sankey** permet de suivre des évolutions sur une séquence de snapshots. Il peut être appliqué entre deux nœuds, un nœud et une orbite, ou un nœud et un graphlet.

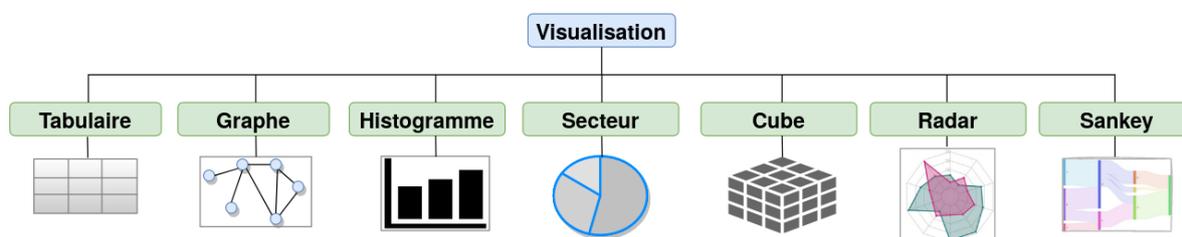


FIGURE 4.5 – Options de visualisation des données proposées par BEAM.

4.3 Implémentation d'un Proof of Concept

Dans cette section nous allons décrire l'architecture de notre preuve de concept (POC) mettant en œuvre BEAM.

Pour répondre aux besoins en termes de performance, d'interopérabilité (utilisation d'outils tiers) et d'adéquation entre les structures de données manipulées par les différents algorithmes décrits dans BEAM, nous avons spécifié une architecture en trois couches. Ces couches correspondent 1) au stockage des données, 2) à la détection et 3) à l'interprétation des signaux faibles et communiquent à travers des outils tiers. La figure 4.6 illustre cette architecture.

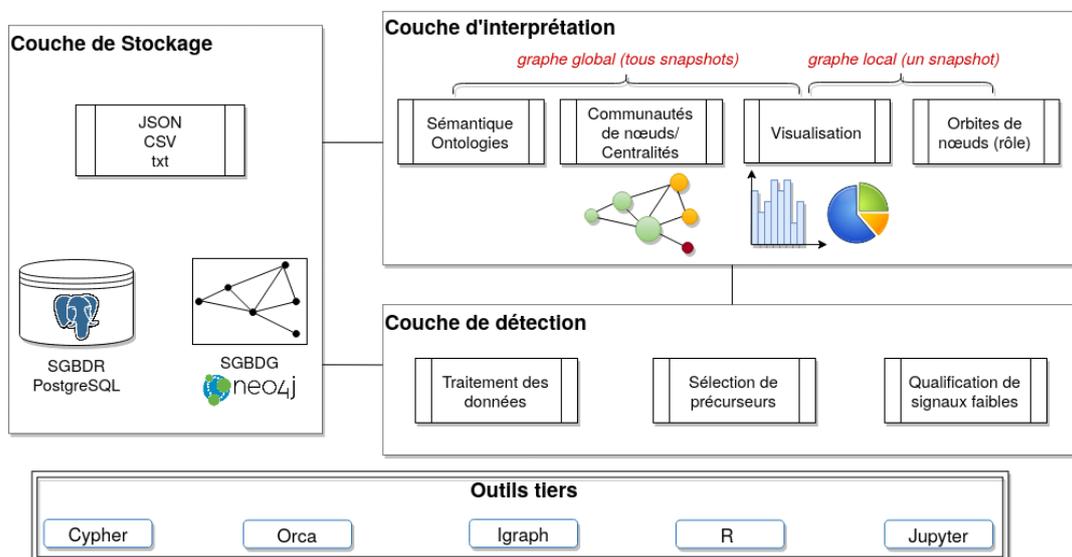


FIGURE 4.6 – Architecture du Proof of Concept.

La couche de stockage contient les données brutes collectées auprès des différentes sources, ainsi que les données résultantes des deux autres couches. Cette couche prend en charge différents types de fichiers de données sources aux formats CSV, TXT ou JSON (par exemple, les tweets sont téléchargés à partir de l'API Twitter sous la forme de fichiers JSON¹). Nous utili-

1. <https://developer.twitter.com/en/docs/twitter-api/v1/data-dictionary/overview>

4.3 Implémentation d'un Proof of Concept

score de centralité PageRank et le numéro de la communauté à laquelle il appartient.

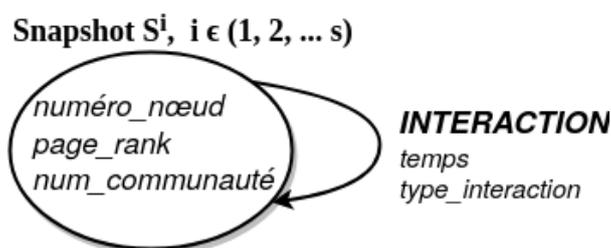


FIGURE 4.8 – « Pseudo-schéma » graphe représentant le corpus d'étude.

La couche de détection des signaux faibles utilise des outils tiers, notamment la bibliothèque de graphes `R Igraph` et l'algorithme Orca pour l'énumération des graphlets et des orbites. Elle transmet les signaux faibles détectés à la couche supérieure à des fins d'interprétation.

La couche d'interprétation contient tous les composants qui donnent sens aux signaux détectés dans la couche inférieure. Ces visualisations sont présentées aux experts métier sous la forme d'un tableau de bord comme le montre la maquette d'interface de la figure 4.9. Cette maquette illustre un exemple d'un snapshot étudié par un expert, où les parties 1 et 2 représentent les données d'interactions dans le snapshot avec leur graphe correspondant. Une fois l'algorithme Orca exécuté, l'expert a accès aux informations sur les graphlets (leur nombre normalisé, leur vitesse et leur accélération, partie 3) et les requêtes *Cypher* sur la base de données *Neo4j* les visualisent sous la forme de graphes (partie 4). En plus, nous proposons deux visualisations pour le nombre de nœuds apparaissant dans chaque orbite des graphlets : soit sous la forme d'histogramme en partie 4.a soit sous la forme d'un diagramme en secteurs en partie 4.b. Dans la partie 5, l'expert est capable d'avoir une vision centrée sur une instance d'un graphlet de la partie 4, avec l'ensemble de ses nœuds. Les communautés détectées sont illustrées dans la partie 6. Il est possible de visualiser les scores de centralité des nœuds pour un snapshot uniquement, ou bien pour le graphe global. Dans la partie 7, les scores PageRank sont calculés pour le graphe du corpus de l'étude (tous snapshots confondus). À droite de cette figure, un panneau historique est proposé, il permet à l'expert de revenir à une visualisation précédente, ou de visualiser les données par rapport à une séquence de snapshots sous la forme d'un cube de données, de barres groupées ou d'un secteur circulaire groupé, etc.

Ces trois couches communiquent par le biais de *workflows* reproductibles que nous avons mis en œuvre à l'aide des *notebooks* Jupyter [149]. Un *notebook* Jupyter est un outil distribué sous licence BSD (Berkeley Software Distribution) utilisé pour l'analyse exploratoire des données. Il permet aux chercheurs en sciences de données de créer des scripts combinant du code, du texte et des interfaces graphiques. Des noyaux spécifiques pour différents langages de programmation fonctionnent indépendamment et interagissent avec Jupyter, notamment Python, R et Scala. Nous considérons le *notebook* Jupyter comme un environnement interactif qui nous permet de recueillir une description des données d'entrée, de développer avec plusieurs langages de programmation dans un seul noyau, puis d'enregistrer les résultats en JSON, PDF ou HTML. La figure 4.10 montre une capture d'écran du *notebook* Jupyter représentant un cas d'étude dans une expérience menée sur les interactions entre les babouins, cette expérience est décrite en section 5.1.2. En haut à droite de cette figure, le type de noyau utilisé pour compiler le code écrit est affiché. Comme mentionné précédemment, nous utilisons le noyau R

CHAPITRE 4 : BEAM : Étape d'interprétation des signaux faibles

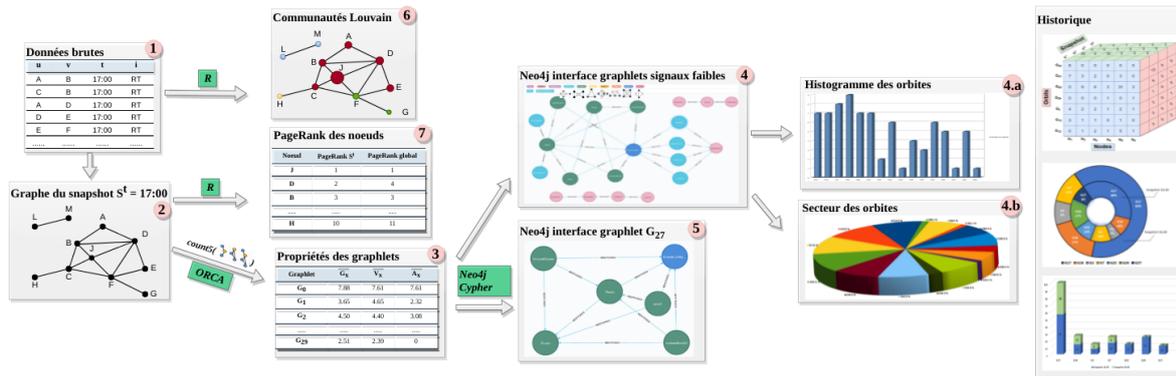


FIGURE 4.9 – Maquette d’interface utilisateur pour un snapshot particulier, à droite, un panneau historique pour tous les snapshots étudiés.

pour exécuter nos scripts. Sur la gauche se trouve un panneau de navigation qui montre les sections qui composent ce *notebook*. Le contenu de la section surlignée (5) en jaune dans ce panneau, est affiché dans la cellule centrale de l’éditeur. Les scripts sont mis en œuvre à l’aide de bibliothèques et de fonctions R, afin de créer une série de snapshots (sous forme de graphes temporels) à partir des interactions des babouins. Une fois que l’exécution des scripts R dans cette cellule est terminée, le temps d’exécution est automatiquement affiché sous la cellule. Sous la cellule centrale se trouve une autre cellule représentant le graphe résultant d’un snapshot particulier. Ici le numéro du snapshot est 13, donc le résultat montre la liste des nœuds interagissant dans ce snapshot.

Figure 4.10 is a screenshot of a Jupyter notebook titled 'Baboons interactions'. The left sidebar shows a table of contents with '5 Snapshots Creation' highlighted. The main area contains a code cell with the following R script:

```

1 rm(links_temporal)
2 rm(nodes_temporal)
3 rm(graph_temporal)
4
5 #two-dimension list vectors, the first dimension represents the interval X,
6 #and the second dimension represents the snapshot S of interval X
7
8 nodes_temporal <- vector(mode="list",30)
9 graph_temporal <- vector(mode="list",30)
10 links_temporal <- vector(mode="list",30)
11
12
13 for(i in 1:max(baboons_interactions[[1]]$rank)){
14
15   links_temporal[[i]] <- as.data.frame(baboons_interactions %>%
16     filter(baboons_interactions$rank == i) %>%
17     count())
18
19   nodes_temporal[[i]] <- as.data.frame(union(links_temporal[[i]]$u1, links_temporal[[i]]$u2))
20   colnames(nodes_temporal[[i]]) <- "u"
21
22   graph_temporal[[i]] <- graph_from_data_frame(links_temporal[[i]],
23     directed = FALSE,
24     vertices = nodes_temporal[[i]])
25
26   graph_temporal[[i]] <- igraph::simplify(graph_temporal[[i]],
27     remove_multiple = TRUE,
28     remove_loops = TRUE)
29
30
31 }
32

```

The output cell shows the result of the script, displaying a list of nodes and their interactions for snapshot 13:

```

In [83]: 1 graph_temporal[[13]]
executed in 43ms, finished 17:13:21 2022-05-18

IGRAPH 8d91df1 UN-- 12 19 --
+ attr: name (v/c)
+ edges from 8d91df1 (vertex names):
(1) ARIELLE --FELIPE ARIELLE --HARLEM ARIELLE --KALI
(4) EWINE --FEYA EWINE --HARLEM EWINE --ANGELE
(7) EWINE --PIPO FEYA --FELIPE FELIPE --HARLEM
(10) FELIPE --ANGELE FEYA --PETOULETTE FEYA --ANGELE
(13) HARLEM --VIOLETTE HARLEM --ANGELE KALI --PIPO
(16) KALI --ATMOSPHERE PETOULETTE --ANGELE PETOULETTE --PIPO
(19) VIOLETTE --ANGELE

```

FIGURE 4.10 – Capture d’écran d’un notebook Jupyter.

4.4 Synthèse et conclusion

Dans ce chapitre, nous avons présenté différents points de vue que nous fournissons aux experts métier, leur permettant d'interpréter les signaux faibles détectés. Ces points de vue prennent plusieurs formes et plusieurs visualisations sur différentes temporalités (un seul snapshot, une séquence de snapshots) et sur plusieurs éléments (type ou instance de graphlet). Pour cela, nous utilisons plusieurs modèles et systèmes de stockage que nous avons présenté, ainsi que le POC développé avec le *notebook* Jupyter. Outre la reproductibilité des workflows, les *notebooks* Jupyter offrent une interactivité qui facilite l'analyse exploratoire des données. Dans l'étape de détection seules les relations directes ou indirectes sont exploitées pour détecter les signaux faibles. Dans l'étape d'interprétation, le contenu du discours porté par les noeuds et leur sémantique sont prises en compte. Ces deux étapes de la méthode BEAM montrent sa flexibilité et son pouvoir d'adaptation aux différents aspects d'un réseau d'interactions.

Dans un second temps, nous pouvons imaginer que les experts métier utilisent le *data story telling* pour convaincre les décideurs de la présence de signaux faibles. Le *data story telling* est une méthode utilisée dans les domaines de la stratégie, du *marketing* et de la communication, et se base sur la visualisation de données pour rendre accessible à plus d'individus la compréhension de ces données. Il ne s'agit plus de montrer des indicateurs mais de les transformer en histoires, ce que permet l'exploitation des images, vidéos, url contenues par exemple dans Twitter.



Le chapitre suivant décrit les différents jeux de données étudiés ainsi que la démarche expérimentale suivie pour évaluer la méthode BEAM.

ÉVALUATION DE LA MÉTHODE BEAM À TRAVERS DIVERSES ÉTUDES EXPÉRIMENTALES

Sommaire

5.1	Validation au moyen d'une vérité de terrain	83
5.1.1	Visite surprise du Président Macron à l'usine Lubrizol	83
5.1.2	Agression dans un groupe de babouins	94
5.2	Validation par contre-exemple	100
5.2.1	Cas d'évènements prévus et répétitifs : école primaire	100
5.2.2	Cas où le contexte n'est pas connu : Facebook et MathOverflow	102
5.3	Étude de la reproduction de résultats avec des données périodiques	103
5.3.1	Description des données brutes et construction du corpus d'étude	103
5.3.2	Étude du premier épisode	104
5.3.3	Étude du deuxième épisode	113
5.3.4	Suivi de comptes porteurs de signaux faibles dans la huitième saison de GOT	115
5.4	Étude de la sensibilité de la méthode	117
5.4.1	Visite surprise du Président Macron à l'usine Lubrizol : graphe des retweets	117
5.4.2	Visite surprise du Président Macron à l'usine Lubrizol : espace des hashtags	118
5.4.3	Game of Thrones : espace des hashtags dans le premier épisode	121
5.5	Synthèse et conclusion	126

L'OBJECTIF de ce chapitre est d'évaluer notre méthode BEAM de détection et d'interprétation des signaux faibles, en la mettant en œuvre à travers une série d'expérimentations sur plusieurs jeux de données issues de différents Réseaux Sociaux Numériques.

Pour rappel, nous adoptons une représentation d'un Réseau Social Numérique sous la forme d'un graphe étiqueté dont les interactions sont temporelles, et nous posons comme hypothèse

que des signaux faibles peuvent être détectés en se basant sur sa topologie. La notion de graphlets est alors utilisée comme support aux signaux faibles.

Les expérimentations décrites dans ce chapitre ont pour objectifs :

1. **la validation de la méthode BEAM** avec deux types d'expériences.

Le premier type d'expériences est une **validation au moyen d'une vérité de terrain**. Présenté en section 5.1, il comprend trois jeux de données qui contiennent des événements importants, l'objectif est de démontrer la capacité de BEAM à découvrir et à interpréter les signaux faibles annonciateurs de ces événements. Les deux premières expériences sont décrites en section 5.1.1 pour le jeu de données sur Lubrizol contenant des tweets publiés relatifs à la visite surprise du Président de la République Macron à l'usine Lubrizol ravagée par un incendie à Rouen en Septembre 2019 et, en section 5.1.2 avec des observations réalisées par un humain et des données de capteurs collectées dans un groupe de vingt babouins de Guinée vivants dans un enclos d'un centre pour primates en France. La dernière expérience, présentée en annexe D, étudie les tweets publiés à l'occasion de la réunion du Conseil Européen qui s'est tenue le 20 octobre 2020. À l'issue de cette réunion, l'annonce de la loi sur la politique agricole commune (PAC) a été faite.

Le deuxième type d'expériences, présenté en section 5.2, dans lequel le jeu de données ne contient pas d'évènements ou contient des évènements prévus ou répétitifs a pour objectif de vérifier que BEAM ne détecte pas de signaux faibles lorsqu'il n'existe pas d'évènements. Il s'agit d'une **validation par contre-exemples**. Nous utilisons les jeux de données suivants : des interactions entre des élèves et des enseignants d'une école primaire ; des publications sur les murs Facebook ; finalement des interactions entre les utilisateurs du site *StackExchange* « Math-Overflow ».

2. **l'étude de la reproduction de résultats avec des données périodiques**. Le jeu de données utilisé contient les retweets publiés, entre avril et mai 2019, lors de la diffusion des six épisodes de la dernière saison de la série télévisée *Game of Thrones*, (GOT) (section 5.3).

3. **l'étude de la sensibilité de la méthode BEAM** en faisant varier les conditions expérimentales afin de vérifier sa robustesse. Pour deux jeux de données, Lubrizol et GOT, nous avons étudié d'autres interactions entre utilisateurs mais aussi l'espace des hashtags (section 5.4).

Les expériences portent sur différents jeux de données issues de plusieurs Réseaux Sociaux Numériques, en particulier Twitter. Certains ont été collectés dans le cadre du projet Cocktail, d'autres sont fournis en *open data*. Pour chacune des expérimentations, nous présentons le jeu de données brutes, le contexte et l'objectif de l'expérience. Les étapes réalisées et finalement les résultats obtenus sont détaillés. Pour toutes les expériences décrites dans ce chapitre, nous avons fixé un top k égal à cinq pour la liste des signaux faibles. Les contributions des graphlets (calculées en étape 4 de BEAM) sont classées par ordre croissant, et les premiers cinq graphlets sont listés parmi les signaux faibles. Ce choix du top k n'est pas exhaustif, mais il laisse un temps suffisant aux experts métier pour interpréter les signaux faibles. Ce chapitre se termine par une synthèse des résultats obtenus.

5.1 Validation au moyen d'une vérité de terrain

Nous présentons dans la suite deux expériences dont l'objectif est de montrer que les signaux faibles identifiés par BEAM sont liés à des événements qui se produisent après leur identification. Les données ont, pour la première expérience, été collectées dans le cadre du projet Cocktail et nous avons choisi un événement qui n'était pas connu des utilisateurs ; pour l'autre il s'agit de données téléchargées depuis le site SocioPatterns qui offre des jeux de données en ligne gratuits à la communauté scientifique. Ce dernier jeu de données comporte aussi une vérité de terrain qui nous permettra de valider les signaux faibles détectés.

5.1.1 Visite surprise du Président Macron à l'usine Lubrizol

Le 26 septembre 2019, un incendie s'est déclaré dans une partie de l'usine Lubrizol¹ à Rouen et dans trois bâtiments de Normandie Logistique. Lubrizol fabrique notamment des produits chimiques additifs pour lubrifiants industriels et pour les carburants. Elle est classée SEVESO seuil haut, c'est-à-dire à risque élevé en raison de la nature toxique de ses produits. L'incendie a provoqué une fuite de pétrole ainsi que de nombreuses explosions. Une fumée noire longue de 22 km s'est propagée dans l'atmosphère.

Dès le début, Twitter a joué un rôle très important dans la diffusion de l'information sur cet incendie. Alors que l'incendie a débuté vers 2 heures 40 minutes, le premier tweet relatif à cet incendie a été publié à 3 heures 3 minutes par Thomas Schonheere, journaliste à France Bleu Normandie. Le hashtag #lubrizol apparaît pour la première fois à 4 heures 15 minutes, et le premier tweet d'une institution, le préfet de la Seine Maritime, est émis à 4 heures 50 minutes demandant d'éviter le secteur (voir figure 5.1).

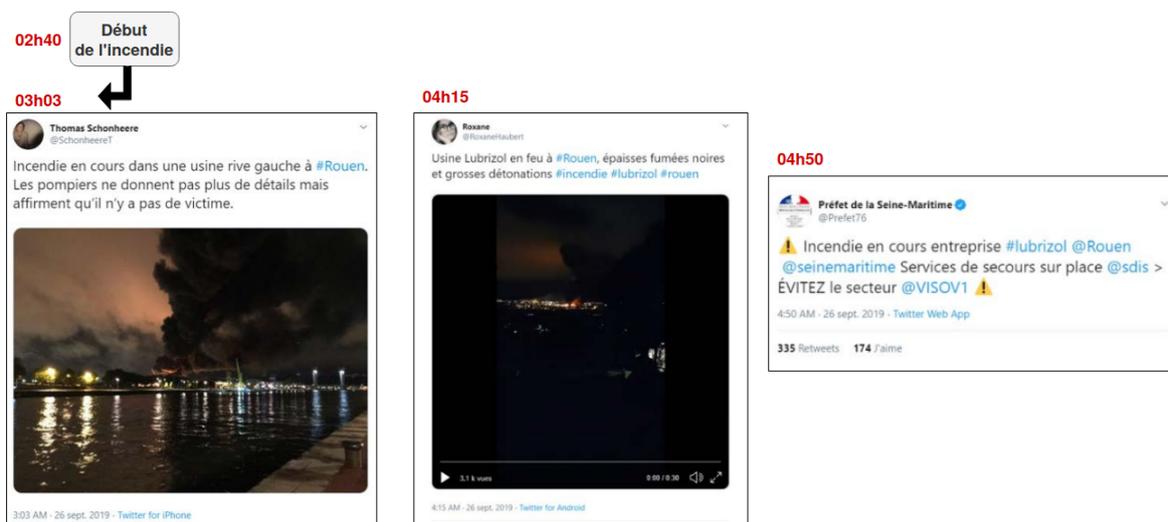


FIGURE 5.1 – Premiers tweets relatifs à l'incendie de Lubrizol.

1. <https://france.lubrizol.com/fr-FR/About>
https://www.lexpress.fr/actualite/societe/incendie-de-l-usine-lubrizol-a-rouen-ce-que-l-on-sait-un-mois-apres_2104941.html

Description des données brutes

L’ampleur de cet accident nous a amené à lancer, dans le cadre du projet Cocktail, une collecte des données Twitter grâce à la plateforme Hydre [70]. À l’aide de nos collègues de l’équipe des Sciences Humaines et Sociales de Cocktail, 47 hashtags et 111 comptes utilisateurs ont été sélectionnés comme critères de collecte. Nous présentons ci-dessous un exemple des critères choisis :

Hashtags : #CELubrizol, #lubrizolrouen, #lubrizoltransparence, #seveso, #VeritePourRouen, #WarrenBuffettDoitPayer, etc.

Utilisateurs : @atmonormandie, @fbleunormandie, @Min_Ecologie, @prefet76, @regionNormandie, @damienadam76, etc.

Ces critères ont permis de collecter environ 2 millions de tweets entre le 26 septembre et le 26 novembre 2019.

Construction du corpus d’étude

Pour les besoins expérimentaux, nous avons filtré les données pour ne garder que les tweets contenant les mots `lubrizol` ou `rouen`. Par exemple, nous avons retenu les tweets contenant `lubrizol` ou `rouen` avec `controlessanitaires`, ou encore `rouen` avec `desastreecologique`. Ainsi, des tweets collectés mais sans rapport avec l’accident sont éliminés, par exemple le compte `@Min_Ecologie`, compte Twitter du Ministère de l’Écologie, a émis des tweets durant cette période sans rapport avec `Lubrizol`. À l’issue de cette opération, le corpus est réduit à 558 895 tweets. Parmi ces tweets, 73 126 sont des tweets originaux et 136 032 mentions ont été émises par 141 177 comptes. Durant la seule journée du 26 Septembre, 35 242 tweets sont émis dont 8 506 contiennent des mentions. Le tableau 5.1 résume les indicateurs globaux de ce corpus.

Indicateur	Valeur
Nombre total de tweets	558 895
Nombre de tweets originaux	73 126
Nombre de retweets	485 769
Nombre de mentions	136 032
Nombre de réponses	19 340
Nombre de quotes	40 883
Nombre de comptes utilisateurs	141 177
Nombre de hashtags	11 660

TABLE 5.1 – Indicateurs globaux calculés à partir du corpus de l’étude de `Lubrizol`.

Nous avons aussi sélectionné les utilisateurs les plus retweetés et les plus mentionnés, à l’aide de requêtes analytiques SQL lancées sur notre base de données relationnelle. `@EmmanuelMacron`, compte officiel du Président Français et `@Prefet76`, compte officiel de la préfecture de la Seine-Maritime, ont été les plus mentionnés dans ce corpus ; `@Prefet76` est aussi parmi les comptes les plus retweetés.

5.1 Validation au moyen d'une vérité de terrain

Détection des signaux faibles

Nous avons choisi comme évènement la visite du Président Macron sur le site à Rouen le mercredi 30 octobre en fin d'après-midi. Cette visite n'était pas à l'agenda présidentiel et n'a été annoncée qu'en toute fin d'après-midi. Cette visite surprise a été considérée comme un évènement important ce qui nous a amené à la considérer comme point d'intérêt pour notre expérience. Les objectifs de l'expérience sont :

- d'observer la circulation de l'information sur Twitter et de trouver des indicateurs agissant comme signaux faibles de la survenue de cet évènement ;
- d'étudier la construction du discours sur Twitter.

La visite ayant eu lieu vers 18 heures le 30 octobre 2019, nous avons réduit la période de l'étude à cette journée entre 12 heures et 19 heures 30 minutes, durant laquelle 16 385 tweets ont été émis. Nous avons choisi, dans un premier temps, la mention comme interaction car elle montre l'inclusion de personnes dans le discours Twitter. Elle prend ici tout son sens, car l'évènement concerne Emmanuel Macron (@EmmanuelMacron), mais il est aussi lié à des ministres, à la municipalité de Rouen, au Préfet, etc. Notre étude porte sur 845 utilisateurs qui ont émis 1 141 mentions.

Nous avons réalisé des expérimentations sur des snapshots de différentes durées afin d'étudier l'impact du changement des durées sur la détection des signaux faibles. Nous avons étudié des snapshots de 60, 30, 15 et finalement de 10 minutes. Le choix de la durée des snapshots dans cette expérience est un compromis entre la précision et la complexité : 1) les snapshots de 10 minutes contiennent peu de liens entre les entités ce qui peut entraver la recherche de

certains graphlets à 5 nœuds comme le G_{24}  ou le G_{28}  par exemple ; 2) à l'opposé, les snapshots de 60 minutes « cachent » les graphlets de petites tailles. Une étude en annexe C présente la démarche expérimentale réalisée pour l'identification des signaux faibles sur les différentes durées de snapshots citées précédemment, ainsi que les résultats obtenus. En se basant sur les résultats obtenus dans ces expérimentations, une durée de snapshots égale à 30 minutes garantira le plus grand nombre de graphlets signaux faibles porteurs de l'information sur l'évènement étudié.

Dans ce qui suit, nous allons détailler les résultats obtenus pour le snapshot de 16 heures 30 minutes à 17 heures qui contient 52 nœuds et 62 liens. Pour ce snapshot, nous avons énuméré les graphlets à l'aide de l'algorithme Orca, calculé leurs vitesses et leurs accélérations, et finalement construit la carte d'émergence des graphlets. Pour sélectionner les précurseurs nous avons choisi un seuil égal à la moyenne des vitesses et des accélérations, et avec lequel nous avons divisé la carte en quatre quadrants. La figure 5.2 illustre cette carte d'émergence où les graphlets précurseurs peuvent être distingués des autres par la zone hachurée en bleu. Le nombre des précurseurs sélectionnés correspond à la moitié du nombre des graphlets, ce qui indique leurs émergences rapides dans ce snapshot.

Une fois les graphlets précurseurs identifiés, nous sommes passés à leurs qualifications en signaux faibles ou non, en nous basant sur le calcul des contributions. Le ratio de la contribution globale d'un graphlet G_x est calculé en divisant son nombre total dans tous les snapshots étudiés par le nombre total de tous les graphlets pour ces snapshots. Les ratios sont classés par ordre croissant et les k premiers graphlets sont qualifiés de signaux faibles, car ce sont ceux qui contribuent le moins et qui donc expriment le critère de rareté. Le tableau 5.2 liste les top cinq graphlets signaux faibles détectés dans le snapshot, classés par ordre croissant de leur contribution globale.

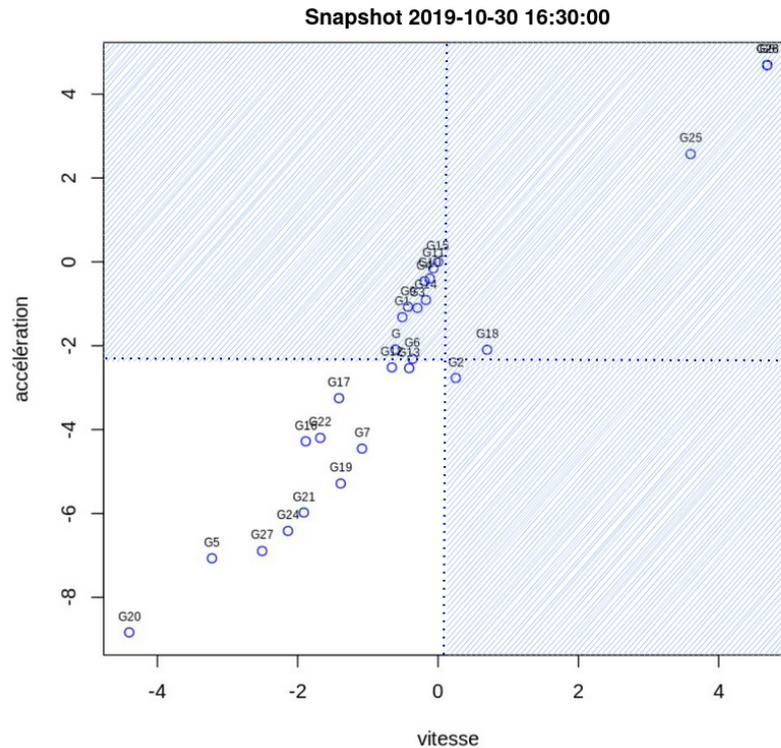


FIGURE 5.2 – Graphlets précurseurs identifiés *via* la carte d'émergence pour le snapshot étudié.

Graphlet	G_4	G_{11}	G_{10}	G_9	G_{14}
Forme					
Contribution Globale	-0.0073	-0.0072	-0.0064	-0.0059	-0.0017

TABLE 5.2 – Top cinq des graphlets qualifiés de signaux faibles dans le snapshot étudié.

Confirmation des signaux faibles

Pour confirmer les signaux faibles, nous utilisons la méthode cross-correlation. Une série temporelle correspondant au nombre de mentions sur toute la période est représentée par la série temporelle (x_1, x_2, \dots, x_s) , où x_i est le nombre de mentions au snapshot S^i et s le nombre de snapshots. La figure 5.3 représente dans sa partie gauche la série temporelle des mentions entre 12 heures 30 et 19 heures 30 minutes où le nombre maximal des mentions est atteint à 18 heures 30 minutes. De même, nous avons construit les séries temporelles pour chacun des trente graphlets pour tous les snapshots de la période d'étude. À droite de la figure 5.3 est la série temporelle correspondante au graphlet signal faible G_{11} .

Après avoir appliqué la cross-correlation entre les trente séries temporelles des graphlets et celle des mentions, nous avons observé les corrélogrammes obtenus. Les graphlets signaux faibles G_4, G_9, G_{10}, G_{11} et G_{14} présentent des corrélations positives ($0.7 \leq \rho \leq 0.8$) avec un décalage négatif égal à -1 ou -2, c'est-à-dire correspondant à 30 et 60 minutes car la durée des snapshots a été fixée à 30 minutes. La partie gauche de la figure 5.4 montre le corrélogramme de G_{11} où la ligne en rouge correspond à une corrélation positive (de valeur égale à + 0.62) de décalage négatif de 30 minutes ($\rho = -1$). À droite de cette figure, le corrélogramme du

5.1 Validation au moyen d'une vérité de terrain

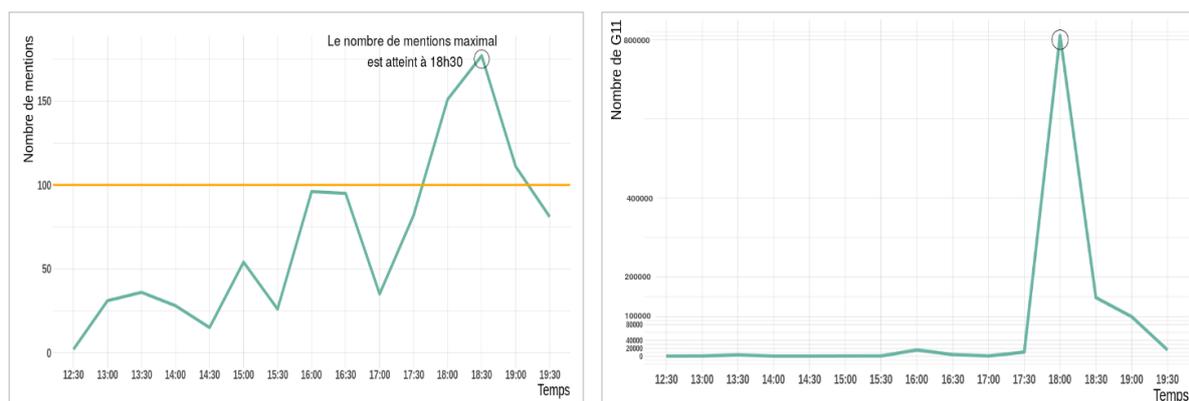


FIGURE 5.3 – Séries temporelles du nombre des mentions et du graphlet G_{11} signal faible, le jour de la visite.

graphlet G_{22} qui n'a pas été détecté comme signal faible présente une corrélation de valeur égale à 0.6 et un décalage positif de valeur égale à +1 c'est-à-dire que l'évènement étudié précède de 30 minutes (ligne en rouge). Ce graphlet sera éliminé de l'étude ou alors gardé pour des analyses ultérieures, et le G_{11} confirmé comme signal faible. Les corrélogrammes des graphlets G_2 , G_5 , G_{18} et G_{19} identiques à celui du G_{22} , sont aussi hors la liste des signaux faibles.

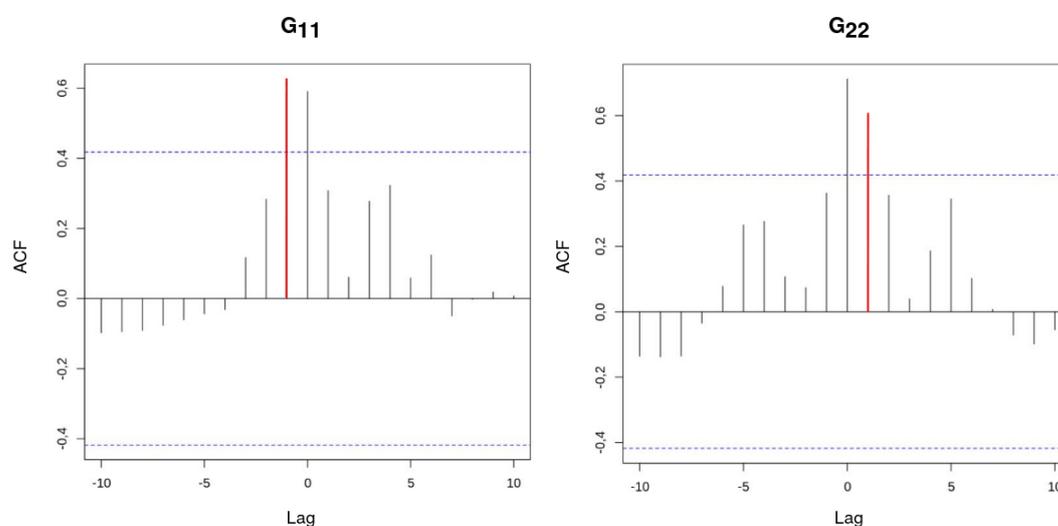


FIGURE 5.4 – Corrélogrammes des graphlets G_{11} signal faible, et G_{22} pour la période étudiée.

D'après l'étude des corrélations, nous avons pu confirmer les graphlets signaux faibles en justifiant leur relation avec l'évènement étudié. Les autres graphlets non signaux faibles ne présentent pas de corrélations significatives d'un décalage négatif avec cet évènement.

Interprétation des signaux faibles

Nous analysons plusieurs éléments pour valider les graphlets signaux faibles détectés, notre objectif est de confirmer que les comptes apparaissant dans les instances de ces graphlets aient émis des tweets relatifs à la visite surprise du Président Macron. Dans un premier temps, nous

identifions les utilisateurs grâce aux positions ou orbites qu'ils occupent dans les instances de graphlets signaux faibles. Dans un second temps, nous réalisons une étude qualitative de leurs tweets ainsi que de leurs relations avec d'autres utilisateurs avant l'évènement.

Comptes utilisateurs dans les graphlets signaux faibles Avec des requêtes SQL analytiques exécutées sur les tables dans lesquelles sont sauvegardés les résultats de BEAM, nous avons pu identifier des nœuds importants et leurs positions dans les graphlets signaux faibles. Pour rappel, Orca calcule aussi le nombre de fois où chaque nœud apparaît dans les orbites des graphlets. Le tableau 5.3 montre quelques nœuds ou comptes utilisateurs Twitter, ainsi que leur type et la fréquence de leur apparition dans les orbites, pour le snapshot étudié.

Compte Twitter	Type du compte	Graphlet	Orbite	Forme	Fréquence
@EmmanuelMacron	Président de la République Française	G10	O21		2 599
		G11	O23		3 901
		G14	O33		837
@benoit_gregory	Directeur et Photographe	G10	O19		261
		G11	O22		867
		G14	O31		106
@HerveHunkeler	Professeur de lettres à l'Université de Rouen	G10	O19		339
		G11	O22		857
		G14	O31		106
@fredveille	Journaliste RTL France, correspondant Paris-Normandie	G10	O19		321
		G10	O20		164
		G11	O22		857
		G14	O31		106
@CamaradeCharles	Animateur en école, Youtubeur en région Seine-Maritime	G10	O20		324
		G10	O21		47
		G11	O22		754
		G14	O32		118
@76actu	Site d'informations locales en Seine-Maritime	G10	O20		309
		G11	O22		533
		G14	O32		339

TABLE 5.3 – Positions (orbites) des comptes Twitter importants apparaissant dans les instances de trois graphlets signaux faibles pour le snapshot étudié.

D'après ce tableau, nous remarquons que le compte du Président Macron occupe majoritairement des positions centrales, confirmant que les twittos s'adressaient fortement à lui avant sa visite surprise. Les autres comptes représentent des journalistes, des youtubeurs,

5.1 Validation au moyen d'une vérité de terrain

des médias occupant des positions périphériques dans les graphlets signaux faibles comme @benoit_gregory, @HerveHunkeler. Les comptes @fredveille, @CamaradeCharles et @76actu se trouvent à la périphérie avec les orbites O_{19} , O_{22} et O_{31} , mais aussi dans une position intermédiaire avec les orbites O_{20} et O_{32} . Cela met en évidence qu'un même utilisateur peut jouer des rôles différents mais essentiels lors de contacts avec d'autres comptes. Une autre visualisation du tableau précédent correspond aux cellules du cube présenté dans la figure 5.5. Le cube offre la possibilité de suivre l'évolution des orbites des nœuds au cours du temps avec les trois dimensions, nœud ou compte utilisateur, orbite d'un graphlet signal faible et le temps. Les cellules marquées en gris dans ce cube signifient respectivement : 1) @EmmanuelMacron apparaît dans l'orbite O_{23} du graphlet G_{11} 3 901 fois pour le snapshot de 16 heures 30 minutes; 2) @fredveille apparaît dans l'orbite O_{33} du graphlet G_{14} 3 fois pour le snapshot de 18 heures; 3) @76actu apparaît dans l'orbite O_{22} du graphlet G_{11} 1 311 fois pour le snapshot de 17 heures 30 minutes. Nous avons créé ce cube à partir de la requête analytique SQL donnée dans le listing 5.1. Elle utilise les données stockées dans les tables correspondant aux graphlets et aux orbites des snapshots sélectionnés dans la clause WHERE, et classe les nœuds suivant le nombre de fois où ils apparaissent dans les orbites.

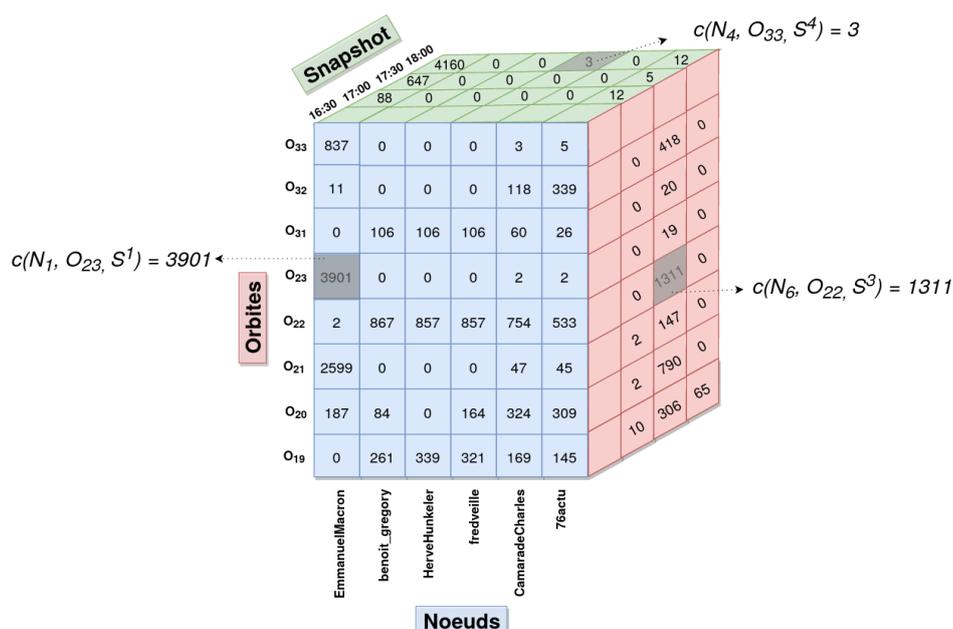


FIGURE 5.5 – Cube représentant les données sur les utilisateurs.

```

SELECT g.user_screen_name,g.graphlet,g.orbit, o.orbit_count,
DENSE_RANK()OVER(PARTITION BY g.user_screen_name, g.graphlet
ORDER BY o.orbit_count::NUMERIC DESC) AS orbit_rank
FROM graphlets g, orbits o
WHERE o.node = g.user_id
AND g.orbit = o.orbit
AND g.graphlet in ('G10', 'G11', 'G14')
AND o.orbit_count <> '0'
AND g.snapshot IN ('16:30', '17:00', '17:30', '18:00')

```

```
ORDER BY g.user_screen_name, g.graphlet, g.orbit;
```

Listing 5.1 – Requête analytique SQL qui retourne les données du cube.

Afin de permettre aux experts métier de réaliser une analyse plus fine, des requêtes *Cypher* sur une base de données graphes *Neo4j* permettent de sélectionner des instances de graphlets et ainsi voir quels nœuds sont en contact. Cette base a été alimentée par les interactions entre les compte utilisateurs du snapshot étudié, voire 62 interactions entre 52 nœuds. Étant donné la petite taille de cette base, les requêtes exécutées retournent des résultats en quelques secondes. La requête *Cypher* du listing 5.2 renvoie six instances différentes du graphlet G_{10} identifié en tant que signal faible. Si nous supprimons les conditions avec l'opérateur OR de la clause WHERE, le résultat est une seule instance du G_{10} .

```
MATCH (u1:Lubrizol)--(u2:Lubrizol)--(u3:Lubrizol)--(u4:Lubrizol), (u3
:Lubrizol)--(u5:Lubrizol)
WHERE NOT ((u1)--(u3)) AND NOT ((u1)--(u4)) AND NOT ((u1)--(u5)) AND
NOT ((u2)--(u4)) AND NOT ((u2)--(u5)) AND NOT ((u4)--(u5))
AND (u1.name = 'manon_leterq' OR u1.name = 'massinfabien')
AND u2.name = 'CamaradeCharles'
AND u3.name = 'EmmanuelMacron'
AND u4.name = 'fredveille'
AND (u5.name = 'benoit_donckele' OR u5.name = 'jeremychatet')
RETURN *
```

Listing 5.2 – Requête Cypher qui sélectionne six instances du graphlet G_{10} .

La figure 5.6 présente une des instances de G_{10} entourée en rouge, renvoyée par la requête. Dans cette instance, nous trouvons @EmmanuelMacron dans la position centrale, orbite O_{21} , @CamaradeCharles dans la position intermédiaire, orbite O_{20} , et @massinfabien, @benoit_donckeler et @fredveille dans les deux positions périphériques, orbites O_{18} et O_{19} respectivement. Les autres instances de cette figure conservent les nœuds @EmmanuelMacron et @CamaradeCharles dans la même orbite, et basculent entre les nœuds restants sur les deux positions périphériques.

En figure 5.7, un autre exemple est montré où la partie gauche montre une instance du graphlet G_{14} avec en position centrale toujours @EmmanuelMacron dans l'orbite O_{33} et en position intermédiaire avec l'orbite O_{32} @CamaradeCharles, @JeromeMorniere, un journaliste à *76actu* puis en position périphérique avec l'orbite O_{31} @Tendanceouest76 un site Web avec une radio et un journal de la région de la Normandie, et @paris_normandie un site Web de l'actualité locale et régionale.

Nous remarquons que les nœuds appartenant à cette instance de graphlet forment un groupe de journalistes et de sites d'actualités autour du compte du Président Macron. Cette instance de graphlet signal faible met en évidence le rôle des médias sociaux dans la diffusion des informations sur Twitter. À droite de cette figure, nous avons représenté les liens de mention orientés entre les nœuds. Nous remarquons que les mentions du compte du Président sont les plus nombreuses mais aussi que @CamaradeCharles mentionne des médias.

Activité de ces comptes avant l'évènement Après l'identification des nœuds apparaissant dans les graphlets signaux faibles, nous avons étudié le contenu de leurs tweets quelques heures précédant la visite surprise du Président, ainsi que les relations qu'ils ont eu avec d'autres comptes.

5.1 Validation au moyen d'une vérité de terrain

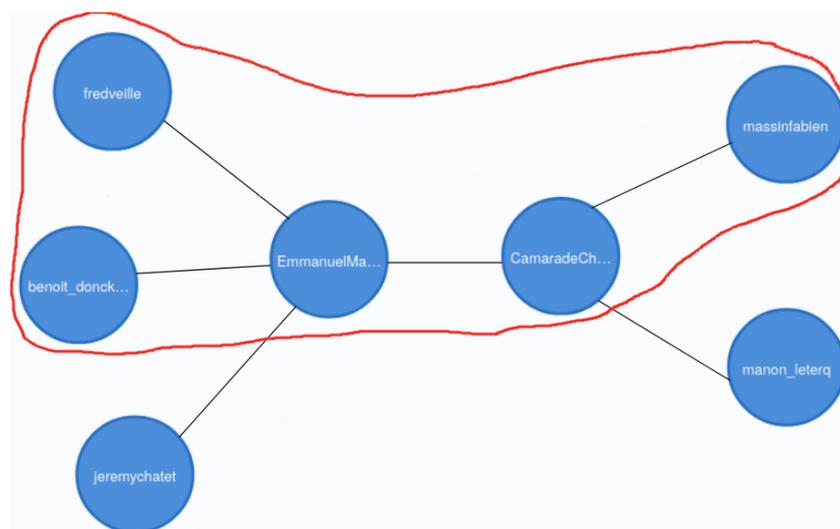


FIGURE 5.6 – Une instance du graphlet G_{10} mise en évidence parmi les six instances, dans le snapshot de 16 heures 30 minutes.

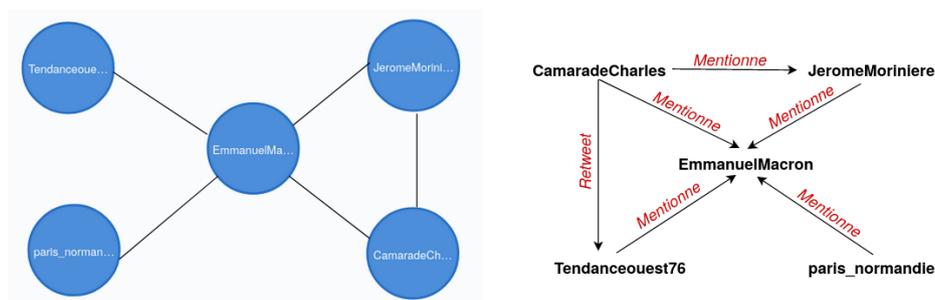


FIGURE 5.7 – Une instance du graphlet G_{14} et les mentions, dans le snapshot de 16 heures 30 minutes.

Nous avons trouvé que le premier tweet annonçant la visite du Président à Lubrizol a été émis par @jeremychatet, journaliste à Paris_Normandie à 13 heures 40 minutes. Dans son tweet, il a cité le Président tout en indiquant une visite possible le jour même, en utilisant les hashtags #Rouen et #Lubrizol. Ensuite vers 16 heures 40 minutes, il annonce l'arrivée du Président dans les prochaines minutes à la mairie de Rouen. Le deuxième tweet a aussi été émis par une journaliste de Paris Normandie (service des reportages), @violaineGargala à 13 heures 41 minutes dans lequel elle annonce la possibilité d'avoir une visite, sans avoir cité le compte du Président; elle a juste mentionné le journal où elle travaille, avec les hashtags #Lubrizol et #Rouen. Le troisième tweet publié à 13 heures 42 minutes, c'est-à-dire une seconde après celui de @violaineGargala, était émis par le compte officiel du journal @paris_normandie dans lequel elle travaille. Dans le tableau 5.4, nous avons reproduit ces trois premiers tweets, ce sont des tweets originaux qui contiennent des informations précises sur la date et le lieu de la visite, ils utilisent des hashtags pertinents et le fait qu'ils soient émis par des journalistes et des médias, officialise l'information.

Nous avons également examiné l'activité des utilisateurs identifiés dans les graphlets signaux faibles pour étudier leur rôle dans l'annonce ou la diffusion de l'information, quelques heures avant la visite du Président (voir tableau 5.4). La version originale de ces tweets est don-

Compte Twitter	Tweet	Heure
@jeremychatet	@EmmanuelMacron aujourd'hui à #Rouen ? Le chef de l'État pourrait y effectuer un déplacement un peu plus d'un mois après #Lubrizol	13 :40
@CamaradeCharles	La visite de Macron est confirmée à #Rouen. Sur les réseaux sociaux, des #giletsjaunes appellent à se réunir devant le palais de justice à 18 heures pour l'accueillir. Faites passer le message.	15 :16
	RT @Tendanceouest76 : Le Président de la république est attendu dans les prochaines minutes à l'hôtel de ville de #Rouen après #Lubrizol.	16 :30
@Tendanceouest76	Le président est attendu dans quelques heures à Rouen, dans le cadre de l'incendie de Lubrizol #Normandie #SeineMaritime #Rouen #EmmanuelMacron #Lubrizol	15 :25
	Le Président de la république est attendu dans les prochaines minutes à l'hôtel de ville de #Rouen après #Lubrizol.	16 :10
@ViolaineGargala	#Lubrizol : un mois après l'incendie, Emmanuel Macron attendu à #Rouen en fin de journée @paris_normandie	13 :41
	@paris_normandie Pendant ce temps là à l'hôtel de ville de #rouen Emmanuel Macron est attendu	16 :34
@paris_normandie	Le président de la République @EmmanuelMacron pourrait effectuer un déplacement à #Rouen mercredi 30 octobre, #Lubrizol #LubrizolRouen #Normandie	13 :42
	RT @ViolaineGargala : #Lubrizol : un mois après l'incendie, Emmanuel Macron attendu à #Rouen en fin de journée @paris_normandie.	13 :42
	Suivez la visite surprise d'@EmmanuelMacron à Rouen en direct #Lubrizol	16 :32
@76actu	Incendie de #Lubrizol #EmmanuelMacron se rend à #Rouen : un appel à manifester.	15 :32
	@EmmanuelMacron @Rouen @manon_Jeterq @massinfabien @JeromeMoriniere #Lubrizol : Emmanuel #Macron devrait arriver à #Rouen dans une demi-heure. Notre direct pour suivre ce déplacement juste ici	16 :30
@JeromeMoriniere	RT @76actu : @EmmanuelMacron @Rouen @manon_Jeterq Un appel à manifester est lancé pour 18 heures. Nos journalistes @massinfabien et @JeromeMoriniere seront sur place #Lubrizol #Macron #Rouen.	16 :31
	@EmmanuelMacron à #Rouen pour #Lubrizol : le direct à suivre sur @76actu.	16 :35

TABLE 5.4 – Tweets annonçant quelques heures à l'avance, la venue du Président Macron à Rouen le 30 octobre. L'annexe E montre ces tweets.

née en annexe E. @CamaradeCharles émet son premier tweet le 30 octobre à 15 heures 16 minutes, qui ne sera pas repris, mais le contenu du tweet confirme la visite et en plus contient un appel à manifester. Ensuite, il continue à diffuser de l'information concernant l'évènement, en retweetant des tweets émis par @Tendanceouest76. Ce dernier compte annonce une visite probable du Président dans un tweet envoyé à 15 heures 25 minutes, et continue pendant l'heure suivante. Le compte @paris_normandie a été le plus actif entre 16 heures et 17 heures en retweetant l'information émise par ses journalistes. @76actu commence à communiquer sur une possible visite, il est ensuite retweeté par l'un de ses journalistes (@JeromeMoriniere) à 16 heures 31 minutes. Certains utilisateurs comme @benoit_gregory, @HerveHunkeler et @benoit_donckele se sont contentés de retweeter des tweets émis par d'autres journalistes ou par les médias, leur rôle s'est limité à propager l'information concernant la visite.

Nous avons réalisé une analyse qualitative en double aveugle des tweets du tableau 5.4. Nos collègues de l'équipe des Sciences Humaines et Sociales (SHS) du projet Cocktail ont proposé trois catégories par modalité énonciative : « information », « annonce » et « diffusion » et ensuite les ont classés par rapport à ces catégories. La figure 5.8 montre deux exemples de tweets catégorisés, avec les extraits de texte qui ont contribué à cette classification. Le tweet à gauche de la figure informe que le Président viendra à Rouen, appelle à manifester et demande de diffuser cet appel de manifestation ; la partie droite de la figure contient un retweet qui informe et annonce que les citoyens attendent une visite du Président.

Étude des communautés dans le graphe global Un processus pertinent dans l'analyse des réseaux sociaux est de découvrir des nœuds qui partagent des caractéristiques communes dans un réseau. Ce processus, appelé détection de communautés, consiste à trouver des groupes ayant une forte densité de liens. L'algorithme Louvain a détecté 44 communautés dans le graphe global du corpus d'étude (tous snapshots confondus), dans lequel 1 141 mentions ont

2. Communauté en rose foncé : des comptes comiques et des groupes publiant des tweets viraux ;
3. Communauté en rose : des médias et le groupe politique *La république en marche*, lancé en 2016 par Emmanuel Macron ;
4. Communauté en violet : des groupes de socialistes soutenant la santé publique ;
5. Communauté en bleu clair : compte du Président français, celui de l'ancien Président @fhollande né à Rouen, et @agnesbuzyn Ministre des solidarités et de la santé publique. La majorité des nœuds de cette communauté ont un score de PageRank élevé, ceci est démontré par leur taille dans la figure ;
6. Communauté en rouge : groupe de journalistes, de médias et @Lemaireflorent maire de Rouen ;
7. Communauté en bleu foncé : @jeremychatet journaliste à @paris_normandie, avec @DragonsdeRouen groupe local de Hockey ;
8. Communauté en jaune : comptes d'anciens ministres, @EPhilippePM Premier Ministre et @Elisabeth_Borne Ministre de l'écologie de 2019 jusqu'à 2020.

Les communautés montrent que certains comptes ont utilisé Twitter pour passer un message de soutien au Président, tandis que d'autres ont communiqué des messages d'humour et de critique, le reste est un groupe de journalistes chargés de fournir des informations d'actualités. Puis, nous avons étudié l'influence des utilisateurs dans leur communauté, en calculant, communauté par communauté, le score PageRank de chaque utilisateur. Dans la figure 5.9, la taille des nœuds utilisateurs est proportionnelle à leur score de PageRank. Nous notons que certains utilisateurs identifiés dans les tableaux 5.3 et 5.4 ont des scores de PageRank élevés. Par exemple, @EmmanuelMacron est classé en premier avec un rang PageRank égal à 1, @76actu et @paris_normandie avec des rangs de 7 et de 10 respectivement. D'autres comme @HerveHunkeler et @fredveille qui appartiennent aussi à la communauté en bleu clair, ont des rangs de 511 et de 130 sur les 845 utilisateurs. Ces résultats sont essentiels pour compléter l'analyse de l'expert métier, mais ne sont pas suffisants pour identifier des éléments annonceurs de l'évènement.

Conclusion Les signaux faibles que nous avons identifiés avec BEAM mettent en évidence des utilisateurs qui annonçaient ou propageaient l'information de la venue du Président Macron en fin de journée, au moins deux heures avant l'évènement. L'importance de l'identification de tels signaux est montrée par le fait qu'ils ont servi à appeler à manifester contre le Président. En effet, ils ont été saisis comme une opportunité d'appel à manifestation et pour le pouvoir en place comme une opportunité à communiquer l'action présidentielle mais aussi à contrôler les manifestants. Dans un deuxième temps, pour tester la robustesse de notre méthode, nous nous sommes intéressés aux retweets et à l'espace des hashtags. Les résultats seront présentés en sections 5.4.1 et 5.4.2.

5.1.2 Agression dans un groupe de babouins

L'objectif de l'étude menée sur cet ensemble de données est d'utiliser des observations réalisées par des primatologues, comme vérité de terrain, pour valider les signaux faibles que notre méthode BEAM a détecté. Ces signaux faibles peuvent être vus comme des indicateurs

5.1 Validation au moyen d'une vérité de terrain

de changement dans le comportement entre individus, notamment en cas d'agression ou d'attaque et être utilisés pour suivre l'évolution du groupe social à long terme.

Description du corpus d'étude

L'ensemble des données utilisées dans cette étude représente le corpus d'étude formé à partir d'une liste d'interactions entre des individus appartenant à un groupe de babouins de Guinée vivants en captivité. Les données couvrent une fenêtre temporelle de près d'un mois entre le 13 juin et le 10 juillet 2019 et ont été collectées par deux méthodes différentes : 1) des observations comportementales par des primatologues et 2) une infrastructure basée sur des capteurs portables. Nous avons téléchargé les données correspondantes depuis le site *SocioPatterns*, <http://www.sociopatterns.org/datasets/baboons-interactions/>.

L'ensemble des données a été utilisé par Gherardi et al. [67] pour vérifier si une interaction entre les babouins observée par un humain a également été enregistrée par les capteurs, ainsi que le temps nécessaire de chaque méthode pour obtenir un réseau social robuste.

Les capteurs portables sont placés dans des colliers en cuir qui équipent un groupe de vingt babouins (voir figure 5.10). Deux individus sont considérés comme étant en contact pendant

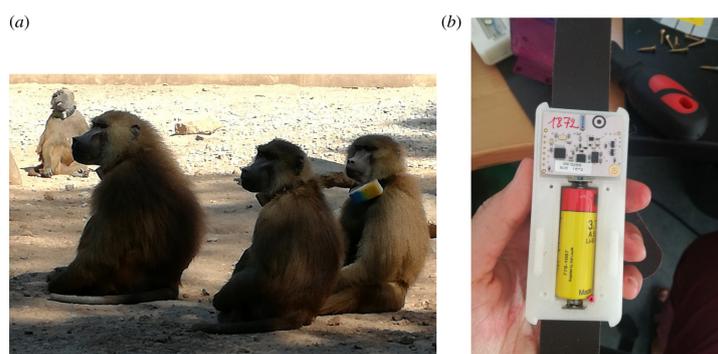


FIGURE 5.10 – (a) Babouins portant le collier (b) Intérieur d'un capteur et sa batterie (extrait de [67]).

un intervalle de 20 secondes, si leurs capteurs ont échangé au moins un paquet pendant cet intervalle, et l'évènement de contact est terminé lorsque les capteurs n'échangent aucun paquet pendant un intervalle de 20 secondes.

Les données issues des capteurs se composent de 63 095 interactions sous la forme d'un tuple à trois composantes (u, v, t) , comme le montre l'extrait dans le tableau 5.5 : u et v sont les noms des babouins en contact et t représente le *timestamp*² auquel l'interaction a eu lieu.

Les données sont ordonnées suivant le temps t et divisées en snapshots de même durée égale à 30 minutes. Nous avons appliqué sur chaque snapshot, les étapes de détection des signaux faibles de la méthode BEAM. Nous ne présentons dans la suite que les résultats obtenus sur le snapshot débutant à 8 heures le 19 juin 2019 qui comporte 3 076 interactions.

Détection des signaux faibles

À l'issue de l'étape 3 de BEAM, nous choisissons un seuil égal à la moyenne des vitesses et des accélérations pour la sélection des précurseurs. Ceux-ci sont les graphlets ayant des valeurs

2. Par exemple, le 13 juin 2019 03 :28 :20 correspond au timestamp 1560396500.

u	v	t
ARIELLE	FANA	1560396500
ARIELLE	VIOLETTE	1560396500
FANA	HARLEM	1560396520
FELIPE	ANGELE	1560396540
ARIELLE	FANA	1560396540
BOBO	FELIPE	1560396580

TABLE 5.5 – Extrait du fichier de données des interactions entre babouins collectées par les capteurs.

supérieures ou égales au seuil choisi. Nous construisons ensuite une carte d'émergence des graphlets pour le snapshot étudié (voir figure 5.11), divisée en quatre quadrants par rapport au seuil. La zone hachurée en bleu de la carte montre les graphlets identifiés comme précurseurs.

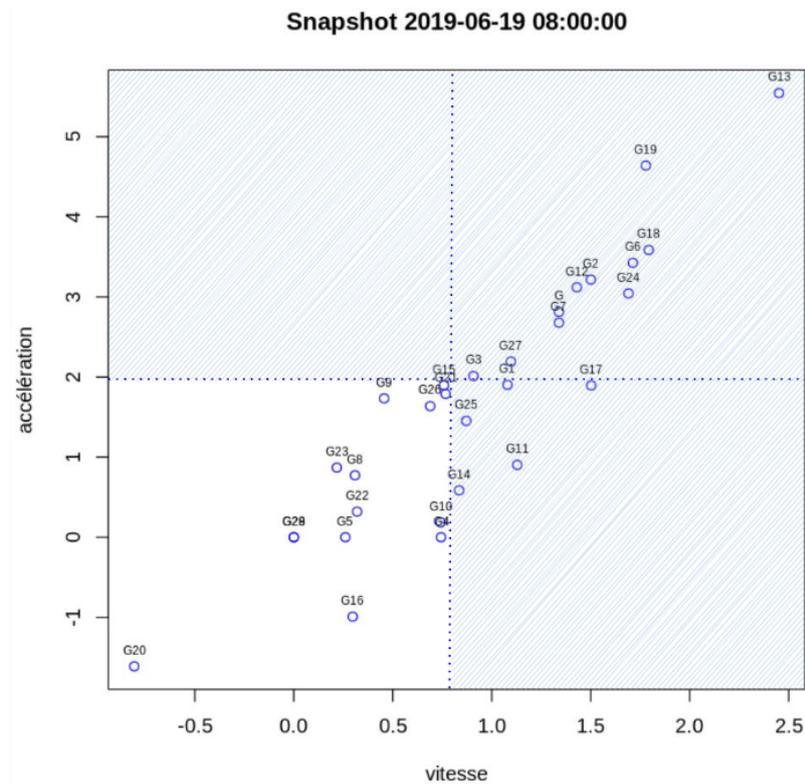


FIGURE 5.11 – Graphlets précurseurs identifiés *via* la carte d'émergence pour le snapshot étudié.

À l'issue de l'étape 4 de BEAM (calcul de contributions), nous présentons les top 5 graphlets retenus comme signaux faibles dans le tableau 5.6.

Confirmation des signaux faibles

Nous avons utilisé la cross-correlation entre les trente séries temporelles des graphlets et la série temporelle des interactions, sur la période de l'étude. Les graphlets identifiés comme signaux faibles présentent des corrélations positives à des décalages négatifs avec la série des

5.1 Validation au moyen d'une vérité de terrain

Graphlet	G_{25}	G_{14}	G_{27}	G_7	G_{11}
Forme					
Contribution Globale	0.0198	0.0246	0.0324	0.0360	0.0381

TABLE 5.6 – Top cinq des graphlets qualifiés de signaux faibles dans le snapshot de 8 heures.

interactions, mais le coefficient ρ n'est pas assez élevé pour confirmer la relation de corrélation. Par exemple dans le corrélogramme du graphlet G_7 signal faible, les coefficients à des décalages négatifs ne dépassent pas la valeur +0.4. Le corpus d'étude étant limité à 20 nœuds, les données sont peut-être insuffisantes pour appliquer une méthode statistique. Nous avons alors examiné les courbes des séries temporelles pour y trouver des « ressemblances ». En effet, une corrélation entre deux séries s'illustre par le fait que les deux courbes « se ressemblent », mais avec un décalage. La figure 5.12 montre la série temporelle des interactions (en vert), celle du graphlet G_7 signal faible (en rouge) et celle du graphlet G_{10} qui n'est pas identifié comme signal faible (en orange). La partie hachurée en bleu correspond au snapshot dans lequel nous avons détecté les signaux faibles (de 8 heures à 8 heures 30 minutes). Nous remarquons que la courbe de la série du G_7 « ressemble » à celle des interactions, avec un décalage négatif dans le temps. Au contraire, la courbe correspondant au G_{10} ne ressemble pas à celle des interactions.

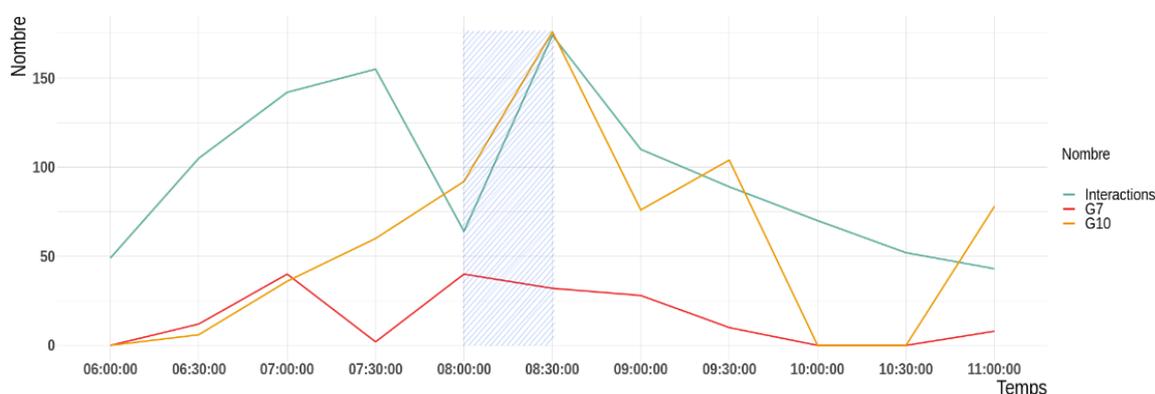


FIGURE 5.12 – Séries temporelles des interactions et de deux graphlets, sur quelques snapshots de l'étude.

Validation des signaux faibles identifiés par une vérité de terrain

Nous utilisons les observations enregistrées par un humain comme vérité de terrain pour valider les signaux faibles que nous avons détectés avec BEAM. Les observations comportementales ont été enregistrées cinq jours par semaine entre le 13 juin et le 10 juillet 2019 en utilisant la méthode d'échantillonnage focal [5], avec deux sessions d'environ deux heures par jour à des moments différents chaque jour, allant de 8 heures jusqu'à 17 heures. Au cours de chaque session, un observateur formé s'est concentré sur chaque individu pendant une période de 5 minutes et a enregistré son comportement. Il faut noter que lorsque l'observateur ne voit pas les babouins ou lorsqu'il s'agit d'un comportement non répertorié, aucune interaction n'est

enregistrée. Le fichier des données d'observation contient 5 377 interactions, et il est composé de sept colonnes détaillées ci-dessous :

DateTime : L'horodatage de l'interaction, c'est-à-dire le moment de l'enregistrement d'une action ;

Actor : Le nom du babouin ;

Recipient : Le nom du babouin sur lequel l'acteur agit ;

Behavior : Le comportement de l'acteur. Il existe 15 types de comportement différents, dont "Repos", "Jouer avec", "Grogner-mâcher", "Mendier", "Menacer", "Se soumettre", "Toucher", "Éviter", "Attaquer" ;

Catégorie : La classification des comportements. Un comportement peut être "affilié", "agonistique" ou "autre" ;

Durée : en secondes, du comportement observé, les contacts ponctuels n'ont pas de durée ;

Point : Indique si le contact est un évènement POINT (YES) ou un évènement STATUT (NO).

Nous nous sommes placés sur la même période que celle que nous avons étudiée pour détecter les signaux faibles dans l'ensemble de données issues des capteurs. Le tableau 5.7 montre un extrait des données observées par l'observateur le 19 juin 2019 entre 8 heures 58 minutes et 8 heures 59 minutes du matin, où nous avons remarqué un changement des comportements affiliatifs à des comportements agonistiques. Dès la troisième ligne de ce tableau, le comportement devient agonistique entre des individus qui interagissaient tranquillement une seconde avant (LOME et FELIPE), et à 9 heures 11 minutes, leur interaction redevient affiliative. Dans le même ensemble de données, nous avons remarqué que ces comportements agonistiques étaient suivis par des attaques entre VIOLETTE, MUSE, HARLEM et MALI à 9 heures 16 minutes.

DateTime	Actor	Recipient	Behavior	Category	Duration	POINT
19/06/2019 08 :58	LOME	FELIPE	Resting	Affiliative	17	NO
19/06/2019 08 :58	LOME	ANGELE	Resting	Affiliative	17	NO
19/06/2019 08 :59	FELIPE	LOME	Submission	Agonistic	0	YES
19/06/2019 08 :59	FELIPE	LOME	Threatening	Agonistic	0	YES
19/06/2019 08 :59	LOME	FELIPE	Chasing	Agonistic	11	NO
19/06/2019 08 :59	ANGELE	LOME	Attacking	Agonistic	0	YES
19/06/2019 08 :59	ANGELE	LOME	Submission	Agonistic	0	YES
19/06/2019 08 :59	LOME	FELIPE	Resting	Affiliative	37	NO
19/06/2019 08 :59	ANGELE	LOME	Attacking	Agonistic	0	YES
.....

TABLE 5.7 – Extrait du fichier de données des interactions entre babouins observées par un humain.

Notre objectif est de vérifier que les nœuds ou babouins appartenant aux instances de graphlets signaux faibles détectés entre 8 heures et 8 heures 30 minutes se retrouvent en position de soumission, de menace ou d'attaque dans les données d'observation à 9 heures. C'est pourquoi, nous avons interrogé, à l'aide de requêtes *Cypher*, une base de données graphes *Neo4j* contenant l'ensemble des données des capteurs. Nous avons intégré dans cette base l'ensemble des

5.1 Validation au moyen d'une vérité de terrain

interactions du snapshot étudié, correspondant à 52 liens entre 13 nœuds. Le listing 5.3 est un exemple de la requête Cypher qui sélectionne une instance du graphlet G_{27} , après avoir spécifié les attributs des nœuds appartenant à cette instance car plusieurs nœuds peuvent occuper la même orbite dans des instances différentes. Dans cette instance, ARIELLE occupe l'orbite centrale O_{69} , et les autres individus FELIPE, HARLEM, FANA et VIOLETTE occupent l'orbite périphérique O_{68} .

```
MATCH (u1) -- (u2) -- (u5) , (u2) -- (u3) -- (u5) , (u3) -- (u4) -- (u5) , (u4) -- (u1)
-- (u5)
WHERE NOT ((u1) -- (u3)) AND NOT ((u2) -- (u4))
AND u1.name = 'FANA' AND u2.name = 'VIOLETTE' AND u3.name = '
HARLEM'
AND u4.name = 'FELIPE' AND u5.name = 'ARIELLE'
RETURN *
```

Listing 5.3 – Requête Cypher sélectionnant une instance du graphlet G_{27} .

Les résultats des requêtes sur les graphlets signaux faibles détectés dans le graphe issu des capteurs montrent que la majorité des nœuds renvoyés correspondent aux babouins identifiés comme ceux ayant participé aux agressions rapportées par l'observateur humain une heure plus tard, c'est-à-dire vers 9 heures. La figure 5.13 montre un extrait de telles instances de graphlets identifiés comme signaux faibles (listés dans le tableau 5.6). Certains babouins se trouvent dans des positions centrales comme FELIPE en 5.13.b) ou en position périphérique comme ANGELE en 5.13.b).

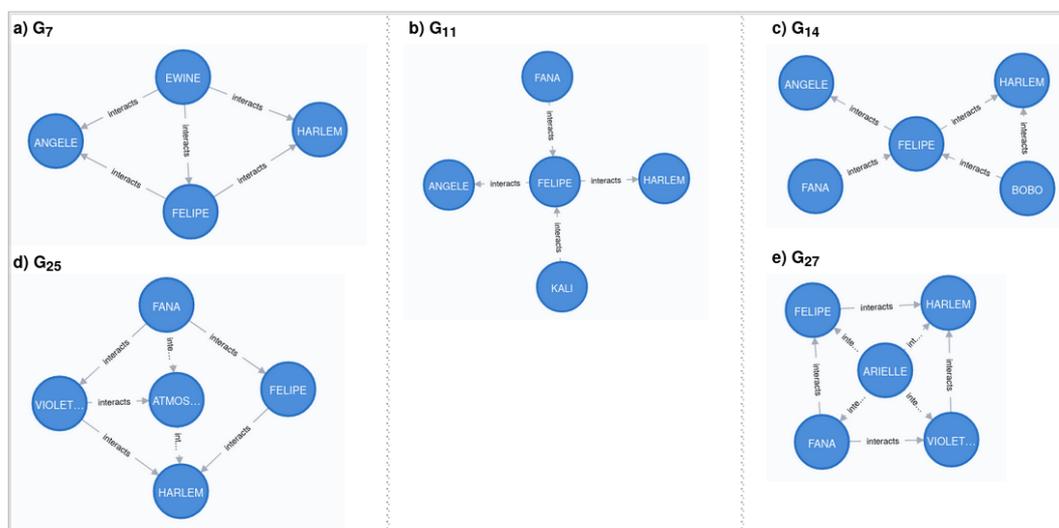


FIGURE 5.13 – Positions des nœuds dans des instances des cinq graphlets signaux faibles entre 8 heures et 8 heures 30.

Étude des communautés dans le graphe global issu des capteurs

L'objectif est de montrer que l'étude seule du graphe global des interactions ne permet pas de détecter un changement de comportement. Les communautés, détectées par l'algorithme de Louvain, sont illustrées dans la figure 5.14 et différenciées par des couleurs rouge et verte

comme le montre le tableau à gauche de la figure 5.14. La communauté en rouge est celle qui contient la plupart des individus du groupe. En effet, ceci est normal car les individus qui en font partie, notamment FELIPE, LOME et HARLEM, sont ceux qui ont le plus participé aux interactions qu’elles soient affliatives ou agonistiques. Nous avons également constaté qu’il existe des liens importants entre des individus appartenant à des communautés différentes, comme FELIPE et ANGELE, ou VIOLETTE et HARLEM par exemple. L’algorithme de détection de communauté n’est pas suffisant pour prévenir les attaques, puisque les attaques existent entre des babouins d’une même communauté, comme elles existent entre des babouins appartenant à deux communautés différentes.

<i>Detected louvain communities (baboons participating in attacks)</i>	
Baboon	Community
FELIPE	Red
LOME	Red
ANGELE	Green
VIOLETTE	Green
MUSE	Red
HARLEM	Red
MALI	Green

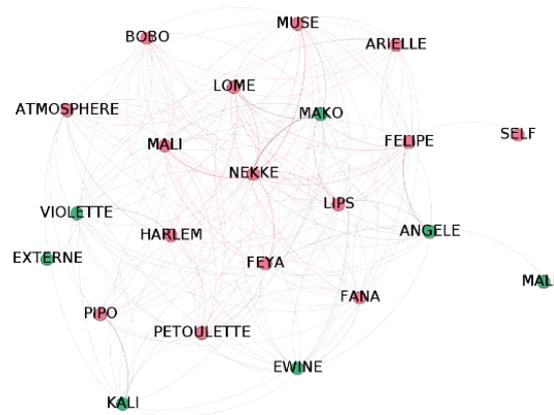


FIGURE 5.14 – Deux communautés obtenues dans le jeu de données issues des capteurs avec l’algorithme de Louvain.

Conclusion

Cette expérience a validé notre méthode BEAM par rapport à une vérité de terrain qui rapporte des comportements agressifs entre des individus. Nous avons détecté des graphlets signaux faibles environ une heure avant les attaques observées par un humain, et où les babouins participants aux attaques font partie des instances de graphlets signaux faibles.

5.2 Validation par contre-exemple

À travers les expériences suivantes, nous avons cherché à vérifier qu’aucun signal faible n’est trouvé lorsque les évènements sont prévus et/ou répétitifs ou lorsqu’il n’y a pas d’évènement.

5.2.1 Cas d’évènements prévus et répétitifs : école primaire

Nous avons analysé les interactions sociales entre des individus d’une école primaire, avec comme évènements, les pauses du midi et les récréations prévues à des moments connus. Les interactions ont lieu entre des élèves d’une école primaire à Lyon, en France, pendant deux jours consécutifs en octobre 2009. Les élèves âgés de 6 à 12 ans font partie du cycle élémentaire. Dans cette école, chacune des cinq années du cycle est divisée en deux classes, pour un total de dix classes. Chaque classe a une salle et un enseignant. La plus petite classe compte vingt-deux enfants et la plus grande vingt-six, pour un total de deux cent quarante-un

5.2 Validation par contre-exemple

enfants et dix enseignants. La journée scolaire se déroule de 8 heures 30 minutes à 17 heures 30 minutes, avec une pause déjeuner entre 12 heures et 14 heures, et deux pauses de 20-25 minutes vers 10 heures 30 minutes et 15 heures 30 minutes qui ont lieu dans une cour de récréation commune. Les élèves portent des badges RFID³, deux élèves sont considérés en interaction si ils sont séparés entre un mètre et un mètre cinquante l'un de l'autre pendant au moins vingt secondes.

Description du corpus d'étude

Les interactions dans l'école primaire ont été utilisées dans deux travaux qui ont proposé des modèles pour quantifier la possibilité de transmission des infections respiratoires et identifier les situations où le risque de transmission est plus élevé, dans les écoles [176, 68].

Le fichier des données que nous avons utilisé dans l'étude a été téléchargé depuis le site officiel *Sociopatterns*, <http://www.sociopatterns.org/datasets/primary-school-temporal-network-data/>. Il contient une liste d'interactions où chaque ligne est de la forme $(time_interval, id_i, id_j, class_i, class_j)$, où id_i et id_j sont les identifiants anonymes des élèves en interaction, $class_i$ et $class_j$ sont leurs classes respectives et $time_interval$ (en secondes) détermine l'intervalle pendant lequel l'interaction a eu lieu c'est-à-dire $[time_interval - 20s, time_interval]$. Si plusieurs interactions ont eu lieu durant le même intervalle alors plusieurs lignes commençant par la même valeur de $time_interval$ apparaîtront dans le fichier brut. Le tableau 5.8 montre un extrait du contenu de ce fichier.

time_interval	id_i	id_j	class_i	class_j
31220	1560	1570	3B	3B
31220	1567	1574	4B	4B
31220	1632	1818	1B	1B
31220	1632	1866	1B	1B

TABLE 5.8 – Extrait du fichier brut des données de l'école primaire.

Nous avons divisé le corpus en snapshots d'une durée de 10 minutes chacun, et choisi de travailler avec cinq snapshots correspondant aux moments précédant la pause déjeuner (de 11 heures 20 minutes à 12 heures) du premier jour d'école.

Détection des signaux faibles

Nous présentons notre analyse du snapshot de 11 heures 40 minutes où nous avons identifié quelques précurseurs. Ensuite, nous avons évalué les contributions de tous les graphlets. Les graphlets précurseurs, n'ayant pas de faibles ratios, n'ont pas été sélectionnés comme signaux faibles. En revanche, des graphlets non précurseurs présentant de faibles ratios ont été sélectionnés comme signaux faibles : G_4 , G_{11} , G_{14}  et G_{18} .

3. L'identification par radiofréquence (RFID) utilise des champs électromagnétiques pour identifier et suivre automatiquement les étiquettes fixées aux objets.

De fausses alertes

Pour confirmer ce résultat, nous avons exécuté la cross-correlation sur l'ensemble des données des interactions pour les deux jours d'école, c'est-à-dire une étude par jour. Avec les corrélogrammes obtenus, nous n'avons trouvé aucune corrélation significative de décalage négatif entre la série temporelle des interactions et celles des graphlets.

Ces résultats confirment que lorsque l'évènement est déjà planifié ou répétitif, il n'y a pas de signaux faibles annonciateurs d'un tel type d'évènement : **les graphlets étiquetés signaux faibles sont dans ce cas des fausses alertes.**

5.2.2 Cas où le contexte n'est pas connu : Facebook et MathOverflow

Nous avons appliqué notre méthode BEAM sur deux jeux de données où aucun évènement est connu.

Description des corpus d'étude

Facebook Il s'agit d'un réseau représentant des publications sur les murs d'utilisateurs de Facebook. Ce réseau contient 88 234 interactions entre 4 039 utilisateurs anonymes collectées entre octobre 2004 et janvier 2009. Il est disponible sur <http://snap.stanford.edu/data/ego-Facebook.html>. Ce jeu de données a fait l'objet d'une étude permettant d'identifier les cercles sociaux des utilisateurs sur Facebook [122].

Nous avons réduit la taille des données pour nous focaliser sur une période comprise entre le 5 et le 7 janvier 2009, le graphe est alors constitué de 6 677 liens entre 6 726 nœuds.

MathOverflow contient des interactions temporelles provenant du site Stack-Exchange MathOverflow qui sont de type : répondre à une question ; commenter la question d'un autre utilisateur ; commenter la réponse d'un autre utilisateur.

Notre jeu de données, disponible sur <http://snap.stanford.edu/data/sx-mathoverflow.html>, correspond à des données collectées sur une période de 2 350 jours entre septembre 2009 et mars 2016, soit 506 550 interactions entre 24 818 utilisateurs. Ce jeu a été utilisé en conjonction avec des données issues du site StackOverflow, où les auteurs ont proposé un algorithme d'énumération de motifs temporels [146].

Nous avons réduit la taille des données brutes à une période d'étude comprise entre le 27 et le 30 octobre 2010, le graphe correspondant à cette période contient 414 nœuds et 966 liens.

Détection des signaux faibles

Nous avons choisi de découper les deux corpus d'étude en des snapshots de durée égale à une heure. Ne connaissant pas d'évènement, nous avons observé l'activité des utilisateurs et nous présentons les résultats du snapshot précédent un grand nombre d'interactions qui nous a fait penser à un possible évènement.

Pour Facebook, dans le snapshot correspondant, nous avons identifié les graphlets G_3 $\bullet \rightarrow \bullet \rightarrow \bullet$ et G_9 $\bullet \rightarrow \bullet \rightarrow \bullet \rightarrow \bullet \rightarrow \bullet$ comme précurseurs, mais le calcul de leurs contributions nous a montré des ratios forts, la méthode BEAM a détecté aucun signal faible.

Pour MathOverflow, l'étude des précurseurs dans le snapshot précédant le pic d'interactions a

5.3 Étude de la reproduction de résultats avec des données périodiques

mis en évidence les graphlets G_3 , G_9  et G_{10} . Là aussi le calcul de leurs contributions nous a montré des ratios forts ne permettant pas de les qualifier de signaux faibles.

Confirmation de l'absence de signaux faibles

Pour ces deux réseaux, nous avons utilisé la cross-correlation sur la période d'étude. Dans les deux cas, aucun coefficient significatif avec des décalages négatifs entre les séries temporelles des graphlets et celle des interactions a été trouvé, ce qui confirme l'absence de signaux faibles.

Conclusion

Nous avons pu montrer à travers ces trois expériences que les faux positifs sont bien éliminés. Notre méthode ne détecte aucun signal faible lorsqu'aucun évènement existe ou lorsque le jeu de données est trop généraliste car un signal faible doit toujours être associé à un contexte.

5.3 Étude de la reproduction de résultats avec des données périodiques

Grâce au streaming à haute qualité, HBO⁴ a estimé que la dernière saison de la série télévisée *Game of Thrones* (GOT) a attiré en moyenne 44,2 millions de téléspectateurs par épisode. La dernière saison a entraîné de nombreux échanges en raison des changements de scénaristes et du raccourcissement de la saison, uniquement six épisodes diffusés une fois par semaine entre le 14 avril 2019 et le 19 mai 2019. Les épisodes ont été diffusés en direct à 21 heures, heure américaine, et les données collectées correspondent aux tweets publiés au même horodatage.

Le but de l'étude menée sur cet ensemble de données est de vérifier la capacité de la méthode BEAM à détecter des signaux faibles avant un évènement important et viral, et de confirmer la reproduction des résultats avec les six épisodes de GOT.

5.3.1 Description des données brutes et construction du corpus d'étude

L'ensemble des données brutes est composé des tweets publiés entre le 10 avril 2019 et le 25 mai 2019, soit avant et après le lancement de la saison finale. Les critères utilisés pour la collecte de ces données sont les hashtags `#gameofthrones`, `#got` et `#gots8` (pour huitième saison de la série), afin d'éliminer les tweets sans rapport avec la série. Le nombre de tweets collectés est égal à 46 481 705 émis par 8 194 319 utilisateurs, dont 12 387 340 sont des tweets originaux et 34 094 365 des retweets.

La diffusion de la saison finale de GOT ayant eu lieu entre le 14 avril et le 19 mai 2019, nous avons réduit le corpus global pour ne prendre en compte que les données comprises entre ces deux dates. Le corpus d'étude obtenu contient alors 9 975 124 tweets originaux et 27 388 263 retweets. Nous choisissons de travailler sur ce corpus avec la relation `retweet`, car elle exprime la propagation de l'information. La diffusion des épisodes ayant lieu vers 21 heures chaque semaine, pour chacun des épisodes, nous avons appliqué BEAM sur trente cinq snapshots entre midi et 20 heures, chaque snapshot ayant une durée de 10 minutes. Pour

4. *Home Box Office* est un réseau américain payant de télévision appartenant aux studios *WarnerMedia*.

justifier notre choix de cette durée, nous avons réalisé une expérimentation sur le corpus du premier épisode, en faisant varier la durée des snapshots entre 10, 15, 30, 40, 50 et 60 minutes. Les résultats de cette expérimentation sont décrits en annexe C. Nous avons choisi la durée de 10 minutes puisqu'elle permet de trouver le plus grand nombre de signaux faibles porteurs de l'information dans le volume de données du corpus d'étude.

Dans ce qui suit, nous présentons en détail les résultats pour les deux premiers épisodes en s'attachant plus particulièrement à l'étape d'interprétation, puis nous ferons une synthèse sur le reste des épisodes afin de montrer qu'il est possible de reproduire les résultats.

5.3.2 Étude du premier épisode

Le graphe global du premier épisode, diffusé le 14 avril 2019, contient 270 825 liens et 226 554 nœuds représentant le grand public, des médias, des journalistes, etc. La taille moyenne des graphes correspondant aux snapshots est de 7 963 liens et 8 174 nœuds.

Détection des signaux faibles

Comme nous avons détaillé l'étape de détection dans les expériences précédentes, nous donnons ici les graphlets signaux faibles obtenus sur le snapshot de 17 heures à 17 heures 10 minutes, sans entrer dans les détails. La figure 5.15 illustre la carte d'émergence des graphlets construite pour ce snapshot. Les seuils choisis ici pour sélectionner les précurseurs, et pour diviser la carte en quadrants, sont égaux respectivement à 0.02 pour les vitesses et à 0 pour les accélérations. Dans la figure, les précurseurs sont présents dans la zone hachurée en bleu. L'étape suivante consiste à vérifier la pertinence des précurseurs en éliminant les faux positifs, en conservant les vrais positifs et en ajoutant les faux négatifs.

Le calcul des contributions a sorti une liste de graphlets signaux faibles, nous montrons les top cinq avec leurs ratios dans le tableau 5.9.

Graphlet	G_{12}	G_6	G_9	G_{21}	G_{13}
Forme					
Contribution Globale	0.052	0.066	0.076	0.081	0.089

TABLE 5.9 – Top-5 graphlets détectés signaux faibles dans le snapshot de 17 heures - 17 heures 10 minutes.

Confirmation des graphlets signaux faibles

Nous avons observé les corrélogrammes dans les snapshots de cet épisode. Par exemple, le corrélogramme de G_2 , un graphlet précurseur, ne montre aucune corrélation positive, nous expliquons ce résultat par le fait que son nombre est négligeable par rapport à celui des retweets (par exemple au snapshot de 17 heures nous avons 7 202 retweets et 4 G_2). Nous supposons que ce graphlet est perdu dans la masse de retweets émis lors de cet épisode, ce qui met en évidence le fait d'un signal faible perdu dans le bruit.

5.3 Étude de la reproduction de résultats avec des données périodiques

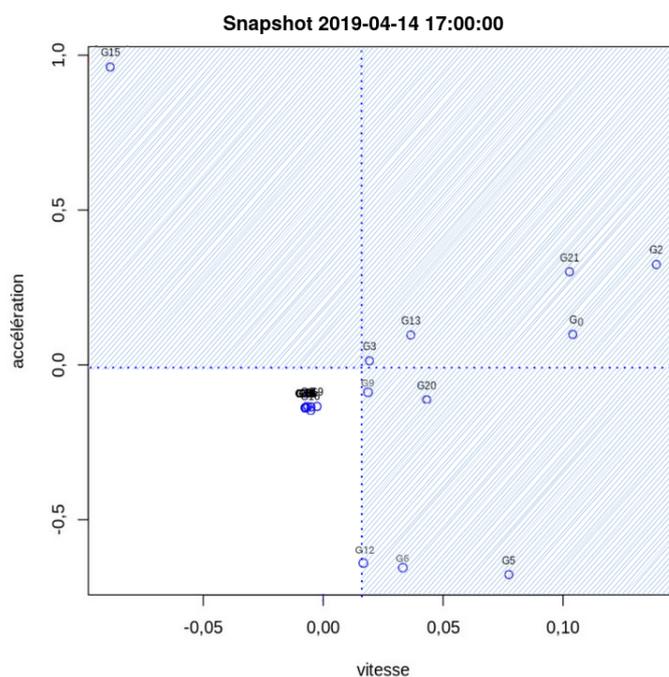


FIGURE 5.15 – Carte d’émergence des graphlets montrant les précurseurs sélectionnés dans le snapshot de 17 heures.

La cross-correlation dans ce jeu de données ne permet ni de confirmer ni d’infirmer les signaux faibles identifiés car les corrélations observées ont des coefficients positifs, mais, leurs valeurs comprises entre $+0.45$ et $+0.6$ sont peu élevées. En revanche, la série temporelle des retweets entre 16 heures et 19 heures montre une rupture à 17 heures 20 minutes, et BEAM a détecté des signaux faibles dans les snapshots précédents cet horaire.

Dans la partie a) de la figure 5.16 les séries temporelles des retweets en vert, et celle du graphlet G_{13} en rouge sont représentées entre 16 heures et 19 heures. Les deux courbes sont presque semblables en forme jusqu’à 17 heures. Mais à partir de cette heure, la courbe du G_{13} évolue, alors que celle des retweets reste stable. Dans la partie b) de la figure, le corrélogramme présente une corrélation positive d’une valeur $\rho = +0.63$ avec un décalage négatif $l = -1$.

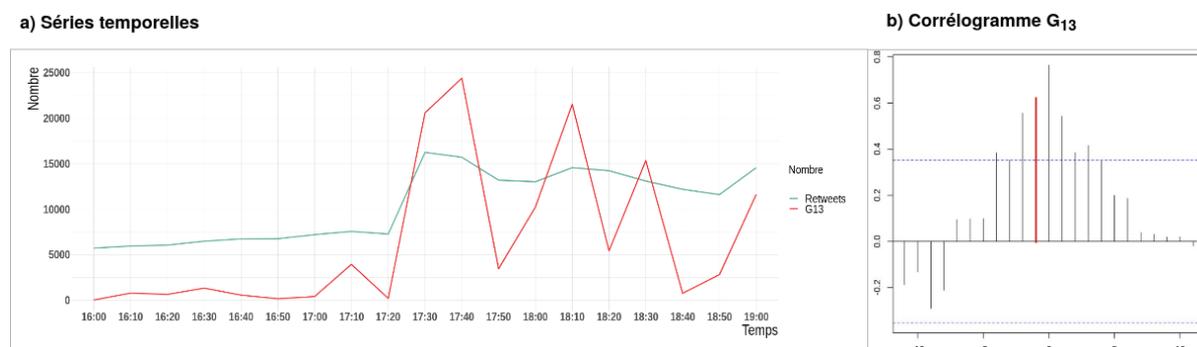


FIGURE 5.16 – Corrélation du graphlet G_{13} signal faible avec les retweets dans le premier épisode de GOT.

Interprétation des signaux faibles

Dans la suite, nous avons choisi de présenter notre analyse sur les nœuds appartenant aux orbites de certains graphlets signaux faibles.

Comptes utilisateurs dans le graphlet signal faible G_9 Le tableau 5.10 illustre un extrait des résultats obtenus.

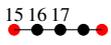
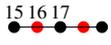
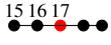
Graphlet-Orbit	Compte	Type du compte	PageRank
	@Got_Tyrion	Seigneur Tyrion Lannister (personnage)	16
O_{15}	 @FreeFolkMemes	Compte de mèmes	31
	@TheMasters	Compte officiel des championnats de Golf	9
O_{16}	 @jonatas_maia12	Designer de produits	61
	@9GAG	Plateforme en ligne, vidéos virales et drôles	31
	@GameofThrones	Compte officiel de GOT	1
O_{17}	 @Daenerys	Mère des dragons (personnage)	3
	@TylerIAM	Journaliste	4
	@skyatlantic	Compte officiel d'une chaîne de télévision	12

TABLE 5.10 – Extrait des nœuds importants appartenant aux orbites du graphlet G_9 , et leur classement PageRank pour le snapshot de 17 heures.

Les comptes @Got_Tyrion et @FreeFolkMemes apparaissent en position périphérique (O_{15}) de G_9 . Les autres comptes occupent les positions intermédiaire (O_{16}) et centrale (O_{17}). La troisième et la quatrième colonne du tableau représentent respectivement les types des nœuds (des comptes comiques, des plateformes en ligne, des personnages principaux de la série ou des journalistes), et leur rang après avoir exécuté l'algorithme PageRank sur 8 174 utilisateurs. Nous remarquons que les comptes officiels de la série ont un PageRank très important car ils sont beaucoup retweetés. Trouver le compte @Daenerys, en position centrale, n'est pas surprenant car le personnage *Daenerys Targaryen* joue un rôle de premier plan et est le plus populaire parmi les personnages de la série⁵. La présence de comptes comiques met en évidence les critiques émises sur cette saison, lui reprochant d'être trop courte avec une fin

5. Elle est l'un des derniers membres survivants, qui était toujours en conflit avec les autres personnages principaux. Une de ses citations, dans le dernier épisode de la saison 5, a été reprise par le fan club :

"Lannister, Targaryen, Baratheon, Stark, Tyrell ... Ils sont les rayons d'une roue. L'un domine, puis un autre, puis un autre encore. La roue tourne encore, écrasant ceux qui sont sur le sol. Je ne compte pas arrêter cette roue. Je vais la broyer." - Daenerys à Tyrion.

5.3 Étude de la reproduction de résultats avec des données périodiques

facile et un traitement des personnages non adapté, les spectateurs n'ont pas apprécié et ont créé des parodies.

Le compte @TheMasters a publié un tweet le 13 avril 2019, veille du dernier jour du tournoi des championnats de golf⁶ et de la diffusion du premier épisode. Ce tweet est devenu viral le lendemain car il a été retweeté par un grand nombre de fans de golf et de Game of Thrones. La victoire de Tiger Woods golfeur professionnel américain, ayant remporté ce tournoi avec un coup d'avance sur les trois finalistes, a provoqué l'enthousiasme des spectateurs qui dans leurs tweets mêlent le golf et la série Game of Thrones. La figure 5.17 illustre des tweets émis autour du snapshot de 17 heures par des fans de golf et de Game of Thrones, qui attendaient impatiemment à la fois que Tiger Woods joue et le début de la diffusion de la saison finale de GOT.

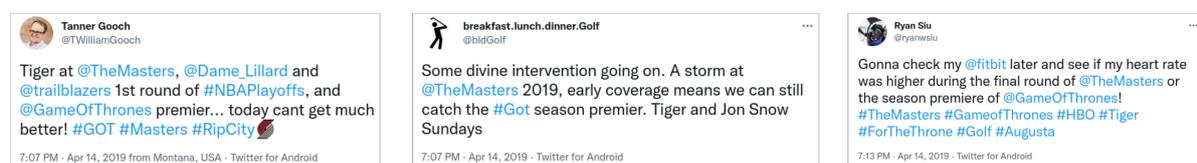


FIGURE 5.17 – Quelques tweets publiés le jour de la diffusion du premier épisode de GOT autour du snapshot de 17 heures par des fans de golf et de GOT.

Le compte @TylerIAM est Trill Withers, un journaliste qui était avant un commentateur sur une chaîne de sports, puis animateur d'émissions en direct sur sa chaîne YouTube, du lundi au vendredi de 12 heures à 15 heures. Il a publié un jour avant la diffusion du premier épisode un tweet, reproduit à gauche de la figure 5.18. Ce tweet souligne l'aspect comique sur deux personnages principaux et annonce des changements inattendus à venir.

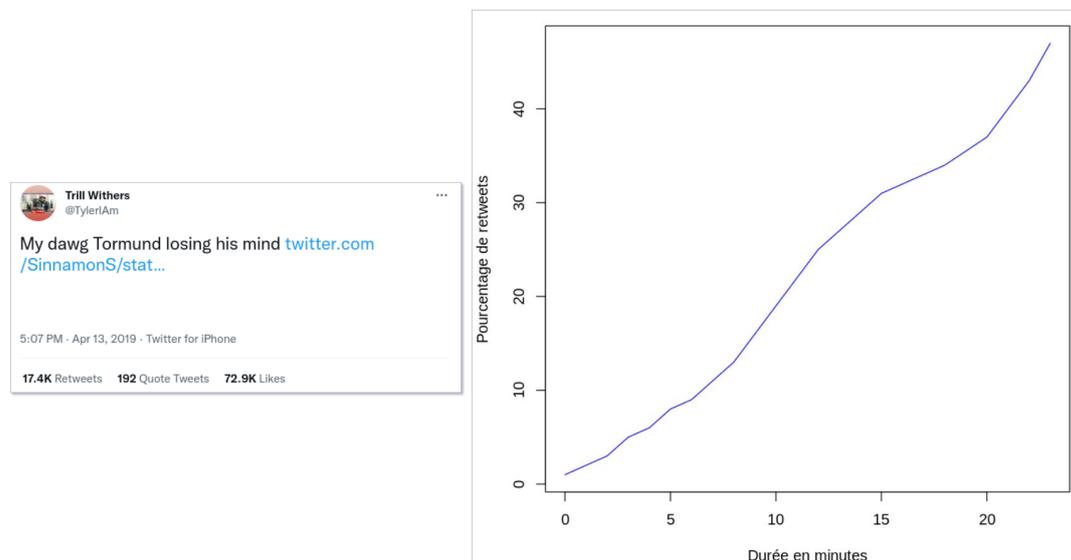


FIGURE 5.18 – Tweet de @TylerIAM et sa viralité.

Retweeté environ 17 000 fois, nous avons réalisé une expérimentation pour vérifier sa viralité. Pour cela, nous avons calculé la durée à partir de laquelle il atteint 10%, 20%, jusqu'à 100% de

6. https://fr.wikipedia.org/wiki/Masters_de_golf

ses retweets. La partie droite de la figure 5.18 illustre ce calcul, où 50% de retweets est atteint en environ 20 minutes et 24 heures après, il atteint 95%. Ces résultats mettent en évidence le rôle de Twitter dans la diffusion rapide d'information qui peut constituer une menace ou une opportunité.

Nous avons étudié ensuite les instances des graphlets signaux faibles à l'aide des requêtes *Cypher* sur la base *Neo4j*. Pour le snapshot étudié, cette base contient 7 109 liens entre 7 898 nœuds, une taille exigeant un temps de réponse important pour une sélection de toutes les interactions. Pourtant, le temps de réponse dans notre cas reste de quelques secondes puisque nous filtrons des nœuds particuliers dans les requêtes *Cypher*. La figure 5.19 représente plusieurs instances du graphlet signal faible G_9 , dans lesquelles nous trouvons @TylerIAM en position centrale, entouré de fans, de comptes de blogueurs ou de plateformes en ligne qui l'ont retweeté. Dans cette figure, nous avons sélectionné l'une des instances de G_9 (entourée en noir) pour étudier les relations entre les nœuds. Dans cette instance, nous remarquons que @Woodlawnwonder blogueur et @joestudz18 artiste et illustrateur de concepts, occupent la position intermédiaire dans G_9 , orbite O_{16} . La position périphérique (orbite O_{15}) est occupée par les comptes @holy_schnitt star des médias sociaux et @TheMasters déjà cité. Cette instance est intéressante puisqu'elle met en évidence l'activité de blogueurs ou de stars qui ont critiqué le script et la performance des acteurs. Ces comptes sont très suivis par les utilisateurs de Twitter et leur activité doit être « surveillée » par les analystes. Cette visualisation permet aussi de montrer des utilisateurs directement ou indirectement connectés dans des graphlets signaux faibles.

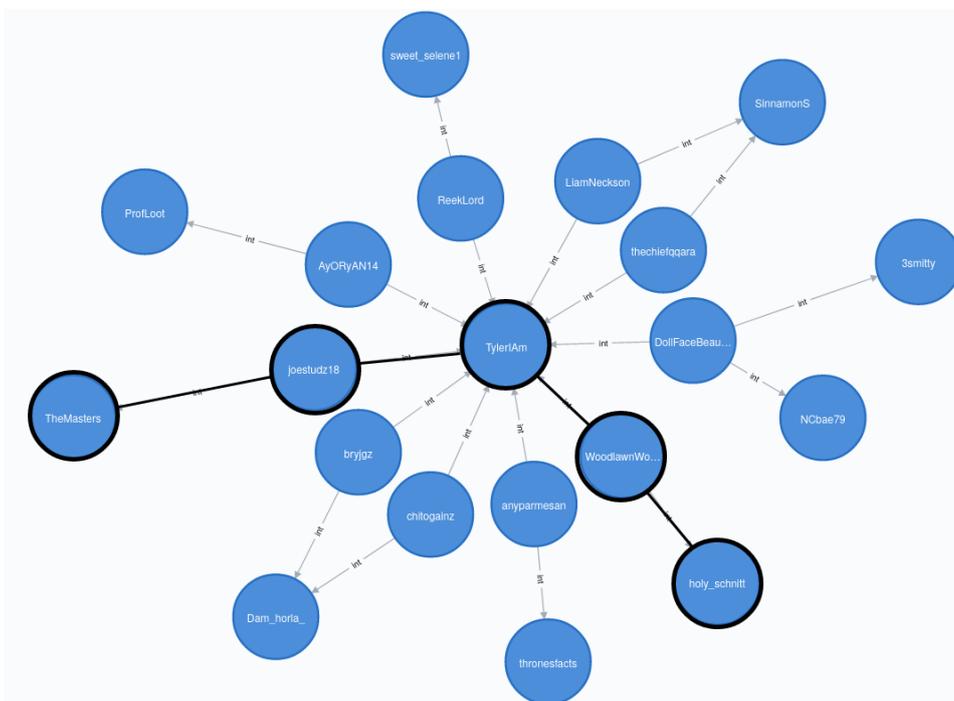


FIGURE 5.19 – Plusieurs instances du graphlet G_9 signal faible avec @TylerIAM, dans le snapshot de 17 heures.

5.3 Étude de la reproduction de résultats avec des données périodiques

Comptes utilisateurs dans le graphlet signal faible G_{13} Nous avons réitéré le même type d'analyse sur d'autres graphlets signaux faibles. Le paragraphe suivant montre les résultats obtenus sur le graphlet G_{13} . La figure 5.20 montre les nœuds et leurs liens entourés en noir représentant une instance de G_{13} dans le snapshot étudié. Dans cette instance, nous avons identifié des amateurs de films, de séries et de livres comiques. En regardant l'option de géolocalisation du profil de ces comptes sur Twitter, nous avons remarqué qu'ils se situent dans différents états du Brésil.

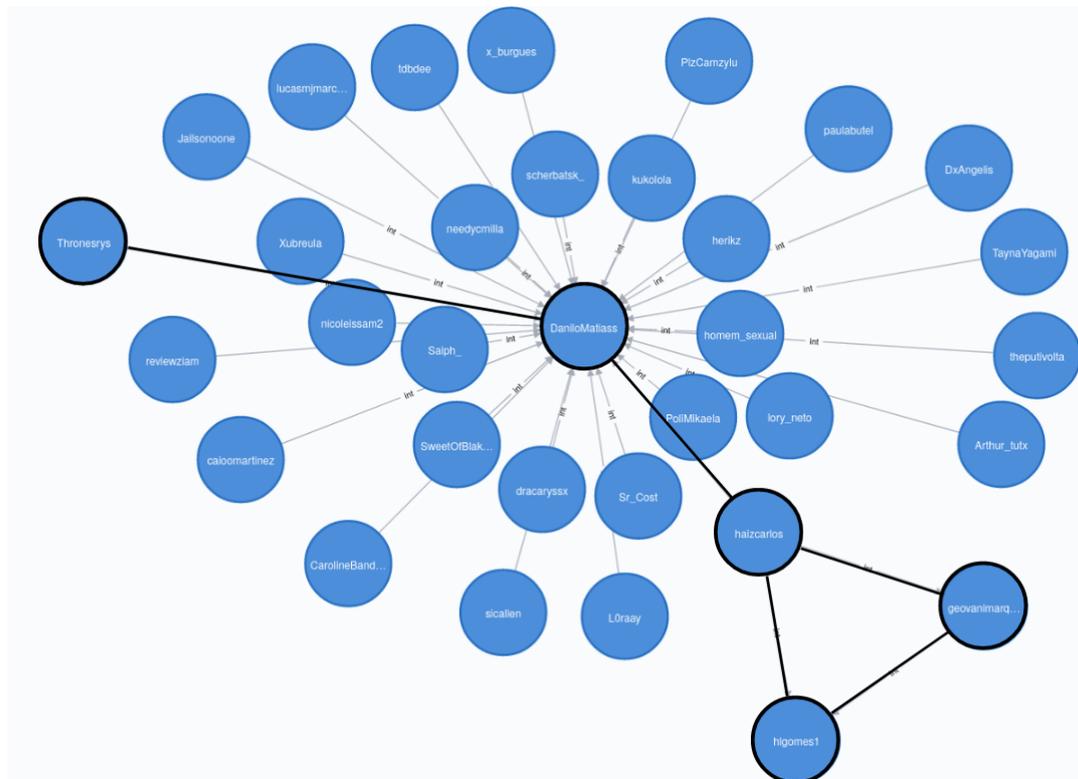


FIGURE 5.20 – Instances du graphlet G_{13} signal faible dans le snapshot de 17 heures.

Relations entre des utilisateurs porteurs de signaux faibles Nous avons utilisé la visualisation en radar pour étudier les relations entre des utilisateurs associés aux signaux faibles. La figure 5.21 montre trois radars mettant en évidence les relations, durant le snapshot de 17 heures, entre un utilisateur (nommé en haut de la visualisation) et d'autres utilisateurs apparaissant aussi dans les graphlets signaux faibles identifiés pour ce snapshot. Par exemple, le premier radar montre que @GameOfThrones apparaît dans cinq graphlets signaux faibles (nombre affiché en gris sur les extrémités du radar) avec @HBO_Brasil, @Daenerys et @skyatlantic, dans quatre graphlets avec @9GAG et @FreeFolkMemes, et finalement dans trois graphlets avec @TheMasters.

Résultats sur deux autres snapshots

Dans ce qui suit, nous présentons une synthèse des résultats obtenus sur deux autres snapshots : le snapshot de 15 heures loin de l'heure de diffusion de l'épisode et celui de 19 heures qui précède la diffusion de deux heures. L'objectif de cette analyse est de vérifier si les utilisateurs

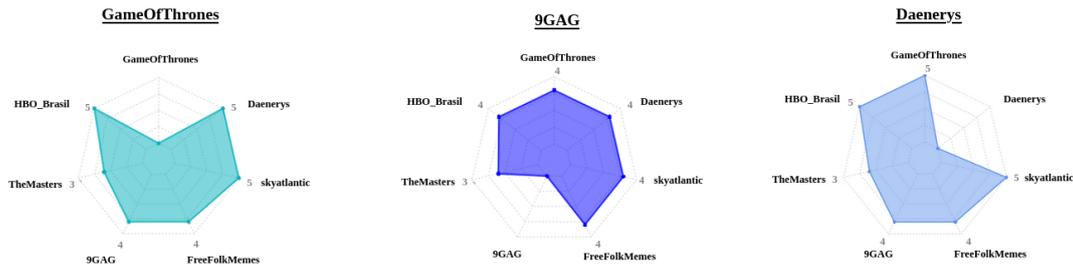


FIGURE 5.21 – Diagrammes en radar montrant quelques utilisateurs appartenant aux graphlets signaux faibles à 17 heures.

appartenant aux signaux faibles sont les mêmes et s'ils gardent le même rôle (position centrale, intermédiaire ou périphérique) ou non.

Nous avons appliqué BEAM sur ces deux snapshots, les top cinq graphlets signaux faibles sont listés dans le tableau 5.11, en rouge ceux qui sont communs aux deux snapshots. Nous remarquons aussi que les graphlets signaux faibles G_6 et G_{12} sont communs aux trois snapshots étudiés (voir tableau 5.9).

Snapshot	Graphlets signaux faibles				
15 heures	G_{19}	G_{20}	G_{24}	G_6	G_{12}
19 heures	G_{12}	G_{17}	G_6	G_{19}	G_{14}

TABLE 5.11 – Top cinq graphlets signaux faibles détectés dans deux autres snapshots du premier épisode.

Nous avons cherché si les utilisateurs apparaissant dans les instances des graphlets signaux faibles du snapshot de 17 heures, sont aussi dans les signaux faibles de 15 et de 19 heures. Nous n'avons pas identifié les mêmes utilisateurs dans le snapshot de 15 heures, ce que nous a confirmé l'étude des tweets qui montre qu'aucun de ces utilisateurs n'avaient d'activité remarquable vers 15 heures. En revanche, dans le snapshot de 19 heures, nous retrouvons des utilisateurs identifiés à 17 heures dans les mêmes orbites de graphlets signaux faibles, en figure 5.22.

En reprenant le compte @TylerIAm appartenant au graphlet G_9 de 17 heures (voir figure 5.19), nous constatons qu'il est encore dans la position centrale au snapshot de 19 heures. Dans l'instance mise en évidence (entourée en noir), nous trouvons deux comptes comiques – @Thrones_Memes et @SanchoYmoi comédien au Texas – mais aussi @farrahconsidine directrice commerciale chez *New Jersey Devils* une équipe professionnelle de Hockey et @JeffMillerTime responsable de la stratégie créative chez Snapchat. Cette instance contient à la fois des comptes pouvant produire un message d'humour ou de moquerie sur la série, tandis que les deux autres se servent certainement de la notoriété de la série pour faire leur propre publicité.

5.3 Étude de la reproduction de résultats avec des données périodiques

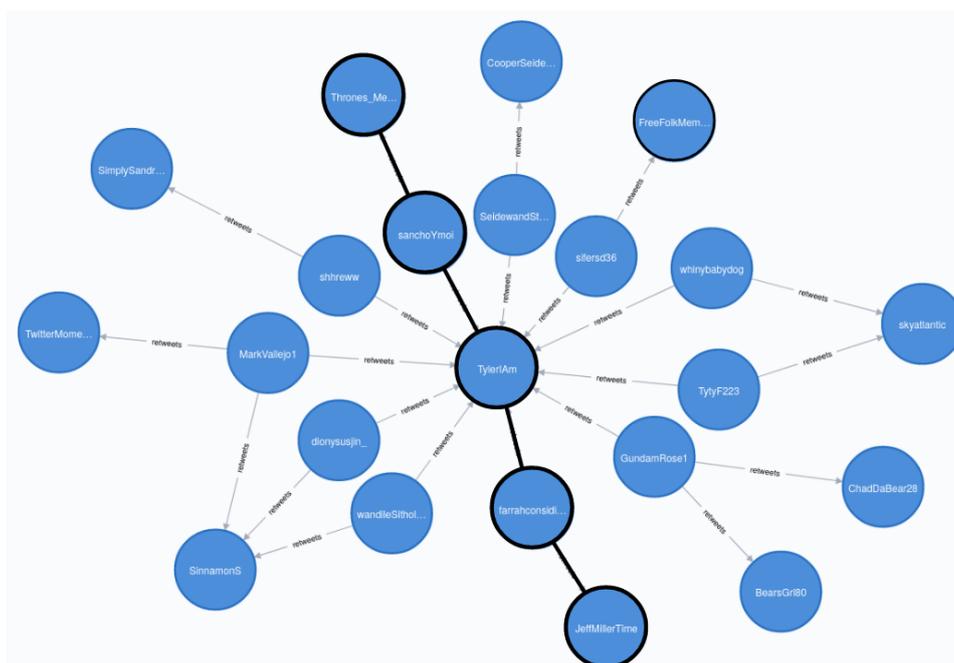


FIGURE 5.22 – Instances du graphlet G_9 dans le snapshot de 19 heures.

@JeffMillerTime a publié un tweet le 13 avril vers 22 heures 30 minutes soit un jour avant la diffusion du premier épisode. Ce tweet, présenté en figure 5.23, contient une vidéo dans laquelle nous trouvons *Times Square* à New York, ensuite un dragon qui apparaît dans le ciel et le bâtiment *Flatiron Building* est ensuite totalement recouvert de glace. Jeff Miller a profité de la viralité de GOT pour inciter les téléspectateurs à utiliser sa plateforme de réalité augmentée. Ce tweet a été retweeté 3 027 fois jusqu'à la fin de la dernière saison.



FIGURE 5.23 – Tweet de @JeffMillerTime.

Étude des communautés dans le graphe global du premier épisode

Nous avons aussi étudié les communautés sur le graphe global. L'algorithme Louvain a détecté 1 800 communautés dont la plus grande contient environ 9 000 nœuds. La figure 5.24 montre certains nœuds appartenant aux plus grandes communautés distinguées par des couleurs différentes.

La communauté jaune regroupe les comptes des personnages de la série GOT comme @Daenerys et @Got_Tyrion. La communauté verte représente des comptes des fans de la série localisés en Angleterre ainsi que @skyatlantic, la chaîne de télévision anglaise. La communauté rose comporte des comptes localisés au Nigeria, où l'un d'eux, @dreadstyn,

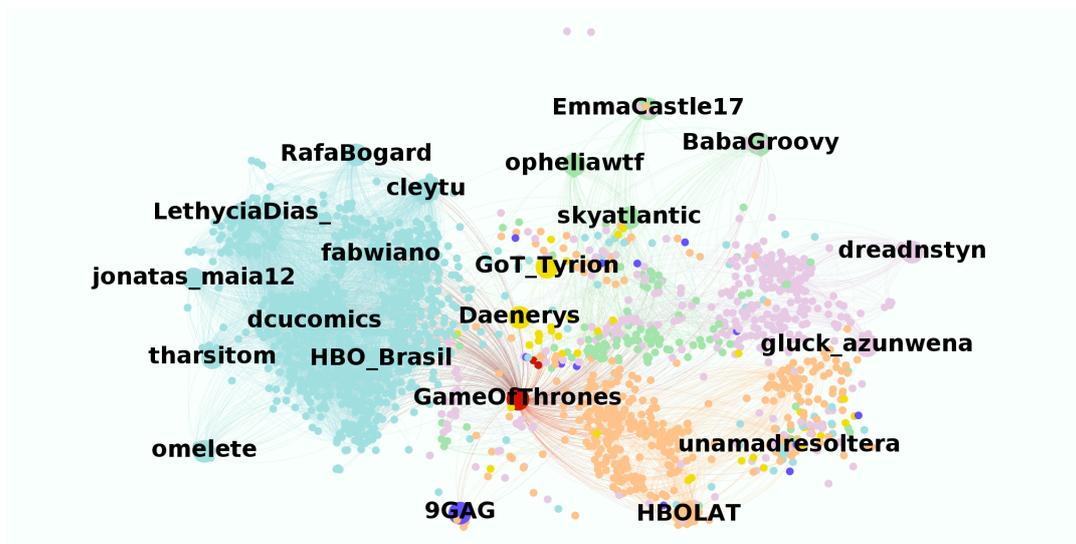


FIGURE 5.24 – Communautés les plus importantes obtenues avec l’algorithme Louvain.

publie et réagit sur des tweets amusants qui deviennent viraux. Parmi les nœuds appartenant à la communauté orange, nous trouvons le compte d’une blogueuse @unamadresoltera et le site officiel de HBO en Amérique latine. La plus grande communauté en bleu, contient des nœuds appartenant aux graphlets signaux faibles, notamment certains retrouvés dans le graphlet G_{13} à 17 heures en figure 5.20. Ces nœuds sont des comptes situés au Brésil, dont un comique et un créateur numérique @cleytu, un animateur @fabwiano, la version brésilienne de la chaîne HBO @HBO_Brasil, une journaliste @LethyciaDias_, le plus grand site de divertissement du Brésil qui diffuse des séries télévisées, des films et de la musique @omelete, @dcucomics le compte des fans de l’univers DC (univers fictif produit par Warner Bros), @tharsitom une méga fan de livres et de romans, etc. Nous remarquons ainsi que toutes les communautés sont reliées les unes aux autres par le biais de @GameofThrones qui est le compte officiel de GOT. Les communautés montrent que la localisation géographique des comptes est primordiale dans la communication, ce que les analystes doivent prendre en compte.

Conclusion

En conclusion, il apparaît que le compte officiel de GOT (@GameofThrones) et ceux des personnages principaux (@Got_Tyrion et @Daenerys) ont surtout communiqué pour inciter le public à regarder GOT : ils soulignaient le rôle crucial des personnages, mettaient en évidence les changements importants et inattendus dans la mise en scène. Nous considérons que les signaux faibles portés par ces comptes peuvent être des opportunités pour les producteurs de la série qui doivent surveiller que le discours est bien perçu et repris. En revanche, les comptes comiques comme par exemple @dcucomics et @9GAG, ou même @TylerIAm avec son tweet sarcastique qui est devenu viral en vingt minutes, peuvent être des menaces pour les producteurs car ils se moquent de GOT ou même détournent son image. Il est alors nécessaire pour les producteurs de surveiller l’activité de ces comptes pour essayer d’atténuer leur impact négatif sur le public. La plupart du temps, les comptes porteurs du signal faible ne sont pas en relation directe les uns avec les autres, comme l’étude des données brutes le

5.3 Étude de la reproduction de résultats avec des données périodiques

montre. En revanche, nous avons identifié les comptes porteurs de signaux faibles et leurs relations à travers l'étude des instances de graphlets signaux faibles.

5.3.3 Étude du deuxième épisode

Le deuxième épisode a été diffusé le 21 avril 2019 vers 21 heures, son graphe global contient 1 611 801 liens entre 729 526 nœuds. Le tableau 5.12 montre les graphlets signaux faibles identifiés dans les snapshots de 15, 17 et 19 heures qui sont aussi ceux étudiés pour le premier épisode. Nous remarquons que le snapshot de 15 heures ne révèle que deux graphlets jusqu'à quatre nœuds, cela peut être dû à une activité de retweet plus faible dans ce snapshot qui est le plus éloigné de l'heure de diffusion.

Snapshot	Graphlets signaux faibles
15 heures	G_4  G_1 
17 heures	G_4  G_6  G_{20}  G_{10}  G_5 
19 heures	G_4  G_{20}  G_{10}  G_5  G_1 

TABLE 5.12 – Signaux faibles détectés dans trois snapshots du deuxième épisode.

Nous remarquons que certains utilisateurs parmi ceux identifiés au premier épisode sont aussi présents dans les instances des graphlets signaux faibles du deuxième épisode, comme par exemple @fabwiano, @Thrones_Memes, @HBO_Brasil, @LordSnow occupant des positions centrales ou périphériques.

Dans le snapshot de 15 heures, nous observons la forte présence du compte @9GAG qui occupe la position centrale, orbite O_7 , du graphlet G_4 . @9GAG a posté un tweet, retweeté 3 000 fois avant 21 heures, pour se moquer d'une scène du premier épisode dans laquelle Jon Snow embrassait Daenerys et se retournait vers son Dragon en colère. De même, dans le snapshot de 17 heures, si nous retrouvons aussi des utilisateurs identifiés dans le premier épisode, nous avons identifié de nouveaux utilisateurs comme @Zack_Nani, un youtubeur et streamer français, dont les émissions varient entre les *Stories*, les vidéos et les concours de blagues, etc.

Un autre utilisateur important @LBaini, Lucas Baini est un journaliste partenaire de Twitch⁷. Cet utilisateur occupe une position centrale (orbite O_7 du graphlet G_4) car son tweet sur le personnage Jon Snow émis le matin du 21 avril a été reweeté de nombreuses fois. Dans ce tweet, reproduit en figure 5.25, @LBaini illustre la façon dont Jon



FIGURE 5.25 – Tweet viral de Lucas Baini

7. Créé en 2011 et racheté par Amazon en 2014, Twitch est un service de diffusion de vidéos en direct. Les spectateurs regardent gratuitement les vidéos et peuvent les commenter en temps réel par écrit, l'animateur de la chaîne voit les messages et peut y réagir.

Snow « ressuscite » après avoir appris la vérité sur ses parents à la fin du premier épisode⁸. Ce tweet se veut être un avant-goût des événements qui se produiront dans le deuxième épisode. Les utilisateurs liés à @LBaini, c'est-à-dire qui se trouvent à la périphérie du graphlet G_4 , sont localisés au Mexique et en Argentine qui est la même localisation indiquée sur le compte Twitter de @LBaini.

Au snapshot de 19 heures, nous avons remarqué la forte présence de @ohmytargaryen, méga-fan de GOT, ayant posté sur Twitter (figure 5.26) côte à côte des scènes de GOT et du film Shrek. Il compare la série avec le film en terme de costumes et décors pour montrer que GOT est une imitation du film Shrek. Son tweet a rapidement « décollé » avec plus de 47 000 retweets. Bien évidemment, ce compte a occupé des positions centrales dans les graphlets signaux faibles détectés dans ce snapshot. La figure 5.27 présente cet utilisateur se trouvant dans l'orbite O_8 du graphlet G_5 (partie a) et dans l'orbite centrale O_{21} du graphlet G_{10} (partie b). Dans cette instance de G_{10} , les comptes @GameOfThronesFR et @marvelftgot sont dans des positions périphériques (orbites O_{18} et O_{20} de G_{10}). @marvelftgot est un compte qui correspond au fait que certains acteurs de GOT ont joué des personnages de Marvel⁹.



FIGURE 5.26 – Tweet viral de @ohmytargaryen.

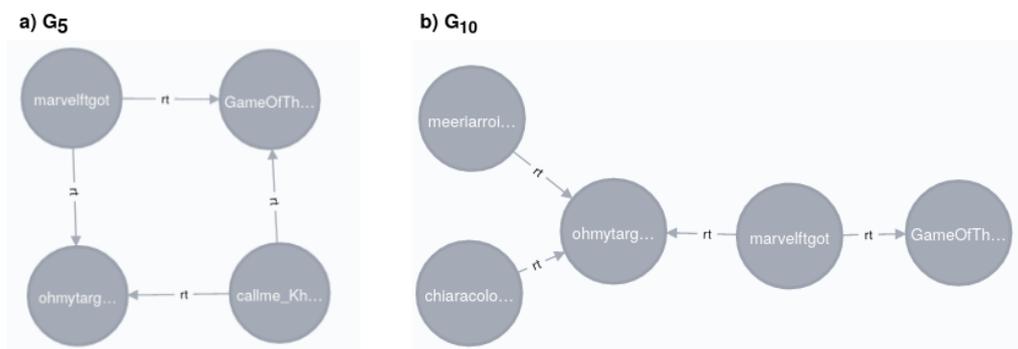


FIGURE 5.27 – Instances des graphlets signaux faibles G_5 et G_{10} détectés dans le snapshot de 19 heures du deuxième épisode.

Conclusion Les deux premiers épisodes de la dernière saison de Game of Thrones ont obtenu des taux d'audience élevés, c'est pourquoi nous avons concentré notre étude et notre

8. Une interview, dans la revue *Inverse*, avec l'acteur Kit Harington qui joue le personnage de Jon Snow, raconte comment Jon va réagir après avoir pris connaissance de la vérité, <https://www.inverse.com/article/55068-game-of-thrones-season-8-episode-2-spoilers-star-kit-harington-on-jon-snow-family>.

9. Marvel est une franchise américaine et un univers centré sur une série de films de super-héros produits par Marvel Studios.

5.3 Étude de la reproduction de résultats avec des données périodiques

analyse sur ces épisodes. À la fin du premier épisode, la vérité sur Jon Snow est révélée : il est le véritable héritier du Trône de Fer et son père biologique est le frère aîné de Daenerys, son amante. Avant que la vérité ne soit révélée à Jon, une scène montre un moment romantique entre ces personnages, sous le regard des dragons de Daenerys. Comme les spectateurs savaient que Jon est le neveu de Daenerys depuis la saison 7, ils ont détesté la scène heureuse de l'épisode 1 de la saison 8. Ils ont exprimé sur Twitter que cette vérité a ajouté un sous-entendu dégoûtant à la scène romantique. Après avoir appliqué BEAM sur différents snapshots de ces deux épisodes, nous avons pu retrouver dans les signaux faibles, les mêmes comptes qui ont réagit sur Twitter sur les évènements ci-dessus. Les résultats obtenus par BEAM correspondent à ces évènements puisque les comptes trouvés, comme @9GAG, @dcucomics, @Thrones_Memes, etc., les critiquent. D'autre part, le scénariste et le producteur de GOT ont essayé de défendre ces deux personnages après les réactions négatives des spectateurs. Dans une interview¹⁰, le scénariste a déclaré que le jeu des acteurs était bon alors que la scène était difficile à jouer.

5.3.4 Suivi de comptes porteurs de signaux faibles dans la huitième saison de GOT

Pour vérifier si les résultats se reproduisent, nous avons réalisé la même expérience sur les retweets publiés sur les quatre épisodes suivants de GOT. Pour éviter de répéter les étapes expérimentales décrites ci-dessus, nous avons choisi de décrire comment quelques comptes porteurs de signaux faibles identifiés dans les deux premiers épisodes évoluent au cours des six épisodes.

Le tableau 5.13 reprend quelques comptes et indique le nombre de fois où ils apparaissent dans les orbites des signaux faibles, épisode par épisode.

Utilisateur	Épisode 1	Épisode 2	Épisode 3	Épisode 4	Épisode 5	Épisode 6
9GAG	4497	0	48584856	923971	184262	0
Daenerys	879983	0	32778147	0	0	4
FreeFolkMemes	26880	240	8072963	0	0	0
GameOfThrones	3825049	0	0	1	25	0
HBO_Brasil	807081	277212	107278620	246	2158	0
LordSnow	0	22820	42253437	350213	0	8

TABLE 5.13 – Apparition d'utilisateurs dans les signaux faibles, épisode par épisode.

Pour aider les analystes dans leur interprétation des signaux faibles, nous pouvons aussi suivre ces comptes *via* une visualisation par diagramme de Sankey (figure 5.28) ou par diagramme en bâtons (figure 5.29). Dans ces deux visualisations, l'axe des abscisses représente les six épisodes et l'axe des ordonnées le nombre de fois où le compte apparaît dans les orbites, en légende les six comptes utilisateurs suivis.

L'utilisateur @GameOfThrones a émis 46 tweets (retweetés environ 139 000 fois) le jour du premier épisode, afin de dévoiler quelques évènements et inciter le grand public à être nombreux à réagir. Ensuite ce compte officiel disparaît, son rôle se limitait à assurer qu'un large public regarde cette dernière saison. @LordSnow n'apparaît pas dans les signaux faibles du

10. Article dans la revue *DigitalSpy* : <https://www.digitalspy.com/tv/ustv/a27222378/game-of-thrones-season-8-episode-2-writer-explains-jon-snow-reaction/>

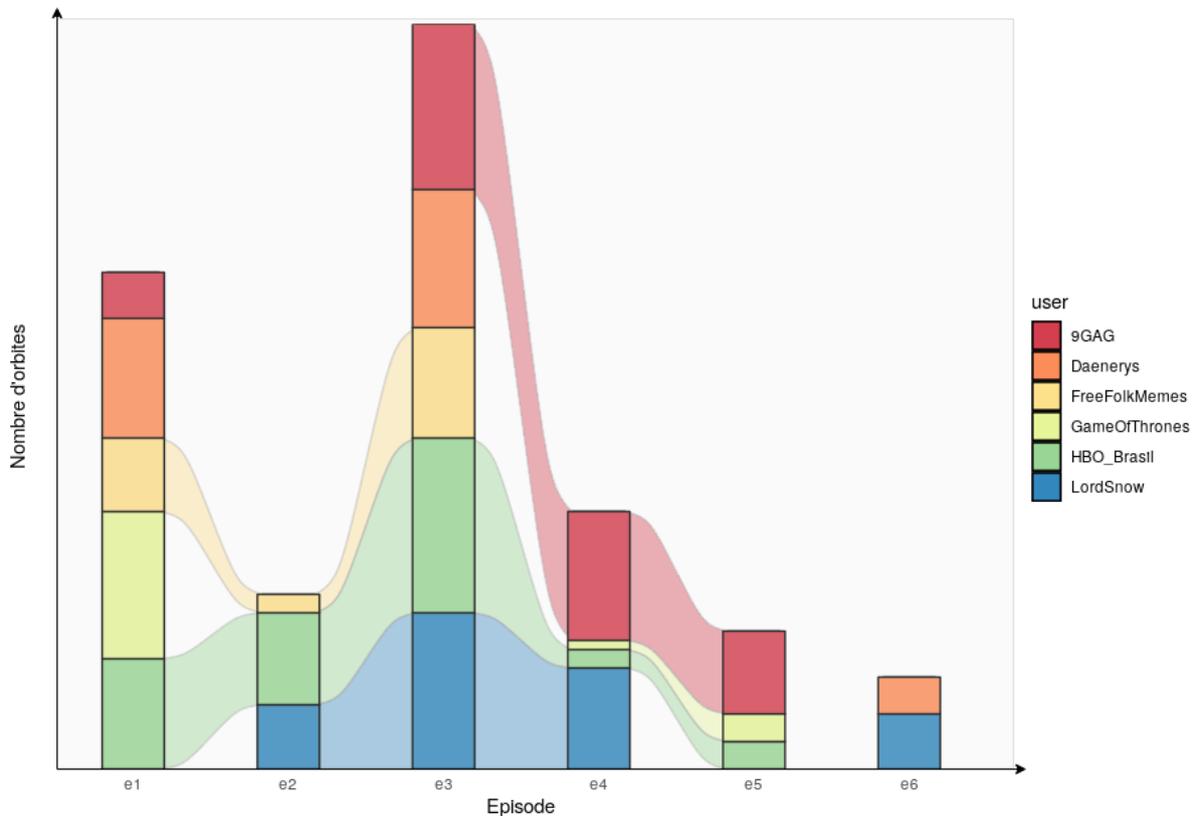


FIGURE 5.28 – Diagramme Sankey montrant l'évolution des utilisateurs participant aux signaux faibles, sur les six épisodes de GOT.

premier épisode mais à partir du deuxième épisode pour disparaître après le quatrième, nous supposons que cela pourrait être lié au fait que ce personnage n'apprend la vérité sur ses parents biologiques qu'à la dernière scène du premier épisode, ce qui a été considéré comme un évènement décisif pour les prochains épisodes. Dès le troisième épisode, nous remarquons la présence des comptes comiques @9GAG et @FreeFolkMemes qui réagissent de manière humoristique sur le comportement des personnages et la mise en scène des deux premiers épisodes, qui portaient un grand changement dans les évènements par rapport à la saison précédente. Dans le dernier épisode, nous remarquons la disparition d'une majorité des comptes, nous supposons que la saison a perdu de son intérêt.

Conclusion La huitième et dernière saison de la série Game of Thrones a eu un grand succès malgré les réactions mitigées et les critiques du public sur son final. Le troisième épisode, vu par 17,8 millions d'abonnés de la chaîne HBO (un record), est qualifié par de nombreux observateurs de moment majeur de l'histoire de la télévision¹¹. C'est aussi l'épisode pour lequel nous avons identifié le plus de signaux faibles. Ces résultats ont montré la capacité de BEAM à identifier, quelques heures avant la diffusion de chaque épisode, des utilisateurs récurrents (c'est-à-dire apparaissant dans plusieurs épisodes) comme porteurs de signaux faibles et à travers différentes visualisations permettre aux analystes leur interprétation.

11. https://www.lemonde.fr/idees/article/2019/05/03/game-of-thrones-un-succes-planetaire_5457798_3232.html

5.4 Étude de la sensibilité de la méthode

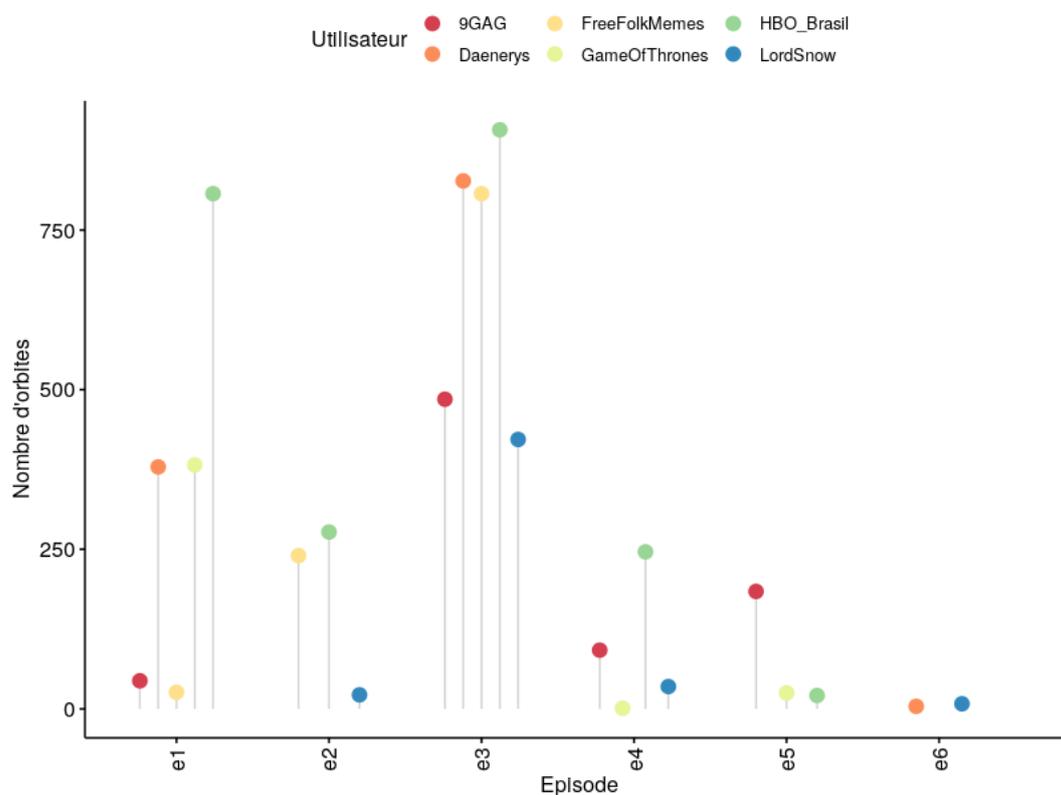


FIGURE 5.29 – Diagramme en bâtons pour montrer l'évolution des utilisateurs participant aux signaux faibles, sur les six épisodes de GOT.

5.4 Étude de la sensibilité de la méthode

Dans les expériences suivantes, nous reprenons certains des jeux de données précédemment étudiés mais pour lesquels nous faisons varier le graphe d'interaction : changement de la relation d'interaction ; changement à la fois de l'interaction mais aussi des types de nœuds lors de l'étude du rôle des hashtags dans les signaux faibles. Dans la suite, nous présentons deux expériences qui reprennent le corpus d'étude Lubrizol étudié en sous-section 5.1.1 : dans un premier temps, nous choisissons comme interaction le retweet (sous-section 5.4.1) puis, nous prenons comme espace de travail le graphe des co-occurrences de hashtags (sous-section 5.4.2). Finalement, nous terminons cette série d'expérimentations avec le jeu de données Game of Thrones et l'étude des hashtags en sous-section 5.4.3.

5.4.1 Visite surprise du Président Macron à l'usine Lubrizol : graphe des retweets

Nous avons réalisé la même expérience avec le graphe des retweets. Dans le snapshot de 16 heures 30 minutes, BEAM n'a renvoyé qu'un seul graphlet, G_3 , comme précurseur qui a été qualifié de signal faible. Si dans ce snapshot, il y a autant de retweets que de mentions, il y a trois fois plus de retweets que de mentions le jour de la visite¹² ce qui implique que les

12. 14 807 retweets pour 3 968 mentions le 30 octobre 2019.

vitesse et accélérations évoluent peu. Le retweet est porteur dans ce jeu de données d'un signal fort. Nous avons aussi étudié comme interactions les quotes¹³ et les réponses. Leurs nombres étaient trop faibles pour pouvoir construire des snapshots sur lesquels exécuter BEAM.

Conclusion Nous avons mis en évidence que le choix de l'interaction est primordial. Pour Twitter deux interactions dominent : le retweet et la mention. En fonction du contexte, il faut choisir l'interaction car le graphe sur lequel nous appliquons BEAM doit être représentatif du contexte d'étude. S'il s'agit de détecter des rumeurs ou « fake news » le retweet qui sert à propager l'information est à privilégier. Si les signaux faibles recherchés portent sur une marque ou une personne, l'interaction mention est un choix judicieux.

5.4.2 Visite surprise du Président Macron à l'usine Lubrizol : espace des hashtags

Les hashtags, commençant par le symbole #, sont un excellent moyen d'accroître la visibilité du contenu d'un tweet et donc de toucher davantage de personnes. En même temps, la construction d'un hashtag est importante : un hashtag doit être court, car si il est trop long, il devient incompréhensible et pour une suite de mots, des capitales au début de chaque mot sont utilisés.

Construction du corpus d'étude

Les top cinq des hashtags les plus utilisés dans les tweets le jour de la visite du président à Lubrizol sont : #rouen, #macron, #lubrizol, #giletsjaunes et #lubrizolrouen. Leur forte présence nous a amené à appliquer BEAM dans l'espace des hashtags sur le graphe de co-occurrence des hashtags (utilisation de hashtags dans un même tweet). La figure 5.30 illustre un exemple de ce type de graphes.

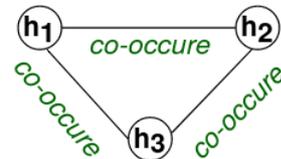


FIGURE 5.30 – Illustration d'un exemple de co-occurrence de hashtags.

Détection des signaux faibles

Le tableau 5.14 montre la taille du graphe global en nombre de nœuds et de liens, la taille des snapshots (nous avons choisi le snapshot de 16 heures 30 minutes à 17 heures), et la liste des signaux faibles obtenus. Nous trouvons ici les graphlets les moins complexes, cela est dû au faible nombre de nœuds et de liens dans le snapshot étudié.

Parmi les précurseurs, nous avons identifié le graphlet G_{29}  mais celui-ci contribue fortement dans l'évolution du nombre des graphlets. Pourtant, nous pensons que son étude pourrait enrichir l'étape d'interprétation de notre méthode.

13. Un retweet qui contient du texte ou des éléments supplémentaires au tweet d'origine est un quote-tweet, ils sont souvent utilisés pour parodier le tweet d'origine.

5.4 Étude de la sensibilité de la méthode

$ V _G$	$ E _G$	Snapshot	$ V _S$	$ E _S$	Graphlets signaux faibles
99	355	16 heures 30 → 17 heures	13	27	$G_1 \dashrightarrow G_2 \triangle$

TABLE 5.14 – Propriétés globales du graphe de co-occurrence des hashtags, avec la liste des signaux faibles identifiés par BEAM. $|V|_G$, $|E|_G$, $|V|_S$ et $|E|_S$ sont le nombre de nœuds et de liens respectivement dans le graphe global et le snapshot étudié.

Confirmation des signaux faibles

Nous avons appliqué la cross-correlation sur le graphe de co-occurrence des hashtags. Le tableau 5.15 détaille les résultats pour lesquels le coefficient ρ est le plus élevé pour un décalage de l négatif. Dans ce jeu de données, la cross-correlation confirme une majorité de signaux faibles. Nous remarquons que le graphlet G_{29}  présente des corrélations significatives avec un décalage de trente minutes. Ce graphlet n'est pas sélectionné comme signal faible car son ratio est fort. Ce résultat peut amener l'expert métier à étudier ses instances car il est une extension du graphlet G_2  qui est signal faible et ainsi enrichir son interprétation.

Graphlet	Signal Faible	Décalage l	Coefficient ρ à l
G2 	oui	-1	+0.66
G29 	non	-1	+0.7

TABLE 5.15 – Résultats de corrélation entre les séries temporelles de deux graphlets et celles des interactions correspondant aux co-occurrences des hashtags.

Interprétation des signaux faibles

Des hashtags appartenant aux graphlets signaux faibles, généraux comme #lubrizol, #lubrizolrouen, #normandie et #pollution n'apportent pas d'information sur l'évènement ciblé. En revanche, la présence des hashtags #macron, #rem et #lrem ciblant le Président Macron confirment que les hashtags identifiés sont des signaux faibles. Il est à remarquer que la présence du hashtag #giletjaunes met en avant des appels sur Twitter à manifester. Nous avons étudié la relation du hashtag #rem avec les autres hashtags et avec les utilisateurs. Ce hashtag est une abréviation du mouvement politique La république en marche lancé en avril 2016 par Emmanuel Macron. Il existe plusieurs dénominations de ce parti comme lrem, larem ou en marche. Ce hashtag a été utilisé le jour de la visite par le compte @Iceman76000 qui est actuellement suspendu, mais qui serait une personne habitant à Rouen (76 000 est le code postal de la commune de Rouen). Dans le snapshot que nous avons étudié, ce compte a émis un tweet qui montre son opposition à la visite du président plus d'un mois après l'incendie :

```
"@paris_normandie @EmmanuelMacron Il vient 1 mois après la bataille ! Quelle réactivité #macron #rem #lrem @enmarchefr #rouen #lubrizol #lubrizolrouen"
```

Parmi les utilisateurs occupant les orbites des graphlets signaux faibles retrouvés par BEAM en section 5.1.1, nous avons trouvé des journalistes comme @GuillaumeDaret, @jbbancaut et @PierreDesaint directeur de la radio france bleu Normandie. Plusieurs hashtags relatifs à l'incendie ont été associés au hashtag #rem, ce qui nous a conduit à étudier ses co-

occurrences. Le tableau 5.16 montre trois de ses co-occurrences avec leur fréquence d'apparition dans les tweets du snapshot.

Hashtag 1	Hashtag 2	Hashtag 3	Hashtag 4	Fréquence
rem	macron	lubrizol	lrem	36
	macron	lubrizolrouen	lrem	27
	macron	lubrizolrouen	lubrizol	27
	lubrizolrouen	lubrizol	lrem	27

TABLE 5.16 – Trois co-occurrences du hashtag #rem dans le graphe hashtag-hashtag.

Pour répondre à la question « *Qui a utilisé quoi ?* », nous nous sommes intéressés à la sémantique, notamment en étudiant plus précisément les instances de graphlets avec l'exécution de requêtes Cypher sur la base de données graphes *Neo4j*, et l'activité de certains comptes sur Twitter. La figure 5.31 illustre l'association des hashtags cités ci-dessus dans plusieurs instances du graphlet G_2 signal faible.

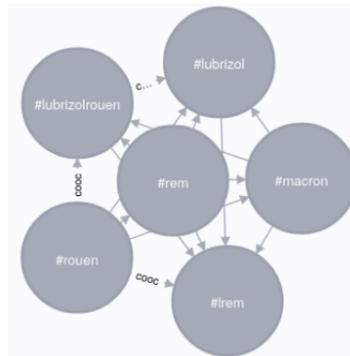


FIGURE 5.31 – Instances de G_2 graphlet signal faible avec le hashtag #rem et ses co-occurents.

Nous avons aussi remarqué la présence d'@AlexandreQuiec, responsable de média et de communication du mouvement La république en marche. Celui-ci a été un soutien au Président en retweetant les tweets émis par le compte officiel d'Emmanuel Macron. La figure 5.32 représente une mise en récit (*storytelling*) sur quelques tweets et retweets émis par @AlexandreQuiec durant et après la visite, et qui mettent en évidence son accord avec le mouvement présidentiel. Le tweet à gauche de la figure montre l'émotion du Président, celui du milieu présente la promesse du Président d'indemniser les habitants, et celui de droite annonce un évènement international à Rouen l'an prochain, pour redorer l'image de la ville après cet incendie.

Conclusion

L'étude de ce jeu de données a mis en évidence des hashtags généraux qui sont en relation avec l'évènement étudié, mais qui ne le ciblent pas directement. Ils ne sont pas suffisants comme signaux faibles caractérisant l'évènement étudié. C'est pour cela que nous avons réalisé une étude sémantique supplémentaire en consultant les tweets émis le jour de la visite du Président. Cette étude a montré que ces hashtags ont été utilisés dans les tweets émis le jour de la visite par des utilisateurs apparaissant dans les signaux faibles. Finalement, l'étude de l'espace des

5.4 Étude de la sensibilité de la méthode



FIGURE 5.32 – Mise en récit par @AlexandreQuiec de la visite présidentielle à Lubrizol.

hashtags confirme que la relation entre des comptes utilisateurs est plus significative par rapport à un évènement ciblé, car nous retrouvons les mêmes utilisateurs dans les signaux faibles avec beaucoup de hashtags qui concernent le mouvement politique du président.

Dans ce qui suit, nous allons décrire les étapes expérimentales réalisées pour l'étude de l'espace des hashtags en utilisant le jeu de données de la série Game of Thrones.

5.4.3 Game of Thrones : espace des hashtags dans le premier épisode

Les producteurs de Game Of Thrones se sont associés à Twitter pour sortir des hashtags et des emoji pour vingt personnages principaux. La figure 5.33 présente un extrait de ces hashtags et de leurs emoji partagés par @TwitterTV¹⁴.

Détection des signaux faibles

Nous avons étudié les signaux faibles pour le graphe des co-occurrences des hashtags sur le snapshot de 17 heures à 17 heures 10 minutes du premier épisode. Nous avons identifié vingt-cinq précurseurs et les top cinq graphlets signaux faibles sont présentés dans le tableau 5.17 où les caractéristiques du graphe global et celui du snapshot étudié sont aussi présentées.

$ V _G$	$ E _G$	$ V _S$	$ E _S$	Graphlets signaux faibles
503	2353	159	661	G_{19}  G_{27}  G_8  G_2  G_{12} 

TABLE 5.17 – Graphlets signaux faibles identifiés dans le snapshot de 17 heures à 17 heures 10 minutes.

Nous avons remarqué la présence de graphlets complexes (fermés) dans la liste des signaux identifiés. L'utilisation de plusieurs hashtags dans un même tweet peut expliquer la présence de tels graphlets dans la liste de signaux faibles.

14. Article publié sur *Independent.ie*, site d'information en Irlande : <https://www.independent.ie/style/celebrity/celebrity-news/game-of-thrones-and-twitter-team-up-ahead-of-eighth-and-final-season-37866130.html>

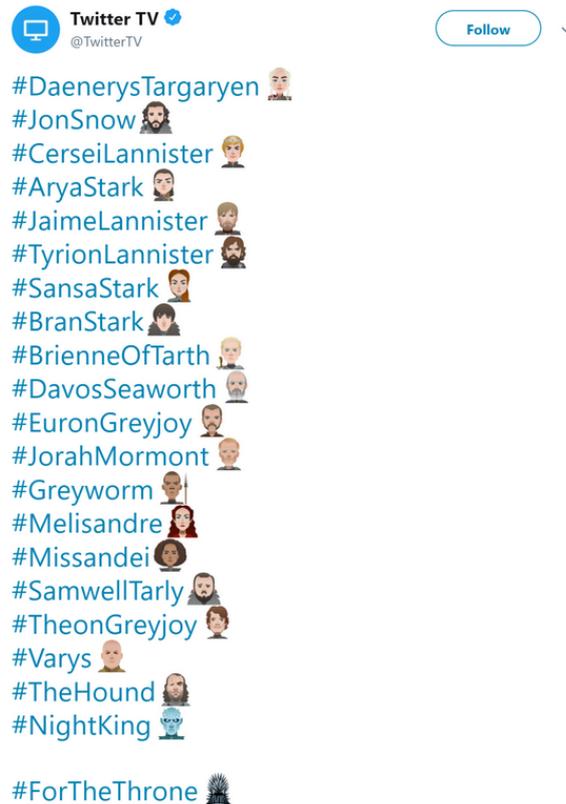


FIGURE 5.33 – Hashtags et emoji de Game of Thrones.

Confirmation des signaux faibles

Nous avons utilisé la cross-correlation pour étudier la relation entre les séries temporelles des graphlets et celle des co-occurrences des hashtags, sur la période du premier épisode. L'étude des corrélogrammes ne peut ni confirmer ni rejeter la présence des signaux faibles dans cet ensemble. D'un côté, les corrélogrammes des graphlets signaux faibles ne présentent pas de corrélations positives significatives à des décalages négatifs. Et si c'est le cas, leurs valeurs comprises entre +0.4 et +0.6 sont peu élevées. Cela est dû à la différence importante entre le nombre des co-occurrences et celui des graphlets : certains ont un nombre très élevé comme G_{12} et G_{19} , d'autres comme G_{27} sont négligeables par rapport à la série initiale. D'un autre côté, l'étude des séries temporelles nous a montré des similarités dans les courbes. La figure 5.34 représente la série des co-occurrences des hashtags en vert, et celles du G_2 et du G_8 en violet et en orange respectivement.

Cette étude montre que l'utilisation d'une méthode statistique n'est pas toujours suffisante pour la confirmation de signaux faibles, et ses résultats dépendent surtout du type des données étudiées.

Interprétation des signaux faibles

Nous avons détecté des hashtags correspondant aux personnages principaux, et surtout le hashtag #GameofThrones qui a été le hashtag le plus fréquemment utilisé d'après *Headline Pla-*

5.4 Étude de la sensibilité de la méthode

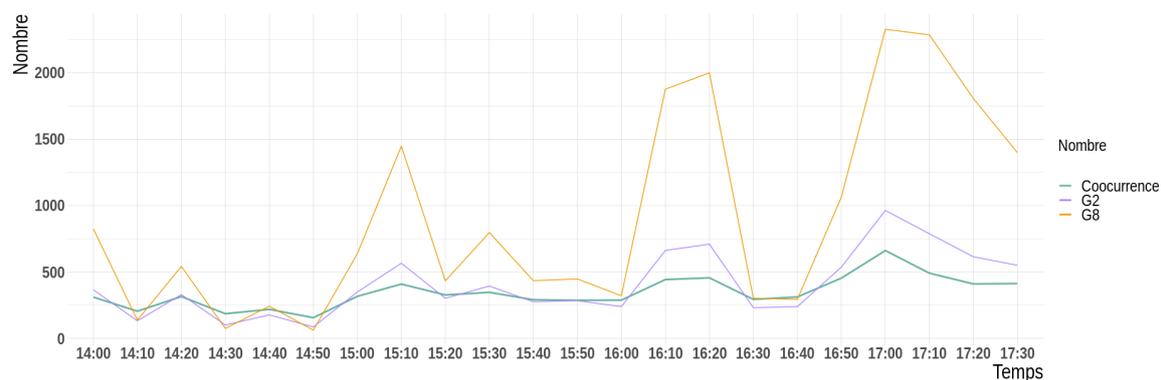


FIGURE 5.34 – Séries temporelles des co-occurrences des hashtags, et celles de deux graphlets signaux faibles, pour quelques snapshots du premier épisode de GOT.

net¹⁵. Nous avons aussi trouvé des hashtags mal orthographiés comme #GameofThornes ou #GameofThones. Le tableau 5.18 montre trois co-occurents de #GameofThrones avec la fréquence de leur apparition ensemble dans un même tweet durant le snapshot de 17 heures. Dans ce tableau, #filu2019 correspond à un hashtag utilisé par une organisation d'éducation nationale au Mexique, avec #facebookdown et #domingoderamos qui signifie le dimanche des rameaux qui avait lieu le 14 avril 2019. La quatrième ligne de ce tableau regroupe des hashtags sur les personnages principaux de la série, et la dernière exprime le compte à rebours pour le premier épisode (#conteregresivo), avec un jeu sur les mots domingo (qui signifie le dimanche en espagnol) et got (#domingot).

Hashtag1	Hashtag2	Hashtag3	Hashtag4	Fréquence
GameofThrones	filu2019	facebookdown	domingoderamos	81
	facebookdown	domingoderamos	14deabril	81
	domingoderamos	clasicojoven	14deabril	81
	daenerystargaryen	cerseilannister	aryastark	3
	forthethrone	domingot	conteregresivo	15

TABLE 5.18 – Liste des top trois co-occurents de #GameofThrones avec leur fréquence d'apparition.

Nous présentons dans le tableau 5.19 quelques hashtags importants trouvés dans les graphlets signaux faibles G_{12} et G_{19} avec leur fréquence d'apparition. Nous remarquons que les hashtags #GameofThrones et #jonsnow occupent des positions centrales ou intermédiaires, avec l'orbite O_{26} du graphlet G_{12} , et #gots8 occupe une position périphérique dans l'orbite O_{25} du même graphlet.

Nous avons effectué une analyse plus fine sur les instances de ces deux graphlets, à l'aide de requêtes *Cypher* sur la base de données *Neo4j*. Cette base alimentée par les données du snapshot étudié consiste sur 661 liens entre 159 nœuds. La figure 5.35 montre dans la partie gauche une instance de G_{12} dans laquelle #jonsnow, #winterishere¹⁶ et #forthethrone

15. Article paru dans le journal *Headline Planet* : <https://headlineplanet.com/home/2019/04/15/game-of-thrones-has-9-biggest-twitter-trends-following-season-8-premiere/>

16. En anglais cette expression correspond à « white raven » qui signifie le corbeau blanc. Elle indique le début

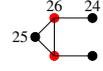
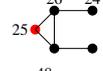
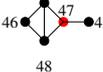
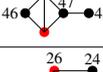
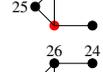
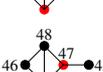
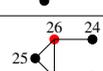
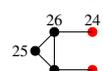
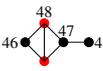
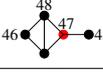
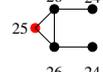
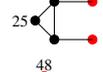
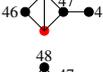
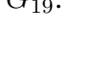
Hashtag	Détails	Graphlet	Orbite	Forme	Fréquence
GameofThrones	Hashtag officiel de la série	G12	O26		79 772
			O25		358
		G19	O47		8552
			O48		2303
jonsnow	Personnage principal	G12	O26		12 159
			O25		2 468
		G19	O48		4 200
			O47		709
winterishere	Le début d'une nouvelle saison de GOT	G12	O26		6 707
			O24		175
		G19	O48		1 715
			O47		1 192
gots8	Saison 8 de la série GOT	G12	O25		4 302
			O24		286
		G19	O48		206
			O46		151

 TABLE 5.19 – Hashtags occupant des orbites de G_{12} et G_{19} .

forment un triangle (orbites O_{25} et O_{26} respectivement), et à la périphérie apparaissent les hashtags #domingot et #chicago (orbite O_{24}). La partie droite de cette figure montre une instance du graphlet G_{19} composée presque des mêmes hashtags trouvés dans G_{12} , auxquels s'ajoute #darenerystargaryen (personnage principal) dans l'orbite O_{48} , et #gameofthronesseason8 dans l'orbite O_{47} .

D'autres hashtags, en lien avec des événements qui ont eu lieu le même jour de la diffusion du premier épisode, ont été utilisés également dans plusieurs tweets. Les hashtags #Facebookdown et #Instagramdown, sans rapport direct avec la série, sont apparus le 14 avril 2019, car de nombreux utilisateurs dans le monde et plus particulièrement en Europe se plaignaient

d'une nouvelle saison de GOT.

5.4 Étude de la sensibilité de la méthode

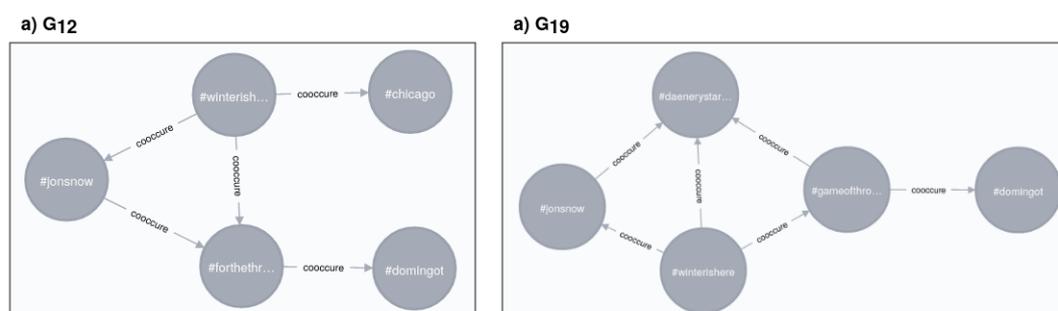


FIGURE 5.35 – Deux instances des graphlets signaux faibles G_{12} et G_{19} .

de difficultés à se connecter sur les applications des réseaux sociaux Facebook, Instagram et Whatsapp, depuis la mi-journée jusqu'à environ 15 heures. Cette utilisation conjointe permet de bénéficier de la popularité de Game of Thrones pour donner de la visibilité au tweet. Par exemple, nous avons trouvé le hashtag #augmentedreality utilisé pour annoncer la première lentille de réalité augmentée de Snapchat affichant un dragon de glace le long d'un bâtiment à New York (voir le compte @JeffMillerTime porteur de signal faible et la figure 5.23).

Le hashtag #epicsundays a été utilisé par @TheMasters (compte identifié comme signal faible en section 5.3) pour annoncer la finale du tournoi de Golf le dimanche 14 avril, jour de diffusion du premier épisode. Avec humour, @TheMasters remarque que même si le tournoi est important, beaucoup de personnes regarderont GOT. Ce hashtag a été utilisé ensuite par tous les amateurs de GOT et de golf, comme le tweet de la figure 5.36 où l'utilisateur utilise des émojis pour symboliser les deux événements avec leur heure.



FIGURE 5.36 – Tweet citant GOT et le tournoi de Golf.

Pour vérifier l'appartenance des hashtags identifiés dans les tweets des utilisateurs participant aux signaux faibles de la relation retweet décrite en section 5.3, nous avons interrogé la base de données relationnelle en indiquant la liste des hashtags et des comptes recherchés dans les tweets de 17 heures. Parmi la liste des comptes, nous sélectionnons @GameofThrones, @TylerIAM, @skyatlantic, etc. Le schéma 5.37 illustre la présence des hashtags cités ci-dessus dans les comptes d'utilisateurs identifiés dans les signaux faibles. Nous avons remarqué que la plupart des comptes utilisent le hashtag #GameofThrones, et que le hashtag #jonsnow n'a été utilisé dans aucun tweet original de ces comptes.

Conclusion

Cette étude nous a permis de vérifier notre hypothèse que les hashtags identifiés dans cette partie, sont utilisés dans les tweets émis par les comptes appartenant aux orbites des signaux faibles détectés dans la relation retweet.

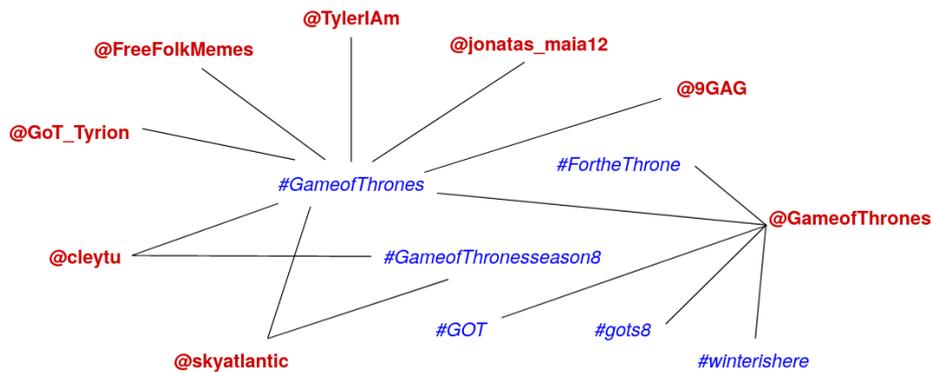


FIGURE 5.37 – Relation entre hashtags et utilisateurs appartenant aux signaux faibles.

5.5 Synthèse et conclusion

Comme décrit dans le chapitre 2, un signal faible doit toujours être associé à un contexte précis. Dans ce chapitre, nous avons évalué notre méthode BEAM dont l'objectif est la détection et l'interprétation des signaux faibles. Pour cela, nous avons mis en œuvre plusieurs expériences sur des graphes issus de plusieurs réseaux sociaux modélisant différents types d'interactions. Des jeux de données associés à une vérité de terrain nous ont permis de démontrer que la méthode proposée :

1. peut détecter et interpréter des signaux faibles associés à des événements réels dans le cas où le jeu de données en contient ;
2. ne détecte pas de signaux faibles s'il n'existe pas d'évènement ou si l'évènement est prévu.

Deux expériences ont été effectuées, l'une sur un jeu collecté par nos soins *via* Twitter (Lubrizol), l'autre est un jeu de données issues de capteurs et d'observations humaines (babouins). Sur ces deux jeux de données, nous avons pu détecter des signaux faibles une ou deux heures avant l'évènement ciblé. Pour le jeu de données Lubrizol, les signaux faibles identifiés sont émis par des utilisateurs qui annonçaient ou propageaient l'information de la venue surprise du Président Macron à Lubrizol. Certains comptes utilisaient cette visite pour appeler à manifester contre la politique du Président Macron, d'autres au contraire étaient favorables à cette visite. Les signaux faibles identifiés dans le jeu des babouins, correspondent à des individus ayant participé à des attaques une heure plus tard.

Nous avons utilisé un jeu de données représentant des interactions entre des élèves d'une école primaire, où les événements sont prévus et correspondent à des récréations et des pauses de midi. Deux autres jeux de données contiennent des interactions sur Facebook et MathOverflow où aucun événement est connu. Dans ces trois jeux de données, aucun signal faible n'est trouvé car il n'y a pas d'évènement pour le premier et les deux autres jeux sont trop généralistes pour qu'un signal faible puisse être détecté.

Après avoir démontré que BEAM était en **capacité de fournir des résultats valables**, nous avons montré sa capacité à **reproduire des résultats** en l'appliquant sur plusieurs périodes d'études correspondant à la diffusion des six derniers épisodes de la série télévisée Game of Thrones. BEAM peut identifier, quelques heures avant la diffusion des épisodes, des utilisateurs récurrents porteurs des signaux faibles. Nous les avons classifié : 1) des comptes qui ont incité le public à regarder la dernière saison, pouvant être vus comme des opportunités pour

5.5 Synthèse et conclusion

les producteurs de la série ; 2) des comptes surtout comiques qui ont détourné l'image de GOT. Ces comptes peuvent être perçus comme des menaces par les producteurs qui souhaiteront surveiller leur activité afin d'atténuer leur impact négatif ; 3) des comptes qui utilisent la notoriété de la série pour accroître la visibilité de leur tweets.

Pour confirmer l'existence des signaux faibles identifiés, nous avons utilisé une méthode statistique, la cross-correlation. Une corrélation significative est caractérisée par une valeur positive élevée et un décalage de temps négatif. L'utilisation de la cross-correlation sur les différents jeux de données nous a montré que les corrélations sont significatives quand il existe un événement dans la réalité. En revanche, et quand l'évènement est prévu ou ponctuel, ou même qu'il n'existe aucun évènement, nous n'avons pas trouvé de corrélations. Nous avons pu démontrer aussi que quand les signaux faibles sont perdus dans la masse des données (par exemple quand le nombre d'un graphlet dans la période d'étude est très petit par rapport au nombre des interactions), nous ne trouvons pas de corrélations significatives.

Enfin, nous avons étudié la **sensibilité de BEAM** en faisant varier plusieurs paramètres :

durée des snapshots : le choix des durées de snapshots est fonction de la taille du graphe global, plus un graphe est volumineux, plus la durée des snapshots sera réduite. La durée résulte d'un compromis entre la précision et la complexité : s'il existe peu de liens dans le snapshot, alors les graphlets à quatre ou cinq nœuds n'apparaîtront pas ; à l'opposé dans des snapshots de longue durée les graphlets à deux ou trois nœuds n'apparaîtront pas. Les jeux de données que nous avons étudiés possèdent des tailles de graphes différentes et donc des durées différentes.

type d'interaction : nous considérons que le choix de l'interaction est primordial car il est directement en lien avec le contexte de l'étude. Avec le réseau Twitter, si l'étude porte sur une personne ou une marque, la mention avec éventuellement la réponse qui consiste à citer et répondre à cette personne dans les tweets est à privilégier. En revanche, si l'étude porte sur des rumeurs ou un produit, il faut choisir le retweet qui permet la diffusion et la propagation de l'information entre les utilisateurs [150].

espace supplémentaire : les hashtags permettent de compléter les signaux faibles, l'étude de cet espace nous a permis de vérifier que les hashtags sont utilisés par les comptes appartenant aux orbites des signaux faibles détectés dans les relations de la mention et du retweet.

Finalement, nous avons assuré la **reproductibilité de BEAM** en utilisant des notebook Jupyter rendant les workflows reproductibles et en mettant à disposition les jeux de données et le code source en ligne pour le public. Ils sont disponibles à partir du lien suivant : <https://github.com/hibaaboujamra/Weak-Signals-Detection-and-Interpretation-BEAM>.



Troisième partie

Conclusion et perspectives

CONCLUSION GÉNÉRALE

POUR conclure ce manuscrit, nous présenterons un bilan des travaux que nous avons effectués puis nous terminerons par une description de nos perspectives de recherche.

6.1 Bilan

Dans les organisations actuelles qui gèrent des environnements complexes, être capable d'anticiper les discontinuités et les événements futurs permet de répondre aux menaces ou de saisir des opportunités. Mais, le volume et la diversité des informations produites empêchent les décideurs de reconnaître les signaux qui peuvent avertir d'événements importants à venir et *a priori* inconnus. Par conséquent, prévoir ces signaux futurs et agir correctement à temps est un défi difficile à relever. Une des caractéristiques des Réseaux Sociaux Numériques est la diffusion rapide d'information où les liens entre les utilisateurs déterminent le flux d'information. Ainsi, la problématique des signaux faibles dans les Réseaux Sociaux Numériques est devenue un sujet de recherche de premier plan. Nous nous sommes inscrits dans ce contexte, et dans le cadre du projet Cocktail. Nous nous intéressons plus particulièrement au réseau social Twitter et notre objectif est la détection et l'interprétation des signaux faibles cachés dans les discours.

Dans le chapitre 2, nous avons vu que la notion de signal faible est difficile à appréhender car elle dépend du domaine applicatif et près de soixante-dix définitions plus ou moins précises ont été élaborées. Le champ lexical est riche et de nombreuses nuances sont utilisées pour définir cette notion, notamment « signe d'avenir », « alerte précoce », « indicateur de changement », « wild cards ». Nous adoptons la première définition des signaux faibles proposée par Ansoff en 1975 qui les définit comme « les premiers symptômes de discontinuités stratégiques agissant comme une information d'alerte précoce, de faible intensité, pouvant être annonciatrice d'une tendance ou d'un événement important ». Les signaux faibles possèdent plusieurs propriétés quantifiables qui permettent leur caractérisation et aident à leur détection. Parmi ces caractéristiques nous trouvons **fragmentaire**, **visibilité faible**, **rare**, **utilité faible** et **fiabilité faible**. La plupart des approches de détection des signaux faibles étudient l'émergence de mots-clés à l'aide des techniques de « *text mining* » et de « *topic modeling* ». En revanche, très peu de travaux exploitent les interactions entre les individus.

Dans le chapitre 3, nous décrivons notre première contribution, dans laquelle nous proposons

une autre voie en analysant la topologie du réseau, afin de trouver des propriétés quantifiables qui peuvent être caractéristiques du signal faible. C'est pourquoi, dans notre méthode BEAM, nous avons choisi les graphlets comme description opératoire pour détecter les signaux faibles. En effet, les graphlets répondent aux caractéristiques des signaux faibles : ce sont de petits fragments ou motifs d'un graphe, qui pris seuls sont peu visibles et de faible utilité apparente. Tout d'abord, nous trouvons dans un graphe d'interactions entre des entités à des dates données, des graphlets qui représentent des faits clairs et observables, quantifiables à l'aide de mesures de **diffusion** et d'**amplification** qui les caractérisent en précurseurs. Ensuite, nous étudions la **rareté** du signal à l'aide du calcul de la contribution des graphlets dans les signaux faibles. Il s'agit d'un calcul de ratio qui sert à éliminer les fausses alertes (faux positifs) et à qualifier les vrais positifs et faux négatifs en signaux faibles. Ensuite, nous cherchons à confirmer les graphlets signaux faibles détectés avec la corrélation entre les séries temporelles des graphlets et celle des données du corpus d'étude.

Le chapitre 4 présente notre deuxième contribution. Une fois les signaux faibles détectés et confirmés, les experts métier doivent décider de leur pertinence pour l'organisation. Nous passons ici d'une étape quantitative (détection) à une étape qualitative (interprétation) où le rôle des experts métier est prépondérant. Les graphlets, outillage pour la détection des signaux faibles, sont aussi utilisés dans l'étape d'interprétation car les experts métier peuvent s'appuyer sur leur taille, leur forme prédéfinie ainsi que leurs orbites, c'est-à-dire les positions ou les rôles des nœuds dans les graphlets. Dans ce chapitre, nous offrons différents points de vues sur les signaux faibles, en passant des types de graphlets aux instances de graphlets, pour comprendre les éléments composant les signaux faibles et leurs relations. Différentes visualisations sont aussi proposées pour organiser visuellement les signaux faibles.

Finalement, nous avons effectué des expérimentations présentées en chapitre 5. Elles portent sur sept jeux de données issus de différents réseaux (Twitter, Facebook, réseaux de capteurs) ayant des volumes différents. Les expériences que nous avons réalisées ont comme objectif la validation de la méthode BEAM en étudiant son comportement par rapport à des vérités de terrain, sa capacité à reproduire les résultats dans un contexte similaire et sa robustesse lorsque nous faisons varier les paramètres correspondant à l'interaction étudiée et aux types de nœuds.

Les résultats de nos expérimentations ont conforté notre hypothèse que les graphlets peuvent être considérés comme une signature d'un signal faible. Ils permettent à la fois d'automatiser la tâche de détection des signaux faibles dans un gros volume de données tout en laissant une place à l'interprétation par des experts métier gommant ainsi l'effet « boîte noire » que pourrait avoir une méthode entièrement automatisée.

6.2 Perspectives

Dans cette thèse, nous avons étudié et présenté une nouvelle méthode qui exploite les interactions dans les Réseaux Sociaux Numériques et nous avons obtenu de bons résultats. Nous présentons dans la suite un travail réalisé que nous considérons comme une perspective à court terme, puisque les premiers résultats obtenus sont encourageants, et des perspectives pour nos travaux futurs.

6.2.1 Perspective à court terme

Nous travaillons actuellement sur une nouvelle proposition qui pourra enrichir notre méthode BEAM. Cette proposition consiste à remplacer l'étape 3 de BEAM (identification des précurseurs) par une méthode quantitative basée sur des outils de l'algèbre linéaire et de *clustering*. L'objectif est de détecter des variables latentes qui participent le plus au signal faible. L'étape d'interprétation demeure applicable. Nous allons présenter les principes de cette méthode ainsi que les premiers résultats de nos expérimentations et les comparer avec ceux obtenus au chapitre 5.

Nous utilisons la décomposition en valeurs singulières (SVD pour *Singular Value Decomposition*) [53, 177], une technique de l'algèbre linéaire, pour réduire la taille des données, trier le signal et faire apparaître des valeurs latentes dans le graphe d'interactions temporelles. La SVD a été utilisée avec des algorithmes de « *text mining* » ou de « *clustering* » pour la détection des signaux faibles [2, 86, 180] mais aussi pour détecter des tendances [40]. Dans notre cas, nous proposons de l'utiliser sur une signature en graphlets d'un snapshot ou d'une entité mais aussi de l'exploiter avec les orbites ou les rôles des entités.

Une décomposition « complète » en valeurs singulières de toute matrice $A \in \mathbb{R}^{m \times n}$, est définie comme suit en utilisant trois facteurs : $A = U\Sigma V^T$, où $U \in \mathbb{R}^{m \times m}$ et $V \in \mathbb{R}^{n \times n}$ sont des matrices orthogonales, dont les colonnes se composent des vecteurs singuliers gauche et droit de A , respectivement, et $\Sigma \in \mathbb{R}^{m \times n}$ est une matrice pseudo-diagonale avec $r = \text{rang}(A)$ ¹ entrées diagonales positives. Les r entrées de Σ se composent de σ_i , où $i = 1, \dots, p$ et $p = \min(m, n)$, et ces σ_i sont appelés les valeurs singulières de A .

Après avoir calculé le nombre de graphlets et d'orbites dans un snapshot, nous appliquons la SVD sur différents types de matrices :

1. Matrice **Snapshot** \times **Graphlet**, qui exprime le nombre de graphlets dans les snapshots de la période étudiée. Dans cette matrice, les lignes correspondent aux s snapshots étudiés, et les colonnes aux trente graphlets, G_0 à G_{29} ;
2. Matrice **Entité** \times **Graphlet**, qui exprime le nombre de fois où une entité apparaît dans les trente graphlets pour un snapshot S^t donné. Dans cette matrice, les lignes correspondent aux identifiants des entités et les colonnes aux trente graphlets ;
3. Matrice **Entité** \times **Orbite**, qui exprime le nombre de fois où une entité (les lignes) apparaît dans les soixante-treize orbites (les colonnes) des trente graphlets pour un snapshot S^t donné.

Par exemple, appliquer la SVD sur la première matrice **Snapshot** \times **Graphlet** la décompose en trois nouvelles matrices U , Σ et V avec U est la matrice de taille $s \times s$ des snapshots, V est la matrice de taille 30×30 des graphlets, et Σ est la matrice diagonale de taille $s \times 30$ des valeurs singulières. Les valeurs singulières sont ordonnées de manière décroissante dans la matrice Σ , ainsi les premières valeurs sont celles dont les vecteurs associés portent le plus d'information sur le signal. Pour cela nous réduisons la taille des matrices U et V en fonction des k premières valeurs singulières choisies dans Σ (nous avons fixé k à 3 pour les expériences). Ceci nous permet ensuite d'identifier des entités similaires, mais aussi des entités qui ne ressemblent pas aux autres. Pour mesurer la similarité/différence entre des entités, nous utilisons deux techniques différentes : la similarité cosinus [79] et l'algorithme de *clustering* K-means [126].

1. $\text{rang}(A) = \dim(C(A))$ tel que $C(A)$ est le sous-espace engendré par les colonnes de A , et \dim est sa dimension dans l'espace vectoriel.

La similarité cosinus est utilisée sur les matrices décomposées par la SVD. Cette méthode retourne une valeur comprise entre -1 et +1 qui indique le degré de similarité entre deux entités. Une valeur égale à +1 signifie que les deux entités sont identiques, et une valeur égale à -1 indique que les deux sont très différentes. Nous utilisons également l'algorithme K-means sur les matrices décomposées pour regrouper les entités similaires dans un même cluster. Cette technique est menée d'un outil de visualisation qui permet aux experts métier d'observer clairement les entités similaires, et de confirmer celles qui fournissent le plus d'information sur le signal. K-means répartit les entités de la matrice décomposée en K clusters. Nous utilisons la méthode *Elbow* pour calculer le nombre optimal des clusters K [108]. Selon le type de la matrice prise en entrée de cet algorithme, les clusters résultants peuvent regrouper des snapshots, des utilisateurs, des graphlets ou des orbites.

Pour évaluer ces deux méthodes, nous comparons leurs résultats : par exemple, les entités ayant un coefficient de similarité proche de +1, doivent être regroupés dans le même cluster.

La figure 6.1 résume les étapes suivies à partir du corpus de l'étude pour détecter des variables latentes.

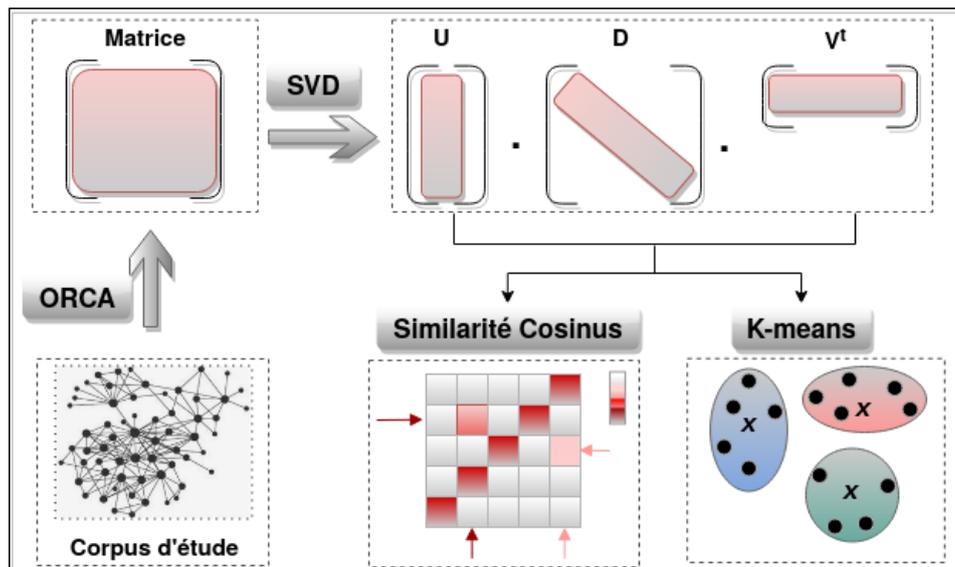


FIGURE 6.1 – Étapes suivies pour faire apparaître des variables latentes.

Pour évaluer la méthode proposée, nous avons réalisé une série d'expérimentations décrites dans l'annexe G, et menées sur deux jeux de données du chapitre 5 : Lubrizol et GOT. Ces premières expériences ont montré des résultats prometteurs, qui seront poursuivis ultérieurement.

Conclusion Nous avons présenté une nouvelle voie pour détecter des variables latentes qui participent au signal faible. Nous avons utilisé la SVD et le K-means, et nous l'avons évaluée à l'aide d'une série d'expérimentations menée sur deux jeux de données. Les résultats obtenus sont encourageants et nous avons démontré leur pertinence en fonction de ceux obtenus avec l'étape de détection de BEAM.

6.2 Perspectives

6.2.2 Perspectives à plus long terme

En plus de notre travail actuel décrit dans la sous-section précédente, des perspectives intéressantes émergent pour renforcer nos propositions.

Avec les Réseaux Sociaux Numériques, les utilisateurs peuvent exprimer et partager leurs opinions et leurs émotions sur des produits et des services, des sujets d'actualité ou des événements [155]. Dans certaines organisations, les décideurs ont besoin d'identifier les avis négatifs reçus afin de gérer leur réputation et de mettre en avant des avis positifs pour améliorer leur image de marque. Un utilisateur peut aimer un message ou le critiquer. Ces spécificités peuvent être très instructives pour l'interprétation des signaux faibles. Une perspective intéressante à court terme est de proposer des méthodes d'analyse du contenu des données et, en particulier, d'analyse de sentiments.

Une autre piste de recherche consiste à détecter et interpréter les signaux faibles au sein des communautés ou entre communautés. Les personnes d'une même communauté ont généralement des propriétés communes. Par exemple, ils peuvent être amis ou sont originaires du même pays. Une telle étude peut être utile dans des applications de marketing. De plus, le temps passé à identifier les signaux faibles est réduit puisqu'il est évident que la communauté est plus petite que le réseau social. Il est aussi intéressant de connaître les personnes d'une communauté qui sont en relation avec des personnes appartenant à une autre communauté, ces personnes jouant un rôle charnière dans la diffusion des signaux faibles d'une communauté vers une autre.

Le processus de prise de décision effectué par l'expert métier implique une connaissance du domaine et une compréhension des signaux faibles identifiés. L'expert métier peut s'appuyer sur les diagrammes d'argumentation qui sont souvent utilisés pour augmenter la confiance dans un système [153]. L'argumentation consiste à convaincre les acteurs prenants d'une conclusion sur la base d'éléments de preuve qui influenceront leur décision [168]. Il existe plusieurs travaux dans lesquels une formalisation à base de diagrammes d'argumentation a été proposée. Par exemple, dans [167], les auteurs proposent une modélisation d'un réseau d'arguments autour des régimes végétariens. Chaque argument est formalisé par un nœud connecté aux autres arguments par des liens de réfutation. Avec cette méthode, ils ont répondu à la question « Quels sont les arguments utilisés pour prendre la décision de devenir végétariens ? ». Duffau et al. [51] proposent un système d'argumentation et l'appliquent sur deux études de cas, l'une dans le domaine biomédical et l'autre pour générer le meilleur workflow de tâches de Machine Learning en fonction de la taille et de la qualité des données.

D'un point de vue appliqué, nous voulons offrir des diagrammes d'argumentation basés sur les signaux faibles pour permettre aux experts métier de justifier leur prise de décision.

Les changements d'états brusques sont très fréquents dans les systèmes complexes. La recherche de précurseurs, c'est-à-dire d'indicateurs précoces de leur arrivée, est fondamentale dans plusieurs domaines [69]. Cependant, il est difficile d'avertir longtemps à l'avance de la survenue de ces brusques changements. Nous souhaitons adapter notre méthode pour traiter les transitions de phases. Cela peut être réalisé en utilisant des concepts comme la théorie de la percolation permettant de trouver des précurseurs qui anticipent le point de basculement du système [193]. Un exemple pratique consiste à établir un seuil de percolation (par exemple un rapport entre la moyenne et la variance des degrés de nœuds), au delà duquel les nœuds seront considérés comme des éléments participant à la transition de phase du réseau.

CHAPITRE 6 : *Conclusion Générale*

Quatrième partie

Annexes

COMPLÉMENTS SUR LES GRAPHLETS

Cette annexe donne un complément sur la notion de graphlets avec une présentation des mesures spécifiques aux graphlets et leur utilisation dans des domaines proches de notre recherche.

A.1 Mesures sur les graphlets

Ces mesures ont été appliquées aux réseaux biologiques pour identifier des groupes de nœuds topologiquement similaires : par exemple pour identifier des gènes du cancer, pour identifier la dégradation des protéines ou pour prédire des propriétés biologiques de nœuds non encore caractérisés.

La signature d'un nœud u ou *Graphlet Degree Vector* (GDV) correspond au nombre de fois où le nœud u apparaît dans les orbites, la première coordonnée correspond au degré du nœud u .

La première mesure date de 2004 et a pour objectif de mesurer la distance entre deux graphes avec la *relative graphlet frequency distance* [157]. Cette distance se base sur la fréquence relative des graphlets $\frac{|G_i|}{T(G)}$ avec $|G_i|$ le nombre de graphlets G_i et $T(G) = \sum_{i=1}^{i=29} |G_i|$ le nombre total de graphlets énumérés dans le graphe G . La distance entre deux graphes G et H est alors définie par :

$$D(G, H) = \sum_{i=1}^{i=29} |F_i(G) - F_i(H)| \text{ où } F_i(G) = -\log \left(\frac{|G_i|}{T(G)} \right)$$

Le logarithme est employé afin de lisser les proportions de graphlets car ils apparaissent de façon très hétérogène les uns par rapport aux autres au sein des réseaux d'interaction de protéines sur lesquels les auteurs de cette mesure travaillent. L'utilisation du $-$ permet d'obtenir une valeur de $F_i(G)$ toujours positive puisque le logarithme d'une proportion comprise entre 0 et 1 est négatif par nature. Leurs travaux ont conclu que les réseaux d'interaction de protéines sont proches des réseaux géométriques aléatoires¹.

En 2007, Pržulj définit une autre mesure de similarité entre des graphes utilisant les orbites [156]. La *Graphlet degree distribution agreement* correspond au nombre de fois où chaque

1. Un réseau géométrique aléatoire est un réseau dont les sommets sont placés aléatoirement et dont les arêtes relient les sommets qui sont proches les uns des autres.

sommet du graphe apparaît dans chacune des soixante-treize orbites des trente graphlets de taille cinq ou moins. Pour chaque orbite O_j , $d_G^j(k)$ est le nombre de sommets du graphe G qui apparaissent exactement k fois dans l'orbite O_j . La distribution graphlets-degrés (GDD) de l'orbite O_j dans G est : $d_G^j = (d_G^j(0), d_G^j(1), \dots, d_G^j(\infty))$.

La figure A.1 illustre, pour le graphe G le nombre de graphlets de taille 2 et 3, les *Graphlet Degree Vector* et la distribution graphlets-degrés pour les quatre orbites.

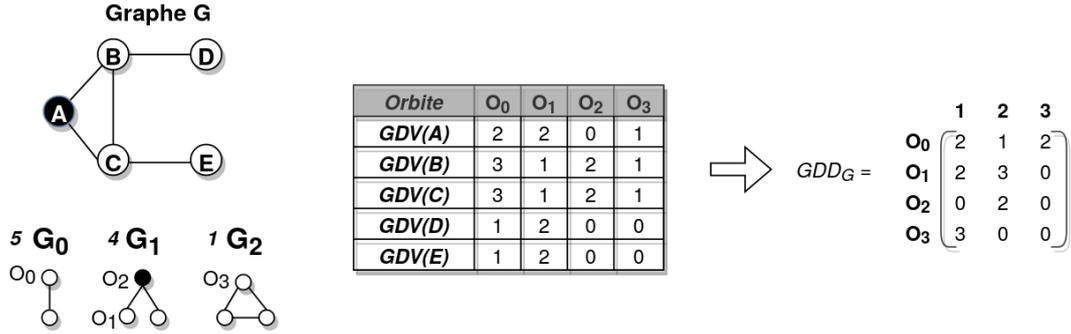


FIGURE A.1 – Graphe G , nombre de graphlets de taille 2 et 3 et les mesures GDV et GDD, inspirée de [12].

Pour réduire l'influence des forts degrés dans GDD , chaque valeur $d_G^j(k)$ est normalisée par $\overline{d_G^j(k)} = \frac{d_G^j(k)}{k}$, les composantes du vecteur sont sommées, $T_G^j = \sum_{k=1}^{\infty} \overline{d_G^j(k)}$.

Ainsi, la distribution normalisée des graphlets-degrés est donnée par : $N_G^j(k) = \frac{\overline{d_G^j(k)}}{T_G^j}$.

La distance, comprise entre 0 et 1, de deux graphes G et H pour une orbite O_j est définie par $D^j(G, H) = (\sum_{k=1}^{\infty} [N_G^j(k) - N_H^j(k)]^2)^{\frac{1}{2}}$

Cette mesure est en réalité une mesure de similarité car c'est un accord entre deux graphes qui est calculé par $A^j(G, H) = 1 - D^j(G, H)$. Finalement le score de proximité des deux graphes, toutes orbites confondues est la moyenne au sens arithmétique ou géométrique de l'ensemble des accords relatifs aux soixante-treize orbites des graphlets :

$$A_{arithm}(G, H) = \frac{1}{73} \sum_{j=0}^{72} A^j(G, H) \quad A_{geo}(G, H) = \prod_{j=0}^{72} A^j(G, H)^{\frac{1}{73}}$$

A.2 Utilisation des graphlets dans des domaines connexes

Dans cette section, nous présentons l'utilisation des graphlets dans les Réseaux Sociaux Numériques. Les graphlets ont aussi été utilisés, avec Twitter comme cas d'étude, dans le domaine de la diffusion d'information avec la viralité des tweets, la prédiction de cascade de retweets ainsi que la prédiction de tendance avec les hashtags.

Prédire la viralité des tweets permet de comprendre comment l'information se propage à travers le réseau et d'agir en réduisant, par exemple, la propagation de fausses nouvelles. À côté des méthodes classiques (centralités, PageRank), Bass et al. [16] puis Khorshidi et al. [100] ont montré que la distribution graphlets-degrés (GDD) est une mesure efficace pour prédire la viralité dans un réseau d'interactions. Les variations de cette mesure au cours du temps ont permis d'identifier un sous-ensemble de graphlets impliqués dans le processus viral et ainsi trouver les nœuds qui propagent l'information. Dans les deux articles, deux modèles de diffu-

A.2 Utilisation des graphlets dans des domaines connexes

sion sont utilisés (le modèle Susceptible-Infected-Susceptible et le modèle de Hawkes) sur des réseaux bien connus comme soc-dolphin², Zachary's Karate³.

Lussier et al. [127] étudient la propagation de l'information par l'intermédiaire de cascade de retweets. Pour un tweet t , ils construisent sa cascade de retweets qui est un très petit graphe orienté C . Pour chaque cascade C , ils calculent sa signature v_C comme étant le vecteur qui contient le nombre de fois où le graphlet G_i apparaît dans C . Ils concluent que les graphlets de type chemin et étoilé se trouvent dans des cascades qui se déclenchent rapidement (dans les vingt-quatre heures) alors que des graphlets plus complexes sont dans des cascades qui se produisent moins rapidement. Cette étude confirme les résultats présentés dans [123].

Leskovec et al. [124] ont aussi étudié les graphlets orientés dans le domaine du marketing viral lors de la recommandation de produits entre acheteurs et potentiels acheteurs. Ils ont mis en évidence que les graphlets orientés (voir la figure 3.4 du chapitre 3) de type G_2 et G_4 sont les plus fréquents c'est-à-dire le cas où un acheteur recommande à deux personnes et le cas où deux acheteurs recommandent à la même personne respectivement. Deux autres comportements ont aussi été mis en évidence : les graphlets G_{23} et G_{27} correspondent au cas où deux acheteurs ont les mêmes amis mais ils ne se recommandent pas et les graphlets G_{24} et G_{26} où un acheteur recommande à un autre et ces deux personnes recommandent aux mêmes personnes.

Šourek et al. [175] proposent une méthode basée sur les graphlets pour prédire quels hashtags seront tendance. Pour chaque jour D et chaque hashtag H , un sous-graphe est construit comme suit : il existe un nœud pour chaque utilisateur et un arc orienté (u_i, u_j) si et seulement si u_i suit (relation *follows*) u_j . Un nœud est étiqueté par H si et seulement si l'utilisateur correspondant à ce nœud a utilisé le hashtag H dans au moins un de ses tweets le jour D . La liste des graphlets orientés de taille 3 comprenant le hashtag H avec leur nombre est calculé pour le jour D et stocké dans un vecteur V_H . À partir de ces vecteurs, pour chaque hashtag H , on construit un vecteur V_{rank} où le i ème composant de V_{rank} correspond au rang (c'est-à-dire l'ordre) du i ème élément du vecteur V_H , c'est-à-dire le graphlet orienté G_i . Les auteurs font l'hypothèse que les relations orientées entre les utilisateurs (relation *follows*) représentent en réalité des liens de causalité dans la dynamique de propagation des tendances. Si ce n'est pas le cas, l'information ne provient probablement pas du réseau, elle est reçue par d'autres voies. Pour évaluer la causalité, les caractéristiques temporelles entre deux jours sont alors calculées comme des moyennes ou des écarts-types de ces différents rangs.

Dans [60], les auteurs analysent la collaboration entre chercheurs lors de cinq épidémies, l'objectif est de déterminer si les collaborations demeurent pérennes ou changent en fonction des épidémies. Deux types de graphes sont analysés : un graphe bi-parti chercheur-article et un graphe de collaboration entre chercheurs. Ils ont mis en lumière l'importance des graphlets G_4 en identifiant des chercheurs qui jouent le rôle de « colonne vertébrale » entre chercheurs par leur position centrale dans le graphlet. Ils réalisent aussi des mesures de concordance/discordance basées sur les graphlets entre les deux graphes.

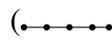
Un travail que l'on peut considérer comme proche du nôtre est la détection d'anomalies dans une séquence de graphes (sous-graphes) orientés à l'aide de graphlets. Harshaw et al. [81] énumèrent les graphlets de taille 3 et les orbites dans chacun des sous-graphes. La détection

2. <https://networkrepository.com/soc-dolphins.php>

3. <https://networkrepository.com/karate.php>

des anomalies est réalisée par une approche statistique avec l'utilisation de la loi normale multidimensionnelle⁴ sur l'ensemble des *Graphlet Degree Vectors* (GDV) obtenus où la méthode *minimum covariance determinant* ajuste les meilleures moyenne et covariance et la distance de Mahalanobis⁵ permet de comparer deux sous-graphes consécutifs [90].

Enfin, un dernier travail propose une classification des graphlets qui peut nous aider lors de l'étape d'interprétation : Charbey [37] classe les graphlets de taille cinq : les chemins

(,  et ) , les étoilés ( et ) , les triangulés possèdent tous au moins un triangle

induit mais ont malgré tout une faible densité (, ,  et ) , les trousés (, , , )

et ) et les densifiés (, , , , ,  et ) . Cette classification a fait ressortir, à

partir de caractéristiques structurelles propres à Facebook, cinq types de réseaux qui peuvent être associés à une, parfois deux, catégories de graphlets. Par exemple, les réseaux densifiés et les réseaux en étoile ont une très forte représentation des graphlets de même nom et ont des sous-représentations dans les autres catégories. Charbey insiste sur le fait que cette étude n'est valable que pour les réseaux égo-centrés.

4. C'est une généralisation de la loi normale, https://fr.wikipedia.org/wiki/Loi_normale_multidimensionnelle

5. https://fr.wikipedia.org/wiki/Distance_de_Mahalanobis

PRISE EN COMPTE DE LA DIMENSION TEMPORELLE DANS LES GRAPHEs

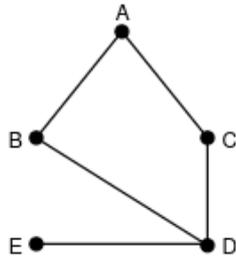
Les interactions temporelles peuvent être modélisées sous la forme d'un graphe statique $G(V, E)$ où $E \subseteq V \times V$ est l'ensemble des liens modélisant l'interaction ou la relation entre les paires de nœuds, si $(u, v) \in E$ alors les nœuds u et v sont liés (figure B.1.a). Les interactions temporelles n'admettent pas cette seule représentation sous forme de graphe.

La vision graphe augmenté représente les interactions temporelles trouvées dans un ensemble fini \mathfrak{X} tel que $(u, v, t) \in \mathfrak{X}$ indique que u interagit avec v à l'instant t , sous la forme d'un graphe unique [111]. Un graphe est créé dans lequel un nœud est un couple (v, t) , avec $v \in V$ et $t \in T$, et dans lequel le nœud (u, t_i) est lié au nœud (v, t_j) soit si ils interagissent c'est-à-dire si $t_i = t_j = t$ et $(u, v, t) \in \mathfrak{X}$, soit si ils sont contigus dans le temps c'est-à-dire si $u = v$ et $t_j > t_i$ (voir figure B.1.c). Une seconde représentation est de faire porter la temporalité sur les liens (voir figure B.1.b).

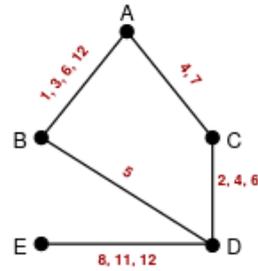
La vision flot de liens a été formellement définie par Latapy et al. [115] : un flot de liens $L = (T, V, E)$ est défini par un intervalle de temps $T \subset \mathbb{R}$, un ensemble de nœuds V et un ensemble de liens $E \subseteq V \times V \times T$, où $(u, v, t) \in E$, indique que les nœuds u et v ont interagi au temps t .

ANNEXE B : *Prise en compte de la dimension temporelle dans les graphes*

a) *Graphe statique contenant tous les liens*



b) *Graphe étiqueté sur les liens*



c) *Graphe étiqueté sur les noeuds*

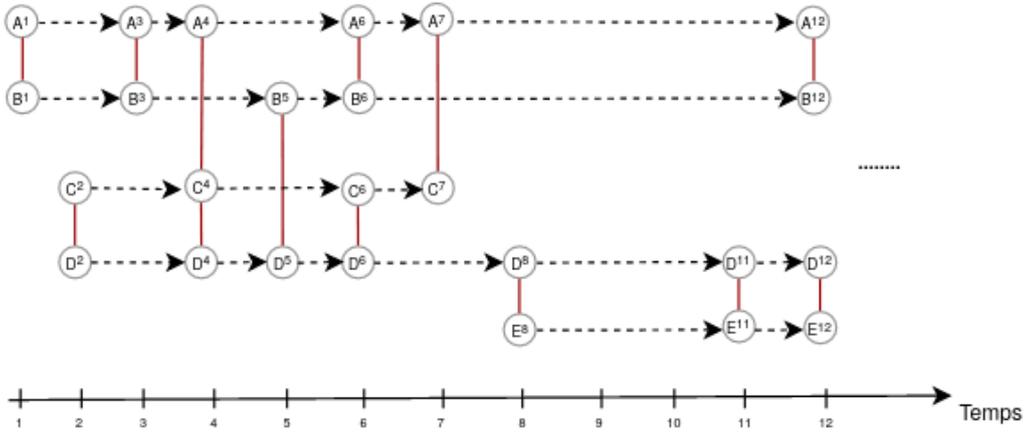


FIGURE B.1 – Représentations temporelles étiquetées sur les liens et les nœuds du graphe statique.

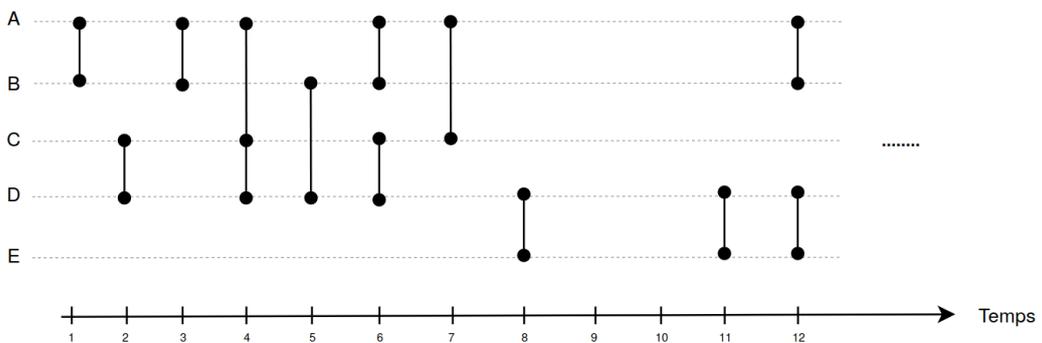


FIGURE B.2 – Flot de liens du graphe statique de la figure B.1.

EXPÉRIMENTATIONS SUR L'IMPACT DU CHANGEMENT DE LA TAILLE DES SNAPSHOTS

L'objectif des deux expérimentations présentées ci-dessous est de mesurer l'impact de la taille du snapshot sur l'identification des signaux faibles afin de pouvoir fournir un guide aux experts métier.

C.1 Jeu de données Lubrizol : graphe des mentions

Comme décrit en sous-section 5.1.1, nous avons appliqué la méthode BEAM sur le graphe des mentions du jeu de données Lubrizol avec des snapshots de différentes tailles. Nous rappelons que dans cette étude, 1 141 mentions ont été émises par 845 utilisateurs.

Nous avons fait varier la durée des snapshots de 10, 15, 30 et 60 minutes entre 16 heures et 17 heures. Le tableau C.1 synthétise les résultats obtenus. La première colonne indique la durée du snapshot choisie, la deuxième colonne détaille les heures de début et de fin du snapshot comprises entre 16 heures et 17 heures. Les troisième, quatrième et cinquième colonnes montrent les caractéristiques topologiques des sous-graphes construits de chacun des snapshots, respectivement le nombre de nœuds, de liens et la densité. Quelque soit le snapshot, les sous-graphes contiennent peu de nœuds et de liens et leur densité est faible. La dernière colonne indique les cinq graphlets signaux faibles. À des fins de visualisation, les deux graphlets G_4 et G_{11} communs à tous les snapshots sont en rouge et pour chacune des durées choisies (sauf pour $\Delta t = 60$ minutes), des lignes horizontales pointillées divisent la période d'étude en deux. Nous avons quantifié la présence des graphlets signaux faibles, en calculant leur pourcentage de participation dans tous les snapshots étudiés. Par exemple, les graphlets G_{10} , G_9 et G_3 sont détectés respectivement dans 77%, 46% et 38% des snapshots. Le graphlet G_3 apparaît dans tous les snapshots se terminant à 16 heures 30 minutes (avec $\Delta t \in \{10, 15\}$) puis disparaît de la liste. 80% des graphlets signaux faibles détectés dans les deux snapshots de 30 minutes et dans celui de 60 minutes sont aussi détectés dans les snapshots de 10 et 15 minutes correspondants. 100% des graphlets détectés dans le snapshot de 60 minutes sont détectés dans au moins un des deux snapshots de 30 minutes.

Comme les graphlets G_4 et G_{11} sont présents dans tous les snapshots, nous avons étudié leurs

ANNEXE C : Expérimentations sur l'impact du changement de la taille des snapshots

Durée Δt	Intervalle	$ V $	$ E $	D	Graphlets signaux faibles
10 min.	16h00 → 16h10	17	20	0,147	G_{11} G_4 G_{10} G_3 G_1
	16h10 → 16h20	39	42	0,057	G_{11} G_{10} G_4 G_3 G_9
	16h20 → 16h30	23	31	0,122	G_{11} G_{10} G_4 G_9 G_3
	16h30 → 16h40	29	26	0,064	G_5 G_{16} G_4 G_{11} G_{20}
	16h40 → 16h50	22	24	0,104	G_{11} G_5 G_4 G_{18} G_{16}
	16h50 → 17h00	19	24	0,140	G_{11} G_4 G_{17} G_{10} G_{24}
15 min.	16h00 → 16h15	24	28	0,101	G_{10} G_{11} G_4 G_3 G_9
	16h15 → 16h30	47	59	0,054	G_{11} G_{10} G_4 G_3 G_1
	16h30 → 16h45	38	34	0,048	G_5 G_{20} G_{16} G_4 G_{11}
	16h45 → 17h00	22	31	0,134	G_4 G_{11} G_{10} G_{18} G_1
30 min.	16h00 → 16h30	65	87	0,042	G_{11} G_{10} G_4 G_9 G_1
	16h30 → 17h00	52	62	0,046	G_4 G_{11} G_{10} G_9 G_{14}
60 min.	16h00 → 17h00	105	144	0,026	G_{11} G_4 G_{10} G_9 G_{14}

TABLE C.1 – Lubrizol : top-5 graphlets signaux faibles détectés entre 16 heures et 17 heures, en faisant varier la durée du snapshot. $|V|$ et $|E|$ correspondent aux nombres de nœuds et de liens dans les sous-graphes de chaque snapshot, et D leur densité.

instances. La figure C.1 présente des instances des graphlets G_4 et G_{11} trouvées dans quatre snapshots de durées différentes. Pour G_4 , les mêmes nœuds apparaissent dans toutes les instances où le compte utilisateur @CamaradeCharles occupe l'orbite centrale O_7 , @manon_leterq, @massinfabien et @Rouen occupent l'orbite périphérique O_6 . Ces quatre utilisateurs ont été identifiés comme porteurs de signal faible.

Les snapshots de 15 minutes ont détecté un graphlet (en bas de la figure) qui une extension du graphlet détecté dans les snapshots de 10 minutes avec les mêmes utilisateurs auquel s'est ajouté @JeromeMoriniere. Ces utilisateurs représentent des journalistes et le compte officiel de la ville de Rouen.

Nous concluons que quelque soit la durée des snapshots, des graphlets signaux faibles sont récurrents et que les utilisateurs qui apparaissent dans leurs instances sont porteurs du signal faible comme notre expérience l'a aussi montré en sous-section 5.1.1.

C.2 Jeu de données GOT : graphe des retweets

Nous avons répété l'expérience ci-dessus sur le graphe des retweets du jeu de données GOT décrit en section 5.3. Cette expérience est réalisée sur les données du premier épisode de la dernière saison de GOT. Nous rappelons que le graphe global du premier épisode, diffusé le 14 avril 2019, contient 270 825 liens et 226 554 nœuds, ayant une densité égale à 0.00005. Nous avons découpé ce corpus en des snapshots de durées égales à 10, 15, 30, 40, 50 et 60 minutes. Le tableau C.2 présente les résultats obtenus pour les snapshots compris entre 17 heures et 18

C.2 Jeu de données GOT : graphe des retweets

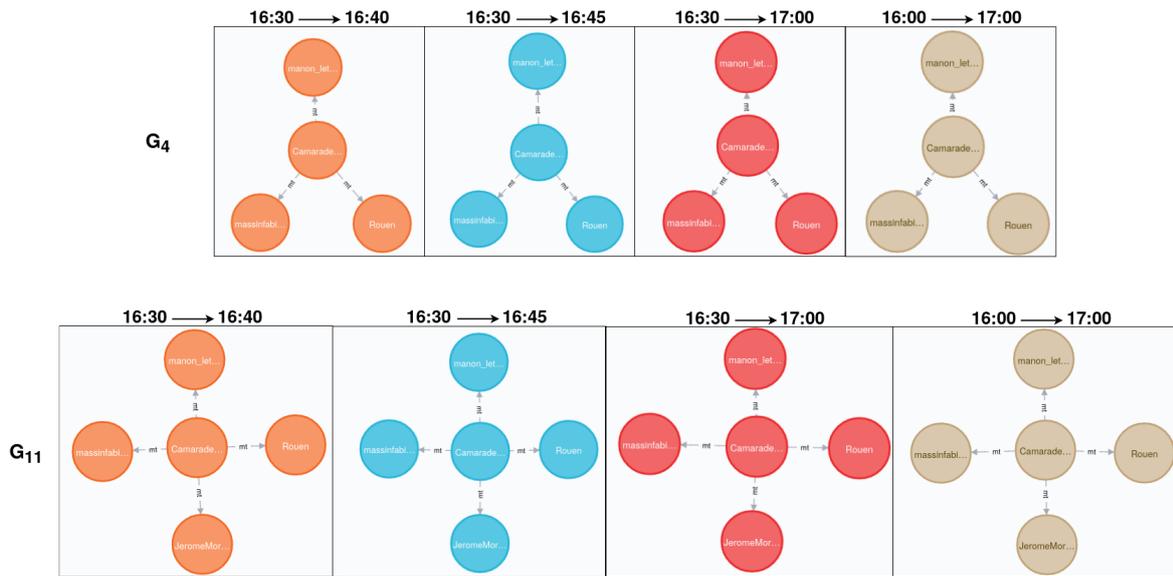


FIGURE C.1 – Appartenance des utilisateurs à quatre instances de G_4 et de G_{11} signaux faibles, ayant différentes valeurs de Δt .

heures, le jour de la diffusion de l'épisode. La première colonne du tableau montre les différentes valeurs choisies pour Δt . La deuxième colonne correspond aux intervalles comprises entre 17 et 18 heures en fonction de Δt . Les trois colonnes suivantes représentent la taille des sous-graphes en nombre de nœuds et de liens et leur densité. Nous remarquons que la densité des graphes est faible, pourtant leur taille est plus importante que celle de l'expérience précédente. À partir d'une durée égale à 40 minutes, Orca prend plus d'une heure pour énumérer les graphlets. Ce facteur doit être pris en compte lors du choix de la durée des snapshots, car les résultats doivent être fournis rapidement si l'expert examine en permanence les indicateurs d'un évènement imminent. La dernière colonne du tableau contient le top cinq des graphlets signaux faibles détectés.

Les lignes horizontales pointillées du tableau permettent de diviser le snapshot débutant à 17 heures et se terminant à 18 heures en six snapshots pour $\Delta t = 10$ minutes, en quatre snapshots pour $\Delta t = 15$ minutes et en deux snapshots pour $\Delta t = 30$ minutes. Les snapshots où Δt est égale à 40 et à 50 minutes sont particuliers puisqu'ils débutent à 17 heures mais se terminent à 17 heures 40 minutes et à 17 heures 50 minutes respectivement. Nous les avons ajoutés pour évaluer le temps de réponse de l'algorithme sur des grands graphes. Nous remarquons que les graphlets à cinq nœuds, les plus complexes, sont détectés dans tous les snapshots, quelque soit leur durée, à partir de 17 heures 30 minutes. Notre objectif est de calculer les pourcentages de présence des graphlets dans les snapshots pour identifier la durée Δt des snapshots qui renvoie le plus grand nombre de graphlets détectés dans les autres snapshots.

Nous remarquons que le graphlet G_{21} (en rouge) se trouve dans la plupart des snapshots, le graphlet G_{20} est le deuxième le plus fréquent, suivi des graphlets G_{12} , G_{22} , G_6 , G_{15} , G_5 et G_9 . Le tableau C.3 donne la participation des graphlets signaux faibles dans les snapshots, pour ceux qui ont un pourcentage supérieur ou égal à 40%. Nous avons ensuite quantifié la présence de ces graphlets dans chaque durée. Les snapshots où Δt est égale à 10 minutes couvrent tous les graphlets du tableau C.3. Pour Δt égale à 15 et 30 minutes, 83% des graphlets sont retrouvés. Pour Δt égale à 50 et 60 minutes, 67% des graphlets sont présents, et finalement

ANNEXE C : Expérimentations sur l'impact du changement de la taille des snapshots

Durée Δt	Intervalle	$ V $	$ E $	D	Graphlets signaux faibles
10 min.	17h00 → 17h10	7 898	7 109	0,00022	G_{12} G_6 G_9 G_{21} G_{13}
	17h10 → 17h20	8 342	7 435	0,00021	G_3 G_1 G_9 G_6 G_{12}
	17h20 → 17h30	8 108	7 172	0,00022	G_5 G_{20} G_{22} G_{12} G_2
	17h30 → 17h40	16 583	16 080	0,00012	G_{21} G_{15} G_{20} G_{22} G_9
	17h40 → 17h50	16 099	15 373	0,00012	G_{20} G_{21} G_5 G_{15} G_{22}
	17h50 → 18h00	13 820	12 966	0,00013	G_{21} G_{22} G_{15} G_2 G_{20}
15 min.	17h00 → 17h15	11 483	10 731	0,00016	G_5 G_{20} G_{12} G_6 G_7
	17h15 → 17h30	11 841	10 968	0,00015	G_9 G_3 G_1 G_{10} G_6
	17h30 → 17h45	24 331	24 089	0,00001	G_{20} G_{22} G_{12} G_{21} G_5
	17h45 → 18h00	20 867	20 202	0,00003	G_{20} G_7 G_{22} G_{12} G_{21}
30 min.	17h00 → 17h30	38 037	38 626	0,00003	G_{20} G_{25} G_{21} G_{27} G_{15}
	17h30 → 18h00	37 084	37 780	0,00005	G_{12} G_{25} G_{27} G_6 G_{21}
40 min.	17h00 → 18h00	136 189	155 371	0,00002	G_{21} G_{20} G_{15} G_5 G_{24}
50 min.	17h00 → 17h40	96 392	107 339	0,00002	G_{15} G_{21} G_{27} G_{20} G_{22}
60 min.	17h00 → 17h50	174 632	203 564	0,00001	G_{22} G_{12} G_{18} G_6 G_{21}

TABLE C.2 – GOT : top cinq graphlets signaux faibles détectés entre 17 heures et 18 heures, en faisant varier la durée du snapshot. $|V|$ et $|E|$ correspondent aux nombres de nœuds et de liens dans les graphes de chaque intervalle, et D leur densité.

pour une durée Δt égale à 40 minutes, uniquement la moitié de ces graphlets est trouvée. D'après les résultats de notre analyse, nous concluons que les snapshots ayant une durée égale à 10 minutes sont ceux qui offrent le plus grand nombre des graphlets signaux faibles détectés dans les autres snapshots.

Graphlet signal faible	Pourcentage
G_{21}	73%
G_{20}	67%
G_{12}	53%
G_{22}	47%
G_6	40%
G_{15}	40%

TABLE C.3 – Participation des graphlets signaux faibles dans les snapshots de l'étude.

Nous avons lancé des requêtes *Cypher* sur la base de données *Neo4j*, pour étudier plusieurs instances particulières du graphlet G_{21} . Il s'agit des snapshots débutant à 17 heures, pour toutes les valeurs de Δt . La figure C.2 montre trois instances du G_{21} pour Δt égale à 10, 15 et 30 minutes. Nous retrouvons les mêmes utilisateurs occupant les mêmes positions quelque soit la

valeur prise par Δt . Dans ces instances, l'orbite O_{51} est occupée par deux fans de la série GOT (le compte @07h04pm est actuellement suspendu sur Twitter). Un compte fan de la série occupe l'orbite O_{52} , et finalement l'orbite centrale O_{53} est occupée par un fan de GOT et par @hlgomes1 qui est un commentateur de la série Brésilienne BBB (Big Brother Brasil)¹.

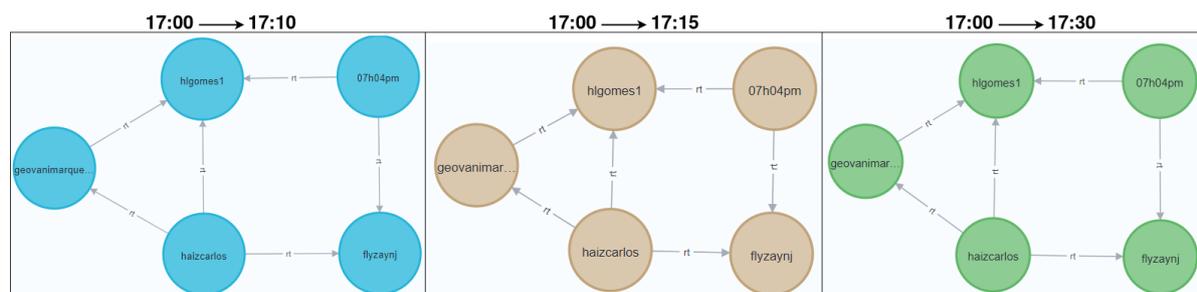


FIGURE C.2 – Appartenance des utilisateurs aux instances du G_{21} signal faible, pour trois valeurs de Δt .

Pour Δt égale à 40 minutes, nous avons retrouvé le compte @flyzaynj dans la même position du graphlet G_{21} (orbite O_{51}), mais avec d'autres utilisateurs que ceux trouvés ci-dessus. L'orbite O_{53} est occupée par @JaliniaAraujo, passionnée de séries télévisées et fan surtout de Daenerys, qui est un personnage principal de GOT. L'autre orbite est occupée aussi par un fan. Pour Δt égale à 50 et 60 minutes, nous avons retrouvé les mêmes utilisateurs apparaissant ensemble dans les snapshots de 10, 15 et 30 minutes. Cela signifie que les relations directes entre ces utilisateurs sont retrouvées quelque soit la durée des snapshots. Globalement, nous avons remarqué que les utilisateurs trouvés dans les orbites du graphlet G_{21} sont tous situés dans différentes régions du Brésil (grâce à l'option de localisation sur leur profil Twitter), et si ce n'est pas le cas, leurs tweets sont postés en portugais, la langue la plus parlée au Brésil.

D'après la série d'expérimentations réalisées sur le premier épisode de GOT, nous avons remarqué que le choix d'une durée comprise entre 10 et 30 minutes, fournit au moins 80% des graphlets signaux faibles. Mais étant donné la taille volumineuse des graphes à partir d'une durée égale à 30 minutes, le temps de réponse de l'algorithme augmentera et l'expert métier se retrouvera face à un grand volume d'information à analyser et à interpréter. Nous avons alors choisi pour ce jeu de données, une durée Δt égale à 10 minutes, qui renvoie plusieurs types de graphlets signaux faibles y compris les types complexes, avec un temps acceptable pour l'expert pour effectuer une analyse efficace et prendre une décision pertinente.

1. BBB est la version brésilienne de l'émission de télé-réalité franchisée *Big Brother*, qui documente des situations réelles non scénarisées entre des personnes inconnues plutôt qu'avec des acteurs professionnels.

ANNEXE C : *Expérimentations sur l'impact du changement de la taille des snapshots*

EXPÉRIMENTATION SUR L'ANNONCE DE LA POLITIQUE AGRICOLE COMMUNE (PAC)

Nous décrivons dans cette annexe une étude que nous avons menée sur des tweets publiés dans le cadre de l'annonce de la loi sur la Politique Agricole Commune (PAC). Les tweets ont été collectés entre minuit le 17 octobre 2020 et minuit le 20 octobre pour un total de 4 679 tweets, dont 807 sont originaux et 3 872 correspondent à des mentions et des retweets. Dans cette expérience, nous nous intéressons aux mentions et aux retweets publiés, les propriétés topologiques du graphe construit à partir de cet ensemble de données sont indiquées dans le tableau D.1.

$ V $	$ E $	d_{mean}	Δ	D
2 535	7 897	6.2303	402	0.0024

TABLE D.1 – Caractéristiques topologiques du graphe étudié. $|V|$ est le nombre de nœuds, $|E|$ le nombre de liens, d_{mean} le degré moyen d'un nœud, Δ le degré maximum et D sa densité.

Détection des signaux faibles L'évènement qui nous intéresse est la prise de décision en faveur de la PAC par le Conseil Européen annoncée le 20 octobre à midi. Ainsi, nous réalisons l'étude sur les deux jours précédant l'évènement (les 18 et 19 octobre) et le jour de l'évènement avec des snapshots d'une heure.

BEAM a détecté les graphlets G_{15} , G_{18} , G_{21}  et G_{28}  comme signaux faibles.

Confirmation par une méthode statistique, cross-correlation L'utilisation de cette méthode a montré des coefficients remarquables pour certains des graphlets signaux faibles. Par exemple, G_{15} et G_{21} présentent des corrélations positives à +0.7 et +0.6 avec des décalages négatifs de deux et de trois heures avec la série temporelle des interactions respectivement. La figure D.1 illustre la corrélation du graphlet G_{15} . G_{18} montre également une corrélation positive de +0.7 avec un décalage d'une heure.

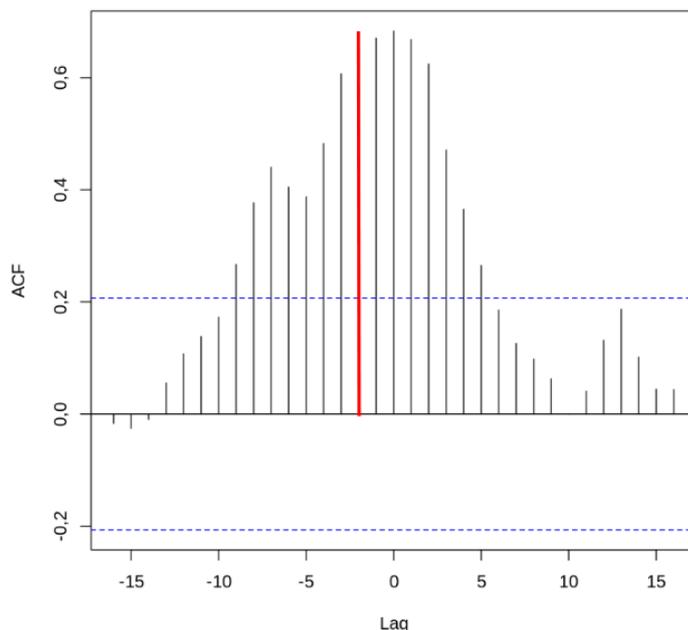
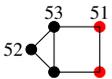


FIGURE D.1 – Corrélogramme du graphlet signal faible G_{15} .

Interprétation des signaux faibles Nous avons étudié quelques comptes associés aux signaux faibles détectés en mettant en évidence leur rôle dans la propagation de l'information sur l'évènement. Le compte @pcanfin, président de la commission de l'environnement du

Parlement Européen, apparaît à 10 heures dans l'orbite O_{51}  du graphlet G_{21} , et à 11

heures dans l'orbite O_{34}  du graphlet G_{15} . Le compte @TheProgressives, représentant le groupe des Socialistes et des Démocrates au Parlement Européen, apparaît à 10 heures dans les orbites de tous les graphlets signaux faibles, et ensuite à 11 heures dans les orbites O_{34} et O_{51} . Ces utilisateurs ont interagi contre la loi quelques heures avant l'annonce de la décision du Conseil, et leurs positions dans les graphlets ci-dessus peuvent révéler leur rôle dans une communauté d'utilisateurs fortement connectés qui partagent les mêmes opinions ou discutent sur les mêmes sujets.

TWEETS ORIGINAUX ANNONÇANT LA VISITE DU PRÉSIDENT MACRON À LUBRIZOL

Cette annexe contient les tweets originaux émis par les utilisateurs avant la visite surprise du Président Macron à Rouen, et présentés dans le tableau 5.4 du chapitre 5. Pour ce faire, nous avons sélectionné l'identifiant de l'utilisateur et celui du tweet émis grâce à la base de données relationnelle. Pour visualiser le contenu original d'un tweet, il suffit de visiter la page officielle de Twitter comme suit : <https://twitter.com/userName/status/tweetId>, où **userName** et **tweetId** sont remplacés par les identifiants de l'utilisateur et du tweet respectivement. Le site Web de Twitter redirige alors automatiquement vers l'URL du tweet.

Les tweets de @CamaradeCharles sont protégés donc nous n'avons pas pu les récupérer, et le deuxième tweet de @ViolaineGargala a été supprimé de son compte.

La figure E.1 montre le tweet de @jeremychatet, son URL est la suivante : <https://twitter.com/jeremychatet/status/1189537500999700481>.

Les deux tweets émis par @Tendanceouest76 sont en figure E.2, et leurs URLs sont les suivantes : <https://twitter.com/Tendanceouest76/status/1189564010255015936> et <https://twitter.com/Tendanceouest76/status/1189574181081493505>.

Le tweet de la journaliste @ViolaineGargala est en figure E.3 et voici son URL sur Twitter : <https://twitter.com/ViolaineGargala/status/1189537795943088128>.

Les trois tweets émis par @paris_normandie sont présents en figure E.4 et se trouvent à partir des liens suivants : https://twitter.com/paris_normandie/status/1189537943423275009, https://twitter.com/paris_normandie/status/1189537981159411713 et https://twitter.com/paris_normandie/status/1189580936532369410.

La figure E.5 illustre les deux tweets de @76actu ayant les URLs suivants : <https://twitter.com/76actu/status/1189565871414489090> et <https://twitter.com/76actu/status/1189579739826180103>.

Finalement, les tweets émis par le journaliste @JeromeMoriniere sont illustrés en figure E.6, et voici leurs URLs : <https://twitter.com/JeromeMoriniere/status/1189578909521797121> et <https://twitter.com/JeromeMoriniere/status/1189581504772526080>.

ANNEXE E : Tweets originaux annonçant la visite du Président Macron à Lubrizol



FIGURE E.1 – Tweet émis par @jeremychatet.



FIGURE E.2 – Tweets émis par @Tendanceouest76.



FIGURE E.3 – Tweet émis par @ViolaineGargala.



FIGURE E.4 – Tweets émis par @paris_normandie.



FIGURE E.5 – Tweets émis par @76actu.

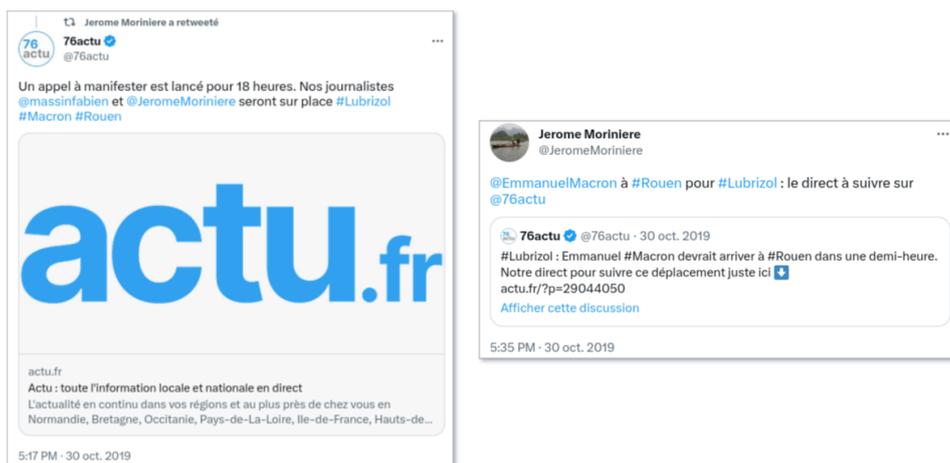


FIGURE E.6 – Tweets émis par @JeromeMoriniere.

ANNEXE E : *Tweets originaux annonçant la visite du Président Macron à Lubrizol*

RÉSUMÉ SOUS FORME ALGORITHMIQUE DE LA DÉTECTION DES SIGNAUX FAIBLES

L'algorithme 1 présente les démarches suivies dans l'étape de détection des signaux faibles. En partant du corpus de données défini pour l'étude, celui-ci est divisé en s snapshots de même durée. Des tableaux de 30 éléments sont initialisés pour calculer les vitesses et les accélérations dans le snapshot S^i , et stocker les résultats i.e. les graphlets précurseurs dans candidats et les graphlets signaux faibles dans WS (lignes 2 et 3).

Pour chaque snapshot S^i , chaque type de graphlet G_x , $\forall x \in \{0, \dots, 29\}$ est énuméré à l'aide de l'algorithme Orca. Le résultat d'Orca est stocké dans un tableau de 30 éléments G^i où $G^i[x]$ contient le nombre de graphlet G_x dans le snapshot S^i (ligne 4). Les valeurs obtenues sont ensuite normalisées en utilisant une procédure inspirée des travaux de Kannelakis, détaillée dans l'algorithme 2.

À partir des valeurs normalisées, nous calculons les vitesses et les accélérations des graphlets, que nous utilisons comme mesures pour quantifier la diffusion et l'amplification des signaux. Sur la base de ces critères, les graphlets dont les valeurs de vitesse ou d'accélération sont supérieures au paramètre d'entrée k , sont sélectionnés comme graphlets précurseurs (lignes 6 à 12). Pour qualifier les graphlets de signaux faibles, nous estimons le critère de rareté. Il s'agit ici de quantifier la contribution de chaque graphlet à l'évolution globale de tous les graphlets à l'aide d'un ratio, afin de confirmer s'il s'agit ou non de signaux faibles (ligne 13). Cette fonction, détaillée dans l'algorithme 3, retourne la liste des graphlets qualifiés de signaux faibles.

Pour chaque graphlet, nous calculons les ratios de contribution à un snapshot S^i (lignes 3 à 5), et classons les valeurs résultantes par ordre croissant. Les top k graphlets classés en premier sont choisis et stockés dans une liste (ligne 7). Ensuite, nous appliquons les règles de vérification suivantes qui visent à qualifier les graphlets de signaux faibles (lignes 9 à 13). Si le graphlet est précurseur (candidat) et se trouve parmi les top k , alors il est classé avec les vrais positifs et ajouté à la liste des signaux faibles. Si le graphlet est précurseur (candidat) mais ne se trouve pas parmi les top k , il est classé parmi les faux positifs ou les fausses alertes. La même vérification est faite pour les deux catégories restantes.

Algorithm 1: Détection des signaux faibles dans un snapshot S^i

Inputs : S^i :ième snapshot, $\overline{G^{i-1}}$ nombres normalisés des graphlets au snapshot S^{i-1} ,
 $\overline{V^{i-1}}$ vitesses normalisées au snapshot S^{i-1} , k

Output: Signaux faibles détectés WS

```

1 begin
2    $WS \leftarrow \{\}$   $candidats \leftarrow \{\}$ 
3    $\overline{V^i} \leftarrow [\text{NULL}]$ ;  $\overline{A^i} \leftarrow [\text{NULL}]$ ;
4    $G^i \leftarrow \text{Orca}(S^i, 5)$ ; /* Énumération des graphlets jusqu'à 5
   nœuds */
5   for  $x$  allant de 0 à 29 par pas de 1, pour chaque type de graphlet  $G_x$  do
6      $\overline{G^i[x]} \leftarrow \text{Normalisation}(x, i, G^i)$ ;
7      $\overline{V^i[x]} \leftarrow \overline{G^i[x]} - \overline{G^{i-1}[x]}$ ; /* Calcul de vitesse pour un
   graphlet de type  $G_x$  */
8      $\overline{A^i[x]} \leftarrow \overline{V^i[x]} - \overline{V^{i-1}[x]}$ ; /* Calcul d'accélération pour un
   graphlet de type  $G_x$  */
9     if  $\overline{V^i[x]} \geq k$  Or  $\overline{A^i[x]} \geq k$  then
10    |  $candidats \leftarrow candidats \cup G_x$ ;
11    end
12  end
13   $WS \leftarrow \text{Qualification}(G^i, candidats, k)$ ;
14  return  $WS$ 
15 end

```

Algorithm 2: Fonction de normalisation

Inputs : Type de graphlet G_x , nombre de snapshots s , G^i pour les s snapshots

Output: Valeur normalisée

```

1 begin
2   Calculer la moyenne du graphlet  $G_x$  sur  $s$  snapshots :  $\mu(G_x)$ 
3   Calculer la déviation standard du graphlet  $G_x$  :  $\sigma(G_x)$ 
4    $Res \leftarrow \frac{G^i[x] - \mu(G_x)}{\sigma(G_x)}$ ; /* Normalisation */
5   return  $Res$ 
6 end

```

Algorithm 3: Fonction de qualification

Inputs : G^i au snapshot S^i , candidats, k **Output:** Liste des signaux faibles

```
1 begin
2    $Res \leftarrow \{\}$ ;  $arr_R \leftarrow \{\}$   $R \leftarrow NULL$ ;           /* Initialisation */
3   for  $x$  allant de 0 à 29 par pas de 1, pour chaque type de graphlet  $G_x$  do
4      $R[x] \leftarrow \frac{G^i[x]}{\sum_{x=0}^{29} G^i[x]}$ ;   /* Calcul du ratio de contribution */
5   end
6   while  $Rank(R[x]) \leq k$  do
7      $arr_R \leftarrow arr_R \cup G_x$ ;           /* Choisir les top  $k$  graphlets */
8   end
9   if  $G_x \in arr_R$  And  $G_x \in candidats$  then
10     $Res \leftarrow Res \cup G_x$                  /* Vrais positifs */
11  else if  $G_x \in arr_R$  And  $G_x \notin candidats$  then
12     $Res \leftarrow Res \cup G_x$                  /* Faux négatifs */
13  end
14  return  $Res$ 
15 end
```

ANNEXE F : Résumé sous forme algorithmique de la détection des signaux faibles

EXPÉRIMENTATIONS SUR L'UTILISATION DE LA SVD ET DU CLUSTERING POUR DÉTECTER DES VARIABLES LATENTES

Nous décrivons dans cette annexe des expériences menées sur deux jeux de données décrits dans le chapitre 5, sur lesquels nous avons utilisé la SVD avec le clustering pour détecter des variables latentes.

G.1 Jeu de données Lubrizol

Sur le graphe des mentions de Lubrizol (voir section 5.1.1), nous avons construit trois matrices :

- A Snapshot \times Graphlet : Cette matrice correspond au nombre des trente graphlets calculés globalement par snapshot durant la journée d'étude (vingt-deux snapshots) ;
- B Utilisateur \times Graphlet : Cette matrice représente le nombre d'apparition des utilisateurs dans les 30 graphlets pour un snapshot que nous avons choisi, celui de 16 heures 30 minutes (nous nous sommes concentrés sur six utilisateurs parmi cinquante) ;
- C Utilisateur \times Orbite : Cette matrice représente le nombre d'apparition des utilisateurs dans les 73 orbites des graphlets pour le snapshot de 16 heures 30 minutes.

En appliquant K-means sur la matrice A , avec $K = 3$, les vingt-deux snapshots sont répartis sur trois clusters comme suit :

- un cluster contenant le snapshot de 17 heures 30 minutes ;
- un cluster contenant le snapshot de 18 heures ;
- un cluster contenant les vingt autres snapshots.

Le dernier cluster contient les snapshots avant la visite surprise du Président Macron, les deux autres clusters contiennent les snapshots qui correspondent au moment où le Président Macron se trouvait à Rouen. En revenant à la série temporelle des mentions, nous pouvons conclure que ce résultat est cohérent car la courbe a la même forme pour tous les snapshots avant 17 heures 30 minutes, mais commence à monter à partir de 17 heures 30 minutes pour atteindre

ANNEXE G : Expérimentations sur l'utilisation de la SVD et du clustering pour détecter des variables latentes

son pic à 18 heures. En appliquant K-means sur les colonnes de la matrice A , nous avons remarqué que les graphlets signaux faibles détectés par BEAM sont regroupés dans un même cluster. En plus, nous avons trouvé une cohérence entre ces résultats et le calcul de similarité effectué sur les mêmes matrices.

Sur la deuxième matrice B et avec un $K = 5$, les utilisateurs sont répartis sur cinq clusters. Le tableau G.1 est un extrait de trois des cinq clusters, où nous trouvons par exemple le compte @EmmanuelMacron tout seul dans le troisième cluster. Ceci est évident puisqu'après l'étude des instances des graphlets, nous trouvons ce compte toujours en position centrale.

Numéro cluster	Utilisateurs
3	@EmmanuelMacron
4	@76actu, @chris230686, @Iceman76000, @JeromeMoriniere
5	@agnesbuzyn, @manon_leterq, @massinfabien, @Rouen

TABLE G.1 – Trois clusters d'utilisateurs parmi les cinq clusters obtenus avec l'algorithme K-means.

Un autre utilisateur @76actu, se trouvant dans le quatrième cluster, appartient aussi aux orbites des graphlets G_{10} et G_{11} signaux faibles détectés par BEAM. La figure G.1 confirme que cet utilisateur se trouve avec @Iceman76000 dans une même instance des deux graphlets (nœuds entourés en orange et en jaune). En consultant une autre instance du G_{10} , @JeromeMoriniere occupe la même position que @76actu (orbite O_{20}). Ceci confirme la similarité entre ces deux utilisateurs.



FIGURE G.1 – Différentes positions de @76actu dans deux instances des graphlets G_{10} et G_{11} signaux faibles.

En appliquant K-means sur la matrice C , nous avons confirmé les résultats obtenus avec la matrice B . Les utilisateurs se trouvant dans un même cluster, appartiennent aux orbites des graphlets signaux faibles.

G.2 Jeu de données GOT

Dans ce jeu de données, la SVD a été utilisée avec la relation retweet (étude détaillée en section 5.3), pour le snapshot de 17 heures du premier épisode. La décomposition est réalisée sur les matrices B et C décrites ci-dessus, avec un nombre d'utilisateurs égal à 8 714. Avec $K = 4$,

K-means a réparti les utilisateurs dans quatre clusters de tailles égales à 6 700, 499, 82 et 1 433. La figure G.2 est une visualisation de cette répartition.

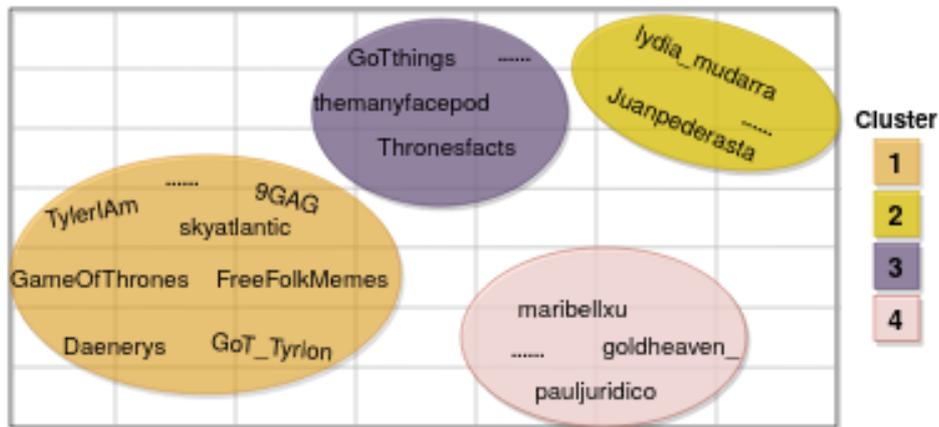


FIGURE G.2 – Visualisation des quatre clusters d'utilisateurs dans le snapshot de 17 heures du premier épisode.

Nous avons remarqué que les utilisateurs trouvés dans le premier cluster appartiennent aux signaux faibles détectés par BEAM. Nous constatons que ces utilisateurs jouent des rôles similaires pour critiquer GOT, ou bien pour inciter les spectateurs à regarder la dernière saison de la série.

Nous avons également appliqué cette méthode sur le jeu de données représentant les interactions dans une école primaire (voir section 5.2.1), avec pour objectif de trier le signal en étudiant des phénomènes récurrents comme les récréations ou les pauses de midi. La matrice décomposée correspond au nombre de graphlets par snapshot de jour d'école. Cette étude nous a montré que les snapshots des pauses/récréations ne se trouvaient pas dans le même cluster que les snapshots des heures de classes. Ceci est une vérité de terrain puisqu'il est rare que des élèves de classes différentes jouent ensemble (ou se mélangent) lors des récréations, donc l'absence des signaux faibles dans ce jeu est confirmée.

ANNEXE G : *Expérimentations sur l'utilisation de la SVD et du clustering pour détecter des variables latentes*

PUBLICATIONS SCIENTIFIQUES

Les contributions proposées dans cette thèse ont abouti aux publications scientifiques suivantes :

1. Hiba Abou Jamra, Marinette Savonnet, Éric Leclercq. **Identification of Weak Signals in a Temporal Graph of Social Interactions**. In : Proceedings of the 26th International Database Engineered Applications Symposium (IDEAS). 2022, pp. 34-42.
2. Hiba Abou Jamra, Marinette Savonnet, Éric Leclercq. **BEAM : A Network Topology Framework to Detect Weak Signals**. In : International Journal of Advanced Computer Science and Applications (IJACSA), Vol 13, no. 4. 2022, pp. 16-27.
3. Hiba Abou Jamra, Marinette Savonnet, Éric Leclercq. **Détection de signaux faibles : Une méthode basée sur les graphlets**. In : INformatique des ORganisations et Systèmes d'Information et de Décision 2022 (*article publié à l'international*).
4. Hiba Abou Jamra, Landy Andriamampianina, Cécile Cayèré, Yohann Chasseray et Pierre-Emmanuel Arduin. **INFORSID 2020 Forum Jeunes Chercheuses Jeunes Chercheurs**. In : Revue ouverte d'ingénierie des systèmes d'information 2022.
5. Hiba Abou Jamra, Marinette Savonnet, Éric Leclercq. **Detection of Event Precursors in Social Networks : A Graphlet-Based Method**. In : Proceedings of the 15th International Conference on Research Challenges in Information Science (RCIS). Springer, Cham, 2021, pp. 205–220.
6. Hiba Abou Jamra, Marinette Savonnet, Éric Leclercq. **The Role of Graphlets as Event Precursors in Social Networks**. In : French Regional Conference on Complex Systems (FRCCS). Dijon, May 2021.
7. Hiba Abou Jamra, Marinette Savonnet, Éric Leclercq. **Détection de précurseurs d'évènements basés sur les motifs dans les réseaux sociaux**. In : 21ème conférence Extraction et Gestion des Connaissances (EGC). 2021, pp. 215-226 ;
8. Hiba Abou Jamra, Marinette Savonnet, Éric Leclercq. **Analyse des discours sur Twitter dans une situation de crise**. In : INformatique des ORganisations et des Systèmes d'Information et de Décision (INFORSID) (2020) : pp. 1-16.
9. Hiba Abou Jamra. **Analyse de la structure latente des réseaux sociaux par graphlets**. In : Actes du Forum jeunes chercheuses jeunes chercheurs d'INFORSID 2020, pp. 5-8.

En plus des publications scientifiques, j'ai eu d'autres contributions :

Projet Cocktail Participation aux comités de pilotage une fois par mois et rédaction du livrable « Conception des scénarios d'analyses – Analyses des scénarios de deuxième niveau » décrivant les algorithmes utilisés dans le projet.

Comités d'organisation de conférence Conférence FRCCS (French Regional Conference on Complex Systems) qui s'est tenue en ligne en 2021

Conférence INFORSID (INFormatique des ORganisations et des Systèmes d'Information et de Décision) qui s'est tenue en présentiel en 2022

BIBLIOGRAPHIE

- [1] J. L. Ackley, T. G. Puranik, and D. Mavris. A Supervised Learning Approach for Safety Event Precursor Identification in Commercial Aviation. In *AIAA AVIATION 2020 FORUM*, 2020.
- [2] A. Adil, V. Kumar, A. T. Jan, and M. Asger. Single-cell transcriptomics : current methods and challenges in data acquisition and analysis. *Frontiers in Neuroscience*, 15 :591122, 2021.
- [3] L. M. Aiello, G. Petkos, C. Martin, D. Corney, S. Papadopoulos, R. Skraba, A. Göker, I. Kompatsiaris, and A. Jaimes. Sensing trending topics in Twitter. *IEEE Transactions on Multimedia*, 15(6) :1268–1282, 2013.
- [4] A. Alanezi. Using social networks in school crisis management : evidence from middle school principals in Kuwait. *Education 3-13*, 49(8) :935–944, 2021.
- [5] J. Altmann. Observational study of behavior : sampling methods. *Behaviour*, 49(3-4) :227–266, 1974.
- [6] V. Amrhein, S. Greenland, and B. McShane. Scientists rise up against statistical significance. *Nature*, 567(7748) :305–307, 2019.
- [7] S. Andrews, B. Brewster, and T. Day. Organised crime and social media : a system for detecting, corroborating and visualising weak signals of organised crime online. *Security Informatics*, 7 :1–21, 2018.
- [8] H. I. Ansoff. Managing strategic surprise by response to weak signals. *California management review*, 18(2) :21–33, 1975.
- [9] H. I. Ansoff and E. J. McDonnell. *Implanting strategic management*, 1990.
- [10] D. Aparício. *Network Comparison and Node Ranking in Complex Networks*. PhD thesis, Universidades do Minho, Aveiro e Porto, 2018.
- [11] D. Aparício, P. Ribeiro, and F. Silva. Extending the Applicability of Graphlets to Directed Networks. *IEEE/ACM Trans. Comput. Biol. Bioinformatics*, 14(6) :1302–1315, nov 2017.
- [12] D. Aparício, P. Ribeiro, and F. Silva. Graphlet-orbit transitions (got) : A fingerprint for temporal network comparison. *PLOS ONE*, 13(10) :1–24, 10 2018.
- [13] E. Aramaki, S. Maskawa, and M. Morita. Twitter catches the flu : detecting influenza epidemics using Twitter. In *Proceedings of the 2011 Conference on empirical methods in natural language processing*, pages 1568–1576, 2011.

- [14] S. Asur and B. A. Huberman. Predicting the Future with Social Media. In *IEEE/WIC/ACM international conference on web intelligence and intelligent agent technology*, volume 1, pages 492–499, 2010.
- [15] L. Azaza. *Une approche pour estimer l'influence dans les réseaux complexes : application au réseau social Twitter*. PhD thesis, Université Bourgogne Franche-Comté, 2019. Thèse de doctorat.
- [16] A. Baas, F. Hung, H. Sha, M. A. Hasan, and G. Mohler. Predicting Virality on Networks Using Local Graphlet Frequency Distribution. In *IEEE International Conference on Big Data (Big Data)*, pages 2475–2482, 2018.
- [17] M. Baiesi. Scaling and precursor motifs in earthquake networks. *Physica A : Statistical Mechanics and its Applications*, 360(2) :534–542, 2006.
- [18] A.-L. Barabási. Network science. *Philosophical Transactions of the Royal Society A : Mathematical, Physical and Engineering Sciences*, 371(1987) :20120375, 2013.
- [19] C. Bisson and Ö. Diner. Strategic Early Warning System for the French milk market : A graph theoretical approach to foresee volatility. *Futures*, 87, 01 2017.
- [20] C. Bisson and F. Gurpinar. A bayesian approach to developing a strategic early warning system for the french milk market. *Journal of Intelligence Studies in Business*, 7 :25–34, 12 2017.
- [21] S. Blanco and N. Lesca. From weak signals to anticipative information : learning from the implementation of an information selection method. In *Proceedings of the International Conference In Search of Time (Isida)*, pages 197–210. Citeseer, 2003.
- [22] D. M. Blei and J. D. Lafferty. Dynamic Topic Models. In *Proceedings of the 23rd International Conference on Machine Learning, ICML '06*, page 113–120, New York, NY, USA, 2006. Association for Computing Machinery.
- [23] D. M. Blei, A. Y. Ng, and M. I. Jordan. Latent Dirichlet Allocation. *J. Mach. Learn. Res.*, 3 :993–1022, mar 2003.
- [24] M.-H. Bleu Laine, T. G. Puranik, D. N. Mavris, and B. Matthews. Multiclass Multiple-Instance Learning for Predicting Precursors to Aviation Safety Events. *Journal of Aerospace Information Systems*, 19(1) :22–36, 2022.
- [25] F. Blondel, S. Edouard, and M. El Mabrouki. Quelle articulation entre intelligence économique et knowledge management au sein de l'entreprise? *Vie & sciences de l'entreprise*, 174-175 :158–177, 2007.
- [26] V. Blondel, J.-L. Guillaume, R. Lambiotte, and E. Lefebvre. Fast unfolding of communities in large networks. *Journal of statistical mechanics : theory and experiment*, 2008(10) :P10008, 2008.
- [27] A. Bouktaib and A. Fennan. A Framework for Weak Signal Detection in Competitive Intelligence using Semantic Clustering Algorithms. *International Journal of Advanced Computer Science and Applications(IJACSA)*, 12(12), 2021.
- [28] M. M. Breunig, H.-P. Kriegel, R. T. Ng, and J. Sander. LOF : identifying density-based local outliers. In *ACM sigmod record*, volume 29, pages 93–104. ACM, 2000.
- [29] B. Brewster, S. Andrews, S. Polovina, L. Hirsch, and B. Akhgar. Environmental Scanning and Knowledge Representation for the Detection of Organised Crime Threats. In *21th International Conference on Conceptual Structures (ICCS)*, 07 2014.

BIBLIOGRAPHIE

- [30] S. Brin and L. Page. The anatomy of a large-scale hypertextual web search engine. *Computer networks and ISDN systems*, 30(1-7) :107–117, 1998.
- [31] S. Brion. Le concept de vigilance une réponse au dilemme entre rapidité et fiabilité des projets. *Revue française de gestion*, 156 :105–128, 2005.
- [32] A. Brizon and J. Wybo. The life cycle of weak signals related to safety. *International Journal of Emergency Management*, 6, 01 2009.
- [33] P. J. Brockwell and R. A. Davis. *Time series : theory and methods*. Springer science & business media, 2009.
- [34] J. Brynielsson, A. Horndahl, F. Johansson, L. Kaati, C. Mårtenson, and P. Svenson. Analysis of Weak Signals for Detecting Lone Wolf Terrorists. In *European Intelligence and Security Informatics Conference*, pages 197–204, 2012.
- [35] J. Brynielsson, A. Horndahl, F. Johansson, L. Kaati, C. Mårtenson, and P. Svenson. Harvesting and analysis of weak signals for detecting lone wolf terrorists. *Security Informatics*, 2(1) :1–15, 2013.
- [36] S. Castaldi, M. Maffeo, B. A. Riviuccio, M. Zignani, G. Manzi, F. Nicolussi, S. Salini, A. Micheletti, S. Gaito, and E. Biganzoli. Monitoring emergency calls and social networks for COVID-19 surveillance. To learn for the future : the outbreak experience of the Lombardia region in Italy. *Acta Bio Medica : Atenei Parmensis*, 91(9-S) :29, 2020.
- [37] R. Charbey and C. Prieur. Stars, holes, or paths across your Facebook friends : A graphlet-based characterization of many networks. *Network Science*, 7(4) :476–497, 2019.
- [38] C. Charitonidis, A. Rashid, and P. J. Taylor. Weak signals as predictors of real-world phenomena in social media. In *IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)*, pages 864–871, 2015.
- [39] C. Chatfield. *The analysis of time series : an introduction*. Chapman and hall/CRC, 2003.
- [40] Y. Chi, B. L. Tseng, and J. Tatemura. Eigen-trend : trend analysis in the blogosphere based on singular value decompositions. In *Proceedings of the 15th ACM international conference on Information and knowledge management*, pages 68–77, 2006.
- [41] B. Coffman. Weak signal research, part I : Introduction. *Journal of Transition Management*, 2(1), 1997.
- [42] A.-C. Crémieux. *Gouverner l'imprévisible : Pandémie grippale, SRAS, crises sanitaires*. Tec & Doc Lavoisier, 2009.
- [43] W. D. Cullen and L. Cullen. *The Ladbroke Grove Rail Inquiry : Part 1 Report*. HSE books London, 2001.
- [44] T. Davies and E. Marchione. Event networks and the identification of crime pattern motifs. *PloS one*, 10(11) :e0143638, 2015.
- [45] F. C. De Almeida and H. Lesca. Collective intelligence process to interpret weak signals and early warnings. *Journal of Intelligence Studies in Business*, 9(2), nov 2019.
- [46] T. Derrick and J. Thomas. Time series analysis : the cross-correlation function. *Innovative Analyses of Human Movement*, pages 189–205, 2004.

- [47] P. Dewan, A. Suri, V. Bharadhwaj, A. Mithal, and P. Kumaraguru. Towards understanding crisis events on online social networks through pictures. In *Proceedings of the 2017 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining 2017*, pages 439–446, 2017.
- [48] T. Dimitrova, K. Petrovski, and L. Kocarev. Graphlets in Multiplex Networks. *Scientific Reports*, 10(1), 2020.
- [49] R. Djiroun, K. Boukhalfa, and Z. Alimazighi. Designing data cubes in olap systems : a decision makers’ requirements-based approach. *Cluster Computing*, 22 :783–803, 2019.
- [50] F. Dotsika and A. Watkins. Identifying potentially disruptive trends by means of keyword network analysis. *Technological Forecasting and Social Change*, 119 :114–127, 2017.
- [51] C. Duffau, C. Camillieri, and M. Blay-Fornarino. Improving confidence in experimental systems through automated construction of argumentation diagrams. In *19th International Conference on Enterprise Information Systems (ICEIS)*, 2017.
- [52] A. Ebadi, A. Auger, and Y. Gauthier. Detecting Emerging Technologies and their Evolution using Deep Learning and Weak Signal Analysis, 2022.
- [53] C. Eckart and G. Young. The approximation of one matrix by another of lower rank. *Psychometrika*, 1(3) :211–218, 1936.
- [54] R. Eckhoff, M. Markus, M. Lassning, and S. Schön. No Outstanding Surprises when Using Social Media as Source for Weak Signals? In *The Ninth International Conference on Digital Society (ICDE)*, 2015.
- [55] M. El Akrouchi, H. Benbrahim, and I. Kassou. Monitoring Early Warning Signs Evolution Through Time. In *3rd International Conference on Algorithms, Computing and Artificial Intelligence*, ACAI, New York, NY, USA, 2020. Association for Computing Machinery.
- [56] M. El Akrouchi, H. Benbrahim, and I. Kassou. End-to-end LDA-based automatic weak signal detection in web news. *Knowledge-Based Systems*, 212 :106650, 2021.
- [57] M. El Akrouchi, H. Benbrahim, and I. Kassou. Review on adopting concept extraction in weak signals detection in competitive intelligence. In *The 7th Annual International Conference on Arab Women in Computing in Conjunction with the 2nd Forum of Women in Research*, pages 1–8, 2021.
- [58] Escande, Jean and Le Coze, Jean-Christophe and Proust, Christophe and Marlair, Guy. Signaux faibles : un concept pertinent? *SGFP*, 10 2013.
- [59] M. Fedoryszak, B. Frederick, V. Rajaram, and C. Zhong. Real-time event detection on social data streams. In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pages 2774–2782, 2019.
- [60] D. Floros, T. Liu, N. Pitsianis, and X. Sun. Using Graphlet Spectrograms for Temporal Pattern Analysis of Virus-Research Collaboration Networks. In *IEEE High Performance Extreme Computing Conference (HPEC)*, pages 1–7. IEEE, 2020.
- [61] M. Friendly. *SAS system for statistical graphics*. SAS Publishing, 1991.
- [62] M. Friendly. Corrgrams : Exploratory displays for correlation matrices. *The American Statistician*, 56(4) :316–324, 2002.

BIBLIOGRAPHIE

- [63] K. R. Gabriel. The biplot graphic display of matrices with application to principal component analysis. *Biometrika*, 58(3) :453–467, 1971.
- [64] B. Ganter and R. Wille. *Formal Concept Analysis - Mathematical Foundations*. Springer, 1999.
- [65] P. I. Garcia-Nunes and A. E. A. da Silva. Using a conceptual system for weak signals classification to detect threats and opportunities from web. *Futures*, 107 :1–16, 2019.
- [66] H. W. Gehman. *Columbia accident investigation board report*, volume 2. Columbia Accident Investigation Board, 2003.
- [67] V. Gelardi, J. Godard, D. Paleressompouille, N. Claidière, and A. Barrat. Measuring social networks in primates : wearable sensors versus direct observations. *Proceedings of the Royal Society A*, 476(2236) :20190737, 2020.
- [68] V. Gemmetto, A. Barrat, and C. Cattuto. Mitigation of infectious disease at school : targeted class closure vs school closure. *BMC infectious diseases*, 14(1) :695, Dec. 2014.
- [69] D. Georgiadis and M. Raubal. An interdisciplinary review on weak signal detection. *Future Resilient Systems Working Paper*, 2020.
- [70] A. Gillet. *Modélisation et développement d’un observatoire générique pour la collecte et l’analyse de données massives*. PhD thesis, Université de Bourgogne, 2021.
- [71] M. Godet. *From anticipation to action : a handbook of strategic prospective*. UNESCO publishing, 1994.
- [72] D. Q. Goldin and P. C. Kanellakis. On similarity queries for time-series data : constraint specification and implementation. In *International Conference on Principles and Practice of Constraint Programming*, pages 137–153. Springer, 1995.
- [73] J. Gray, S. Chaudhuri, A. Bosworth, A. Layman, D. Reichart, M. Venkatrao, F. Pellow, and H. Pirahesh. Data cube : A relational aggregation operator generalizing group-by, cross-tab, and sub-totals. *Data mining and knowledge discovery*, 1 :29–53, 1997.
- [74] I. Griol-Barres, S. Milla, A. Cebrián, H. Fan, and J. Millet. Detecting Weak Signals of the Future : A System Implementation Based on Text Mining and Natural Language Processing. *Sustainability*, 12(19), 2020.
- [75] I. Griol-Barres, S. Milla, and J. Millet-Roig. System Implementation for the Detection of Weak Signals of the Future in Heterogeneous Documents by Text Mining and Natural Language Processing Techniques. In *ICAART*, 2019.
- [76] E. Guillaume. Prise en compte des signaux faibles dans le management de la sécurité : diagnostic sur une raffinerie et un site métallurgique. In *Équipes du programme REX FonCSI. Facteurs socio-culturels du REX : Sept études de terrain, Les Cahiers de la Sécurité Industrielle-Le retour d’expérience*, pages 51–70, 2008.
- [77] T. Gutsche. *Automatic Weak Signal Detection and Forecasting*. PhD thesis, Université de Twente, Pays-Bas, 2018.
- [78] D. C. Hambrick and P. A. Mason. Upper Echelons : The Organization as a Reflection of Its Top Managers. *Academy of Management Review*, 9(2) :193–206, 1984.
- [79] J. Han, M. Kamber, and J. Pei. Getting to know your data. In J. Han, M. Kamber, and J. Pei, editors, *Data Mining (Third Edition)*, The Morgan Kaufmann Series in Data

- Management Systems, pages 39–82. Morgan Kaufmann, Boston, third edition edition, 2012.
- [80] D. Harrington, R. B. D’Agostino, C. Gatsonis, J. W. Hogan, D. J. Hunter, S.-L. T. Normand, J. M. Drazen, and M. B. Hamel. New Guidelines for Statistical Reporting in the Journal. *New England Journal of Medicine*, 381(3) :285–286, 2019.
- [81] C. Harshaw, R. A. Bridges, M. D. Iannacone, J. W. Reed, and J. R. Goodall. Graph-Prints : Towards a Graph Analytic Method for Network Anomaly Detection. *Proceedings of the 11th Annual Cyber and Information Security Research Conference*, 2016.
- [82] E. Hiltunen. The future sign and its three dimensions. *Futures*, 40(3) :247–260, 2008.
- [83] E. Hiltunen. *Weak Signals in Organizational Futures Learning*. PhD thesis, Helsinki School of Economics, 2010.
- [84] L. Hjorth and K.-h. Y. Kim. The mourning after : A case study of social media in the 3.11 earthquake disaster in Japan. *Television & New Media*, 12(6) :552–559, 2011.
- [85] P. Holme and J. Saramäki. Temporal networks. *Physics Reports*, 519(3) :97–125, Oct 2012.
- [86] A. H. Hossny, T. Moschuo, G. Osborne, L. Mitchell, and N. Lothian. Enhancing keyword correlation for event detection in social networks using svd and k-means : Twitter case study. *Social Network Analysis and Mining*, 8(1) :1–10, 2018.
- [87] T. Hočevár and J. Demčar. Computation of Graphlet Orbits for Nodes and Edges in Sparse Graphs. *Journal of Statistical Software*, 71, 07 2016.
- [88] T. Hočevár and J. Demšar. A combinatorial approach to graphlet counting. *Bioinformatics*, 30(4) :559–565, 12 2014.
- [89] J. Huang, M. Peng, H. Wang, J. Cao, W. Gao, and X. Zhang. A probabilistic method for emerging topic tracking in microblog stream. *World Wide Web*, 20, 03 2017.
- [90] M. Hubert and M. Debruyne. Minimum covariance determinant. *Wiley Interdisciplinary Reviews : Computational Statistics*, 2 :36 – 43, 01 2010.
- [91] Y. Hulovatyy, H. Chen, and T. Milenković. Exploring the structure and function of temporal networks with dynamic graphlets. *Bioinformatics*, 31(12) :i171–i180, 2015.
- [92] L. Ilmola and O. Kuusi. Filters of weak signals hinder foresight : Monitoring weak signals efficiently in corporate decision-making. *Futures*, 38(8) :908–924, 2006. Organisational Foresight.
- [93] A. Irimia, P. Paul, and R. Gheorghiu. Tacit Knowledge - Weak Signal Detection. In O. Popescu and C. Strapparava, editors, *Proceedings of the Eleventh International Conference on Language Resources and Evaluation (LREC)*, Paris, France, may 2018. European Language Resources Association (ELRA).
- [94] A. Jazayeri and C. C. Yang. Motif discovery algorithms in static and temporal networks : A survey. *Journal of Complex Networks*, 8(4), 12 2020. cnaa031.
- [95] X. Jessie Jeng. Detecting weak signals in high dimensions. *Journal of Multivariate Analysis*, 147 :234–246, 2016.
- [96] J. Jordan. *The four stages of highly effective crisis management : How to manage the media in the digital age*. CRC press, 2011.

BIBLIOGRAPHIE

- [97] K. Juszczyszyn and G. Kołaczek. Motif-based attack detection in network communication graphs. In *IFIP International Conference on Communications and Multimedia Security*, pages 206–213. Springer, 2011.
- [98] N. Kashtan, S. Itzkovitz, R. Milo, and U. Alon. Efficient sampling algorithm for estimating subgraph concentrations and detecting network motifs. *Bioinformatics*, 20(11) :1746–1758, 03 2004.
- [99] V. Kayser and K. Blind. Extending the knowledge base of foresight : The contribution of text mining. *Technological Forecasting and Social Change*, 116 :208–215, 2017.
- [100] S. Khorshidi, M. Al Hasan, G. Mohler, and M. B. Short. The Role of Graphlets in Viral Processes on Networks. *Journal of Nonlinear Science*, 30(5) :2309–2324, 2020.
- [101] D. Khurana, A. Koli, K. Khatter, and S. Singh. Natural language processing : State of the art, current trends and challenges. *Multimedia Tools and Applications*, pages 1–32, 2022.
- [102] H. Kim, S.-J. Ahn, and W.-S. Jung. Horizon scanning in policy research database with a probabilistic topic model. *Technological Forecasting and Social Change*, 146 :588–594, 2019.
- [103] H. Kim, Y. Han, J. Song, and T. M. Song. Application of social big data to identify trends of school bullying forms in south korea. *International journal of environmental research and public health*, 16(14) :2596, 2019.
- [104] J. Kim and C. Lee. Novelty-focused weak signal detection in futuristic data : Assessing the rarity and paradigm unrelatedness of signals. *Technological Forecasting and Social Change*, 120 :59–76, 2017.
- [105] J. Kim, Y. Park, and Y. Lee. A visual scanning of potential disruptive signals for technology roadmapping : investigating keyword cluster, intensity, and relationship in futuristic data. *Technology Analysis & Strategic Management*, 28(10) :1225–1246, 2016.
- [106] S. Kim, Y. il Kwon, Y. il Jeong, S.-B. Choi, J.-K. Park, and S.-W. Hong. NEST : a Model for Detecting Weak Signals of Emerging Trends Using Global Monitoring Expert Network. In *EKAW*, 2010.
- [107] S. Kim, Y.-E. Kim, K.-J. Bae, S.-B. Choi, J.-K. Park, Y.-D. Koo, Y.-W. Park, H. K. Choi, H.-M. Kang, and S.-W. Hong. NEST : A quantitative model for detecting emerging trends using a global monitoring expert network and Bayesian network. *Futures*, 52 :59–73, 2013.
- [108] T. M. Kodinariya and P. R. Makwana. Review on determining number of cluster in k-means clustering. *International Journal*, 1(6) :90–95, 2013.
- [109] T. Kohonen. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43(1) :59–69, jan 1982.
- [110] P. Korvers. Accident precursors : Pro-active identification of safety risks in the chemical process industry. *eLibrary.ru*, 2004.
- [111] V. Kostakos. Temporal graphs. *Physica A : Statistical Mechanics and its Applications*, 388(6) :1007–1023, Mar 2009.
- [112] P. Krigsholm and K. Riekkinen. Applying Text Mining for Identifying Future Signals of Land Administration. *Land*, 8(12), 2019.

- [113] T. Kuosa. Futures signals sense-making framework (FSSF) : A start-up tool to analyse and categorise weak signals, wild cards, drivers, trends and other types of information. *Futures*, 42(1) :42–48, 2010.
- [114] L.-N. Kwon, J.-H. Park, Y.-H. Moon, B. Lee, Y. Shin, and Y.-K. Kim. Weak signal detecting of industry convergence using information of products and services of global listed companies - focusing on growth engine industry in South Korea. *Journal of Open Innovation : Technology, Market, and Complexity*, 4(1), 2018.
- [115] M. Latapy, T. Viard, and C. Magnien. Stream Graphs and Link Streams for the Modeling of Interactions over Time. *CoRR*, abs/1710.04073, 2017.
- [116] H. Lee, S. Madar, S. Sairam, T. G. Puranik, A. P. Payan, M. Kirby, O. J. Pinon, and D. N. Mavris. Critical Parameter Identification for Safety Events in Commercial Aviation Using Machine Learning. *Aerospace*, 7(6), 2020.
- [117] K. Lee, A. Agrawal, and A. Choudhary. Real-time disease surveillance using Twitter data : demonstration on flu and cancer. In *Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining*, pages 1474–1477, 2013.
- [118] Y.-J. Lee and J.-Y. Park. Identification of future signal based on the quantitative and qualitative text mining : a case study on ethical issues in artificial intelligence. *Quality & Quantity : International Journal of Methodology*, 52(2) :653–667, March 2018.
- [119] H. Lesca. Veille stratégique : Passage de la notion de signal faible à la notion de signe d’alerte précoce. In *Colloque VSST*, 2001.
- [120] H. Lesca and N. Lesca. L’enseignement des signaux faibles pour le management de proximité des incidents critiques, signaux faibles, création collective de sens et connaissances tacites. *Revue internationale psychosociologie*, 01 2009.
- [121] H. Lesca and N. Lesca. *Weak Signals for Strategic Intelligence : Anticipation Tool for Managers*. ISTE Ltd., 2011.
- [122] J. Leskovec and J. Mcauley. Learning to discover social circles in ego networks. *Advances in neural information processing systems*, 25, 2012.
- [123] J. Leskovec, M. McGlohon, C. Faloutsos, N. Glance, and M. Hurst. Cascading Behavior in Large Blog Graphs. In *Proceedings of the 2007 SIAM international conference on data mining*, pages 551–556, 2007.
- [124] J. Leskovec, A. Singh, and J. Kleinberg. Patterns of Influence in a Recommendation Network. In W.-K. Ng, M. Kitsuregawa, J. Li, and K. Chang, editors, *Advances in Knowledge Discovery and Data Mining*, pages 380–389. Springer Berlin Heidelberg, 2006.
- [125] X. Li, M. Fan, Y. Zhou, J. Fu, F. Yuan, and L. Huang. Monitoring and forecasting the development trends of nanogenerator technology using citation analysis and text mining. *Nano Energy*, 71 :104636, 2020.
- [126] S. Lloyd. Least squares quantization in pcm. *IEEE transactions on information theory*, 28(2) :129–137, 1982.
- [127] J. T. Lussier and J. Bank. Final Report : Local Structure and Evolution for Cascade Prediction. Technical report, Tech. rep., Stanford University, CA, 2011.

BIBLIOGRAPHIE

- [128] C. Macrae. *Interrogating the unknown : risk analysis and sensemaking in airline safety oversight*. Number 43 in CARR Discussion Papers (DP 43). Centre for Analysis of Risk and Regulation, London School of Economics, 2007.
- [129] A. Magruk. Identification a priori of wild cards in the context of uncertain events in the modern logistics. *Research in Logistics and Production*, 7 :237–246, 2017.
- [130] J. Maitre, M. Ménard, A. Bouju, and G. Chiron. Recherche de signaux faibles dans un contexte d’investigation numérique. In *Conférence Internationale H2PTM-Hypertextes et Hypermédias. Produits, Outils et Méthodes*, pages 200–215, 2019.
- [131] J. Maitre, M. Ménard, G. Chiron, and A. Bouju. Détection de signaux faibles dans des masses de données faiblement structurées. *Recherche d’Information, Document et Web Sémantique*, 3(1), 2019.
- [132] J. Maitre, M. Ménard, G. Chiron, A. Bouju, and N. Sidère. A Meaningful Information Extraction System for Interactive Analysis of Documents. In *International Conference on Document Analysis and Recognition (ICDAR)*, pages 92–99, 2019.
- [133] D. Marcus and Y. Shavitt. RAGE – A rapid graphlet enumerator for large networks. *Computer Networks*, 56(2) :810–819, 2012.
- [134] B. Mazoyer. *Social Media Stories. Event detection in heterogeneous streams of documents applied to the study of information spreading across social and news media*. Theses, Université Paris-Saclay, Aug. 2020.
- [135] A. J. McMinn, Y. Moshfeghi, and J. M. Jose. Building a Large-Scale Corpus for Evaluating Event Detection on Twitter. In *Proceedings of the 22nd ACM international conference on Information & Knowledge Management, CIKM ’13*, page 409–418, New York, NY, USA, 2013. Association for Computing Machinery.
- [136] S. Mendonça, G. Cardoso, and J. Caraça. The strategic strength of weak signal analysis. *Futures*, 44(3) :218–228, 2012.
- [137] O. Mevel. *Du rôle des signaux faibles sur la reconfiguration des processus de la chaîne de valeur de l’organisation : l’exemple d’une centrale d’achats de la grande distribution française*. PhD thesis, Université de Bretagne occidentale-Brest, 2004.
- [138] A. Milinković, S. Milinković, and L. Lazić. A contribution to acceleration of graphlet counting. *INFOTEH-JAHORINA*, 14 :741–745, 2015.
- [139] R. Milo, S. Itzkovitz, N. Kashtan, R. Levitt, S. Shen-Orr, I. Ayzenshtat, M. Sheffer, and U. Alon. Superfamilies of Evolved and Designed Networks. *Science (New York, N.Y.)*, 303 :1538–42, 04 2004.
- [140] R. Milo, S. Shen-Orr, S. Itzkovitz, N. Kashtan, D. Chklovskii, and U. Alon. Network Motifs : Simple Building Blocks of Complex Networks. *Science*, 298(5594) :824–827, Oct. 2002.
- [141] M. Moijanen. Heikot signaalit tulevaisuudentutkimuksessa (weak signals in futures studies). *Futura 22 (2003) : 4*, 2003.
- [142] A. Moreira, T. W. N. Hayashi, G. P. Coelho, and A. E. A. da Silva. A Clustering Method for Weak Signals to Support Anticipative Intelligence. In *International Journal of Artificial Intelligence and Expert Systems (IJAE)*, volume 6, 2015.
- [143] C. Mühlroth and M. Grottke. A systematic literature review of mining weak signals and trends for corporate foresight. *Journal of Business Economics*, 88(5) :643–687, 2018.

- [144] S. V. Nath. Crime Pattern Detection Using Data Mining. In *IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology Workshops*, pages 41–44, 2006.
- [145] Y. Ning, S. Muthiah, H. Rangwala, and N. Ramakrishnan. Modeling Precursors for Event Forecasting via Nested Multi-Instance Learning. In *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*, KDD, page 1095–1104, New York, NY, USA, 2016. Association for Computing Machinery.
- [146] A. Paranjape, A. R. Benson, and J. Leskovec. Motifs in temporal networks. In *Proceedings of the tenth ACM international conference on web search and data mining*, pages 601–610, 2017.
- [147] C. Park and S. Cho. Future sign detection in smart grids through text mining. *Energy Procedia*, 128 :79–85, 09 2017.
- [148] I. Park and B. Yoon. Technological opportunity discovery for technological convergence based on the prediction of technology knowledge flow in a citation network. *Journal of Informetrics*, 12(4) :1199–1222, 2018.
- [149] F. Perez and B. E. Granger. Project Jupyter : Computational narratives as the engine of collaborative data science. *Retrieved September*, 11(207) :108, 2015.
- [150] F. Pezzoni, J. An, A. Passarella, J. Crowcroft, and M. Conti. Why Do I Retweet It? An Information Propagation Model for Microblogs. In *SocInfo*, 2013.
- [151] J. Phimister, V. Bier, and H. Kunreuther. Accident precursor analysis and management : Reducing technological risk through diligence. *Washington, DC : The National Academies Press*, 02 2004.
- [152] A. Pinar, C. Seshadhri, and V. Vishal. ESCAPE : Efficiently Counting All 5-Vertex Subgraphs. In *Proceedings of the 26th International Conference on World Wide Web*, WWW '17, page 1431–1440, Republic and Canton of Geneva, CHE, 2017. International World Wide Web Conferences Steering Committee.
- [153] T. Polacsek. Validation, accreditation or certification : a new kind of diagram to provide confidence. In *2016 IEEE Tenth International Conference on Research Challenges in Information Science (RCIS)*, pages 1–8. IEEE, 2016.
- [154] J. Ponomareva and A. Sokolova. The Identification of Weak Signals and Wild Cards in Foresight Methodology : Stages and Methods. *SSRN Electronic Journal*, 01 2015.
- [155] F. Pozzi, E. Fersini, E. Messina, and B. Liu. *Sentiment analysis in social networks*. Morgan Kaufmann, 2016.
- [156] N. Pržulj. Biological network comparison using graphlet degree distribution. *Bioinformatics*, 23(2) :e177–e183, 2007.
- [157] N. Pržulj, D. G. Corneil, and I. Jurisica. Modeling interactome : scale-free or geometric? *Bioinformatics*, 20(18) :3508–3515, 2004.
- [158] L. Pépin, P. Kuntz, J. Blanchard, F. Guillet, and P. Suignard. Visual analytics for exploring topic long-term evolution and detecting weak signals in company targeted tweets. *Computers & Industrial Engineering*, 112 :450–458, 2017.
- [159] J. P. Rascão. Strategic Information Surveillance. In R.-D. Leon, editor, *Managerial Strategies for Business Sustainability During Turbulent Times*, pages 78–99. IGI Global, 2018.

BIBLIOGRAPHIE

- [160] P. Ribeiro, P. Paredes, M. E. Silva, D. Aparicio, and F. Silva. A survey on subgraph counting : concepts, algorithms and applications to network motifs and graphlets. *arXiv preprint arXiv :1910.13011*, 2019.
- [161] M. Röder, A. Both, and A. Hinneburg. Exploring the Space of Topic Coherence Measures. In *Proceedings of the Eighth ACM International Conference on Web Search and Data Mining, WSDM '15*, page 399–408. Association for Computing Machinery, 2015.
- [162] S. Roh and J. Y. Choi. Exploring Signals for a Nuclear Future Using Social Big Data. *Sustainability*, 12(14) :5563, 2020.
- [163] P. Rossel. Early detection, warnings, weak signals and seeds of change : A turbulent domain of futures studies. *Futures*, 44 :229–239, 2012.
- [164] K. Rouibah and S. Ould-ali. PUZZLE : a concept and prototype for linking business intelligence to business strategy. *The Journal of Strategic Information Systems*, 11(2) :133–152, 2002.
- [165] P. Rousseau, D. Camara, and D. Kotzinos. Weak signal detection and identification in large data sets : a review of methods and applications. *Springer Nature*, May 2021.
- [166] D. P. Sakas, N. T. Giannakopoulos, M. C. Terzi, I. D. G. Kamperos, D. K. Nasiopoulos, D. P. Reklitis, and N. Kanellos. Social Media Strategy Processes for Centralized Payment Network Firms after a War Crisis Outset. *Processes*, 10(10) :1995, 2022.
- [167] N. Salliou and R. Thomopoulos. Je mange moins de viande! quels arguments? *La revue française de la recherche en viandes et produits carnés*, pages VPC–2018, 2018.
- [168] J. Salvit, Z. Li, S. Perumal, H. Wall, J. Mangels, S. Parsons, and E. I. Sklar. Employing argumentation to support human decision making : A user study. In *AAMAS Workshop on Argumentation in Multiagent Systems*, 2014.
- [169] O. Saritas and J. Smith. The Big Picture – trends, drivers, wild cards, discontinuities and weak signals. *Futures*, 43 :292–312, 04 2011.
- [170] P. J. Schoemaker and G. S. Day. How to make sense of weak signals. *Leading Organizations : Perspectives for a New Era*, 2 :37–47, 2009.
- [171] D. Seidl, H. Tsoukas, and J. Shepherd. The concept of weak signals revisited : a re-description from a constructivist perspective. *Managing the future : foresight in the knowledge economy*, pages 151–168, 2004.
- [172] J. Shin. *Strategic foresight to detect weak signal with young high-potential researchers*. ISPIM, jun 2017.
- [173] C. Sievert and K. Shirley. LDAvis : A method for visualizing and interpreting topics. In *Proceedings of the workshop on interactive language learning, visualization, and interfaces*, pages 63–70, 06 2014.
- [174] H. A. Soufiani and E. Airoidi. Graphlet decomposition of a weighted network. In N. D. Lawrence and M. Girolami, editors, *Proceedings of the Fifteenth International Conference on Artificial Intelligence and Statistics*, volume 22 of *Proceedings of Machine Learning Research*, pages 54–63, La Palma, Canary Islands, 21–23 Apr 2012. PMLR.
- [175] G. Šourek, O. Kuzelka, and F. Zelezny. Predicting top-k trends on twitter using graphlets and time features. *ILP Late Breaking Papers*, 2013.

BIBLIOGRAPHIE

- [176] J. Stehlé, N. Voirin, A. Barrat, C. Cattuto, L. Isella, J.-F. Pinton, M. Quaggiotto, W. Van den Broeck, C. Régis, B. Lina, et al. High-resolution measurements of face-to-face contact patterns in a primary school. *PloS one*, 6(8) :e23176, 2011.
- [177] G. W. Stewart. On the early history of the singular value decomposition. *SIAM review*, 35(4) :551–566, 1993.
- [178] P. Svenson, R. Forsgren, B. Kylesten, P. Berggren, W. R. Fah, M. S. Choo, and J. K. Y. Hann. Swedish-Singapore studies of Bayesian Modelling techniques for tactical Intelligence analysis. In *13th international conference on information fusion*, pages 1–8. IEEE, 2010.
- [179] J. Tang. Computational Models for Social Network Analysis : A Brief Survey. In *Proceedings of the 26th international conference on world wide web companion, WWW '17 Companion*, page 921–925, Republic and Canton of Geneva, CHE, 2017. International World Wide Web Conferences Steering Committee.
- [180] D. Thorleuchter and D. V. den Poel. Weak signal identification with semantic web mining. *Expert Systems with Applications*, 40(12) :4978–4985, 2013.
- [181] D. Thorleuchter and D. Van den Poel. Idea mining for web-based weak signal detection. *Futures*, 66 :25–34, 2015.
- [182] J. H. Tien, M. C. Eisenberg, S. T. Cherng, and M. A. Porter. Online reactions to the 2017'Unite the Right'rally in Charlottesville : measuring polarization in Twitter networks using media followership. *arXiv preprint arXiv :1905.07755*, 2019.
- [183] B. L. van Veen and J. Ortt. Unifying weak signals definitions to improve construct understanding. *Futures*, 134 :102837, 2021.
- [184] B. L. van Veen, J. Roland Ortt, and P. Badke-Schaub. Compensating for perceptual filters in weak signal assessments. *Futures*, 108 :1–11, 2019.
- [185] V. Venugopal, A. Ates, and P. McKiernan. Revisiting Ansoff's weak signals – A systematic literature review. In *36th Annual Conference of the British Academy of Management*, 2022.
- [186] R. L. Wasserstein and N. A. Lazar. The ASA Statement on p-Values : Context, Process, and Purpose. *The American Statistician*, 70(2) :129–133, 2016.
- [187] K. Welz, L. Brecht, A. Pengl, J. V. Kauffeldt, and D. R. Schallmo. Weak signals detection : Criteria for social media monitoring tools. In *ISPIM Innovation Symposium*, page 1. The International Society for Professional Innovation Management (ISPIM), 2012.
- [188] S. Wernicke. Efficient Detection of Network Motifs. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 3(4) :347–359, 2006.
- [189] S. Wernicke and F. Rasche. FANMOD : a tool for fast network motif detection. *Bioinformatics*, 22(9) :1152–1153, 02 2006.
- [190] S. H. Yoo and D. Won. Simulation of Weak Signals of Nanotechnology Innovation in Complex System. *Sustainability*, 10(2), 2018.
- [191] J. Yoon. Detecting weak signals for long-term business opportunities using text mining of Web news. *Expert Systems with Applications*, 39(16) :1243–1250, 2012.
- [192] C. Zhan. Early Identification Methods for Emerging Technologies Based on Weak Signals, 2022.

BIBLIOGRAPHIE

- [193] D. O. Zhukov, A. G. Zaltcman, and T. Y. Khvatova. Forecasting changes in states in social networks and sentiment security using the principles of percolation theory and stochastic dynamics. In *2019 International Conference "Quality Management, Transport and Information Security, Information Technologies"*, pages 149–153, 2019.