

Etat de l'art sur les techniques de détection et de classification de signaux

Introduction	2
Définition des signaux et de leurs caractéristiques	3
Introduction aux signaux et leur nature	3
Caractéristiques spécifiques aux signaux radars	3
Principes de base de la détection et de la classification des signaux	4
Processus général de détection des signaux (échantillonnage, filtrage, seuillage).....	4
Processus général de classification des signaux (extraction de caractéristiques, sélection de modèles)	5
Différentes méthodes et approches utilisées.....	6
Méthodes traditionnelles de détection des signaux Amplitude/Temps	6
Les transformées temps fréquence	7
Les fonctions de probabilité fondamentales	8
Techniques de fusion de données pour améliorer la détection et la classification des signaux (fusion de données multi-capteurs, fusion de données multi-modales).....	8
Quelques articles sur la détection et la classification de signaux.....	9
Extraction of instantaneous frequencies from ridges in time-frequency representations of signals	9
A Deep Learning Framework for Signal Detection and Modulation Classification.....	10
Deep Learning-Based Approach for Low Probability of Intercept Radar Signal Detection and Classification	13
ACF-Based Classification of Phase Modulated Waveforms	14
Deep Learning for real-time gravitational wave detection and parameter estimation: Results with Advanced LIGO data.....	16
An overview of speech endpoint detection algorithms.....	18

A survey of spectrogram track detection algorithms	21
Polyphase coded low probability of intercept signals detection and estimation using time– frequency rate distribution	23
Estimation of Modulation Parameters of LPI Radar Using Cyclostationary Method.....	25

Table des figures

Figure 1 : Diagramme d'un processus de détection classique	5
Figure 2 : Transformée en ondelette des signaux 1 et 2	10
Figure 3 : Diagramme du processus de génération de données d'entraînement	11
Figure 4 : Le modèle utilisé pour la détection de signaux	12
Figure 5 : Processus de traitement d'image pour la classification	12
Figure 6: Architecture du CNN utilisé pour la détection.....	17
Figure 7: Signal d'entrée. En bleu l'onde gravitationnelle à prédire et en rouge le bruit	18
Figure 8 : Chaîne de détection des signaux à code polyphasique	24
Figure 9 : Performance pour la détection des formes d'onde polyphasique	25
Figure 10 : Diagramme mesurant les paramètres de T1	26

Introduction

Dans ce rapport, nous présenterons un état de l'art des techniques de détection et de classification de signaux. Nous commencerons par définir les signaux et leurs caractéristiques, en mettant l'accent sur les spécificités des signaux radar. Ensuite, nous explorerons les principes de base de la détection et de la classification des signaux, en décrivant le processus généralement utilisé pour ces tâches.

Nous aborderons plus en détail les différentes méthodes et approches utilisées dans le domaine de la détection et de la classification des signaux, comprenant les méthodes de détection dans le domaine temporel et fréquentiel, ainsi que les méthodes basées principalement sur les fonctions de probabilité fondamentales. Nous discuterons également de la fusion de données, qui permet d'améliorer la détection et la classification des signaux en combinant les informations provenant de différents capteurs ou modalités.

Pour illustrer ces concepts, nous présenterons plusieurs articles récents sur la détection et la classification de signaux, mettant en évidence les avancées réalisées dans ce domaine. Parmi ces articles, nous aborderons des sujets tels que l'extraction des fréquences instantanées à partir des représentations temps-fréquence des signaux, les approches basées sur l'apprentissage profond

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

pour la détection et la classification des signaux, ainsi que l'estimation des paramètres en utilisant des méthodes cyclostationnaires. Les signaux analysés comprendront les signaux radars, mais aussi ceux de télécommunication, les signaux audio ou encore les ondes gravitationnelles.

En résumé, ce rapport vise à fournir une vue d'ensemble des techniques de détection et de classification de signaux, en mettant en évidence les méthodes et les approches les plus pertinentes dans ce domaine, afin de les appliquer dans le domaine du radar LPI.

Définition des signaux et de leurs caractéristiques

Introduction aux signaux et leur nature

La détection et la classification des signaux nécessitent une compréhension préalable de la nature des signaux et de leurs caractéristiques. Les signaux peuvent être soit analogiques, soit numériques. Les signaux analogiques sont continus dans le temps et l'amplitude, pouvant prendre n'importe quelle valeur dans une plage donnée. En revanche, les signaux numériques sont à la fois discrets dans le temps et l'amplitude, représentés par des valeurs discrètes à des instants spécifiques.

Les signaux ont des caractéristiques temporelles qui décrivent leur comportement et leur évolution dans le temps. Parmi ces caractéristiques, l'amplitude représente l'intensité ou la force du signal à un instant donné. La fréquence indique le nombre de cycles complets effectués par le signal par unité de temps. La phase mesure le décalage temporel par rapport à un signal de référence, tandis que la durée renseigne sur la période pendant laquelle le signal est présent.

Les caractéristiques fréquentielles des signaux fournissent des informations sur la distribution et la composition des différentes fréquences présentes dans un signal. Le spectre représente la répartition des différentes fréquences qui composent le signal, tandis que la bande passante correspond à la plage de fréquences où le signal est significatif. Enfin la résolution spectrale est une mesure de la capacité à distinguer les composantes fréquentielles proches dans un signal.

Outre ces caractéristiques, d'autres éléments sont importants pour la détection et la classification des signaux. L'énergie d'un signal représente la quantité totale d'énergie contenue dans celui-ci, tandis que la puissance mesure la quantité d'énergie transmise par unité de temps. Le décalage fait référence à un retard ou à une avance temporelle du signal par rapport à une référence. Le bruit est une composante indésirable ou aléatoire présente dans le signal, causée par des perturbations ou des interférences indésirables. Le rapport signal à bruit (SNR) permet d'estimer la quantité de bruit présente dans une acquisition pour un signal donné.

Caractéristiques spécifiques aux signaux radars

Il est important de prendre connaissances de certaines caractéristiques des signaux radars permettant aux spécialistes du domaine d'évaluer un signal :

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

- **Fréquence radar** : La fréquence radar fait référence à la fréquence des ondes radio utilisées par le radar pour émettre et recevoir les signaux. Elle peut varier en fonction des besoins et des applications spécifiques du radar. Les radars peuvent utiliser des fréquences allant des ondes radio HF (Haute Fréquence) aux ondes millimétriques.
- **Largeur de bande** : La largeur de bande du radar se réfère à la plage de fréquences utilisée pour transmettre le signal radar. Elle est généralement déterminée par les spécifications du radar et peut avoir un impact sur la résolution en distance et en vitesse.
- **Puissance d'émission** : La puissance d'émission d'un radar correspond à la puissance du signal électromagnétique émis par le radar. Une puissance d'émission plus élevée permet d'obtenir une plus grande portée de détection et une meilleure pénétration des obstacles, mais elle peut également entraîner des contraintes réglementaires et des problèmes de détection.
- **Diagramme de rayonnement** : Le diagramme de rayonnement du radar représente la distribution de l'énergie émise par le radar dans l'espace. Il décrit la directionnalité du faisceau radar, ce qui permet de déterminer la zone de couverture du radar et d'optimiser la détection des cibles.
- **Temps de montée et temps d'impulsion** : Le temps de montée est le temps nécessaire pour que le signal radar atteigne sa puissance maximale, tandis que le temps d'impulsion est la durée pendant laquelle le signal radar est actif. Ces paramètres déterminent la résolution en distance et en vitesse du radar.
- **Signature radar** : La signature radar d'une cible fait référence à la réponse du radar lorsqu'il est illuminé par le signal radar. Elle dépend de la taille, de la forme, du matériau et des caractéristiques de réflectivité de la cible. La signature radar peut être utilisée pour identifier et classer les cibles.

Principes de base de la détection et de la classification des signaux

Processus général de détection des signaux (échantillonnage, filtrage, seuillage)

Le processus de détection des signaux comprend plusieurs étapes clés qui permettent d'extraire les informations pertinentes du signal et de prendre des décisions sur la présence ou l'absence d'un signal spécifique. Voici les principales étapes du processus de détection des signaux :

- **Échantillonnage** : L'échantillonnage est la première étape du processus de détection des signaux. Il consiste à mesurer l'amplitude du signal à des instants réguliers dans le temps pour obtenir une séquence discrète d'échantillons. L'échantillonnage est généralement réalisé à l'aide d'un convertisseur analogique-numérique (CAN) qui convertit le signal analogique en une représentation numérique discrète.
- **Filtrage** : Après l'échantillonnage, le signal peut être soumis à des opérations de filtrage pour éliminer les fréquences indésirables ou atténuer le bruit. Le filtrage peut être réalisé à l'aide de filtres analogiques ou numériques, tels que les filtres passe-bas, passe-haut ou passe-bande, en fonction des caractéristiques spécifiques du signal et des besoins de détection.
- **Seuillage** : Une fois que le signal a été échantillonné et filtré, il est souvent nécessaire de déterminer si le signal dépasse un certain seuil pour être considéré comme présent. Le seuillage consiste à comparer l'amplitude des échantillons du signal à un seuil prédéfini. Si

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

l'amplitude dépasse le seuil, le signal est considéré comme détecté. Sinon, il est considéré comme non détecté.




Figure 1 : Diagramme d'un processus de détection classique

Processus général de classification des signaux (extraction de caractéristiques, sélection de modèles)

Le processus de classification des signaux vise à attribuer des étiquettes ou des catégories à des signaux en fonction de leurs caractéristiques distinctives. Voici les principales étapes du processus de classification des signaux :

- **Extraction de caractéristiques** : La première étape consiste à extraire des caractéristiques discriminantes à partir des signaux. Ces caractéristiques peuvent être des mesures spécifiques telles que l'amplitude, la fréquence, la phase, la variation temporelle ou toute autre mesure pertinente pour le problème de classification. Différentes techniques d'analyse du signal, telles que la transformation de Fourier, la transformée en ondelettes, l'analyse de régression, peuvent être utilisées pour extraire ces caractéristiques.
- **Prétraitement des données** : Après l'extraction des caractéristiques, il peut être nécessaire de prétraiter les données pour les rendre appropriées à la classification. Cela peut inclure des étapes telles que la normalisation des caractéristiques pour les mettre à la même échelle, la réduction de dimension pour éliminer les caractéristiques redondantes ou non discriminantes, ou la gestion des valeurs manquantes ou aberrantes.

On distingue ensuite deux types d'approche. Une utilisant les méthodes d'apprentissage machine et une autre se basant sur un ensemble de règles de décision définies par un expert métier.

Ci-dessous les étapes de classification sans utiliser d'algorithmes d'apprentissage :

- **Conception de règles de décision** : Après avoir extrait et sélectionné les caractéristiques, il est possible de concevoir des règles de décision basées sur ces caractéristiques pour la classification des signaux. Ces règles peuvent être définies manuellement par des experts en utilisant des seuils, des limites ou des critères spécifiques pour attribuer les étiquettes aux signaux en fonction de leurs caractéristiques. Par exemple, si la fréquence d'un signal est supérieure à un certain seuil, il peut être classé comme un signal de type A, sinon il peut être classé comme un signal de type B.
- **Validation et évaluation du modèle** : Une fois que les règles de décision ont été définies, il est important de les valider et de les évaluer pour estimer leur performance. Cela peut être

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

réalisé en utilisant des ensembles de données de test distincts contenant des signaux non étiquetés. Les signaux sont ensuite classés en utilisant les règles de décision et les résultats sont comparés aux étiquettes réelles pour évaluer la précision et la fiabilité du modèle de classification.

- Optimisation des règles de décision : Si les performances du modèle de classification ne sont pas satisfaisantes, il est possible de les améliorer en ajustant les règles de décision. Cela peut inclure l'ajustement des seuils, des limites ou des critères de classification en fonction des caractéristiques spécifiques des signaux. L'optimisation des règles de décision peut être itérative et implique généralement une rétroaction entre les résultats de classification et les ajustements apportés aux règles.

Ci-dessous les étapes d'une classification par un modèle d'apprentissage machine :

- Sélection du modèle de classification : Une fois que les caractéristiques ont été extraites et prétraitées, il est nécessaire de sélectionner un modèle de classification approprié. Il existe différentes approches de classification, telles que les arbres de décision, les réseaux neuronaux, les machines à vecteurs de support (SVM), les k-plus proches voisins (KNN), les réseaux bayésiens, etc. Le choix du modèle dépend du type de signal, du volume de données, de la complexité du problème de classification et des performances souhaitées.
- Entraînement du modèle : Cette étape consiste à entraîner le modèle de classification en utilisant un ensemble de données d'entraînement étiquetées. Le modèle apprend à partir de ces données pour établir des relations entre les caractéristiques et les étiquettes, ce qui lui permet de généraliser et de classer de nouveaux signaux non étiquetés.
- Évaluation du modèle : Une fois que le modèle a été entraîné, il est évalué en utilisant un ensemble de données de test distinct. Cela permet d'estimer les performances du modèle, telles que l'exactitude, la précision, le rappel ou la courbe caractéristique de fonctionnement du récepteur (ROC). L'évaluation permet de vérifier si le modèle est capable de généraliser et de classer correctement de nouveaux signaux.
- Optimisation du modèle : Si les performances du modèle ne sont pas satisfaisantes, des techniques d'optimisation peuvent être utilisées pour améliorer sa précision. Cela peut inclure l'ajustement des paramètres du modèle, l'utilisation de techniques de sélection de caractéristiques plus avancées, l'augmentation des données d'entraînement ou l'utilisation de techniques d'apprentissage en ligne.

Différentes méthodes et approches utilisées

Méthodes traditionnelles de détection des signaux Amplitude/Temps

Dans le domaine de la détection des signaux, il existe plusieurs méthodes traditionnelles qui sont largement utilisées pour détecter la présence de signaux spécifiques dans un environnement bruité. Ces méthodes se basent sur des principes fondamentaux du traitement du signal et ne nécessitent

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

pas l'utilisation de techniques avancées de Machine Learning. Voici quelques-unes des méthodes traditionnelles couramment utilisées :

- **Seuillage** : La méthode de seuillage est l'une des méthodes les plus simples et couramment utilisées pour la détection des signaux. Elle consiste à comparer l'amplitude du signal à un seuil prédéfini. Si l'amplitude dépasse le seuil, le signal est considéré comme détecté. Sinon, il est considéré comme non détecté. Le seuil peut être fixe ou adaptatif, en fonction des caractéristiques du signal et du niveau de bruit ambiant.
- **Corrélation** : La corrélation est une méthode utilisée pour mesurer la similitude entre un signal d'intérêt et un modèle de référence. Elle est souvent utilisée dans la détection de signaux périodiques ou de séquences de symboles. La corrélation croisée ou la corrélation en série peuvent être utilisées pour mesurer la corrélation entre le signal reçu et le modèle de référence. Si la corrélation dépasse un certain seuil, le signal est considéré comme détecté.
- **Filtrage adaptatif** : Le filtrage adaptatif est une méthode qui vise à atténuer le bruit et à améliorer la sensibilité de détection en ajustant les paramètres du filtre en temps réel. Cette méthode utilise des techniques telles que le filtre adaptatif en bande étroite (NLMS), le filtre de Kalman ou le filtrage LMS (Least Mean Squares). Le filtrage adaptatif permet de supprimer le bruit indésirable tout en préservant les caractéristiques du signal souhaité.

Les transformées temps fréquence

Il est parfois plus simple de détecter un signal en réalisant une transformée temps fréquence de ce dernier. Certaines de ses caractéristiques peuvent être extraites ce qui permet de le distinguer du bruit. Voici une liste non exhaustive des transformées temps fréquence couramment utilisés pour la détection et la classification de signaux :

- **Transformée de Fourier** : La transformée de Fourier est une technique largement utilisée pour analyser les signaux en termes de leurs composantes fréquentielles. Elle permet de décomposer un signal en une série de sinus et cosinus de différentes fréquences. La transformée de Fourier permet d'identifier les fréquences présentes dans un signal et d'effectuer des opérations de filtrage et de détection basées sur la manipulation du spectre fréquentiel.
- **Ondelettes** : Les ondelettes sont des fonctions mathématiques qui permettent d'analyser les signaux à différentes échelles de temps et de fréquence. Contrairement à la transformée de Fourier, qui offre une résolution fréquentielle constante, les ondelettes offrent une résolution variable qui permet de capturer à la fois les détails temporels et fréquentiels des signaux. Les ondelettes sont utilisées pour détecter des caractéristiques spécifiques dans les signaux, telles que des transitions rapides, des changements de fréquence ou des événements transitoires.
- **Transformée de Wigner-Ville** : La transformée de Wigner-Ville est une technique de transformée temps-fréquence qui permet d'obtenir une représentation conjointe du signal dans le domaine temporel et fréquentiel. Elle offre une résolution simultanée en temps et en fréquence, ce qui permet de capturer les variations rapides du signal dans le temps ainsi que les variations de fréquence. La transformée de Wigner-Ville est particulièrement utile pour l'analyse de signaux non stationnaires.

La sélection de la technique appropriée dépend des caractéristiques du signal, de la nature du problème de détection et des performances requises. Il est courant d'utiliser une combinaison de ces techniques pour obtenir des résultats optimaux de détection des signaux.

Les fonctions de probabilité fondamentales

Les fonctions de probabilité fondamentales (PDF - Probability Density Functions) sont d'une importance capitale dans la théorie de la détection de signaux. Les PDF décrivent la distribution probabiliste des signaux, c'est-à-dire la probabilité qu'un signal donné se situe dans une plage de valeurs spécifique. Elles jouent un rôle essentiel dans la conception des détecteurs de signaux et dans l'évaluation de leurs performances.

Voici quelques raisons pour lesquelles les PDF sont importantes dans la théorie de la détection de signaux :

- **Modélisation des signaux :** Les PDF permettent de modéliser statistiquement les signaux d'intérêt ainsi que le bruit environnant. En décrivant la distribution probabiliste des signaux et du bruit, les PDF fournissent une représentation mathématique précise des caractéristiques statistiques des signaux à détecter.
- **Définition des seuils de détection :** Les PDF sont utilisées pour déterminer les seuils de détection dans les méthodes de détection des signaux. En fixant un seuil approprié, basé sur la connaissance de la distribution probabiliste du signal et du bruit, il est possible de prendre des décisions de détection optimales, minimisant ainsi les erreurs de détection.
- **Analyse de performance :** Les PDF sont utilisées pour évaluer les performances des détecteurs de signaux. En utilisant les PDF des signaux et du bruit, on peut calculer des métriques de performance telles que la probabilité de détection, la probabilité de fausse alarme, la courbe ROC (Receiver Operating Characteristic), etc. Ces mesures permettent de quantifier l'efficacité du détecteur et de comparer différentes méthodes de détection.
- **Décisions de détection optimales :** Les PDF sont utilisées pour définir des règles de décision optimales dans les détecteurs de signaux. En utilisant des principes statistiques tels que le maximum de vraisemblance ou le critère de Neyman-Pearson, les PDF permettent de déterminer les règles de décision qui maximisent la probabilité de détection tout en maintenant un taux de fausse alarme acceptable.

Techniques de fusion de données pour améliorer la détection et la classification des signaux (fusion de données multi-capteurs, fusion de données multi-modales)

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

Dans de nombreuses applications, il est courant d'avoir accès à des informations provenant de multiples capteurs ou modalités, ce qui permet de recueillir des données complémentaires et d'améliorer la détection et la classification des signaux. Les techniques de fusion de données sont utilisées pour combiner et exploiter ces différentes sources d'informations de manière efficace. Voici deux approches courantes de fusion de données :

- Fusion de données multi-capteurs : Lorsqu'il y a plusieurs capteurs qui mesurent différents aspects d'un signal, la fusion de données multi-capteurs permet de combiner les informations provenant de chaque capteur pour améliorer la détection et la classification des signaux.
- Fusion de données multi-modales : La fusion de données multi-modales consiste à combiner des informations provenant de différentes modalités, telles que des signaux acoustiques, des images ou des données textuelles, pour améliorer la détection et la classification des signaux. Cette approche permet d'exploiter les forces de chaque modalité et d'obtenir une représentation plus riche et plus complète des signaux.

La fusion de données permet de tirer parti de la complémentarité des différentes sources d'informations pour améliorer la détection et la classification des signaux. Cela permet d'obtenir des résultats plus fiables et robustes, en particulier dans des scénarios complexes et bruités.

Quelques articles sur la détection et la classification de signaux

Extraction of instantaneous frequencies from ridges in time-frequency representations of signals

[1]

Cet article aborde le problème de l'extraction des fréquences instantanées à partir des représentations temps-fréquence des signaux, telles que la transformée de Fourier fenêtrée (WFT) ou la transformée en ondelettes (WT).

La WFT distingue les composantes d'un signal en fonction de leurs différences de fréquence (avec une résolution de fréquence linéaire), tandis que la WT le fait en fonction des rapports entre leurs fréquences (avec une résolution de fréquence logarithmique). En d'autres termes, la WFT divise le spectre en bandes de fréquences équidistantes, tandis que la WT divise le spectre en bandes de fréquences dont les rapports sont constants.

Le principe est d'extraire la courbure d'un signal dans l'image temps fréquence de l'acquisition en se basant sur les pics d'amplitude de l'image. La sélection de la courbe est ajustée en fonction d'un algorithme d'optimisation de chemin prenant en entrée l'ensemble des pics d'amplitude de l'image TF. Plusieurs algorithmes sont proposés mais celui obtenant les meilleurs résultats, noté $II(1,1)$, associe les valeurs $\alpha = 1$ et $\beta = 1$ où α et β contrôlent l'intensité de la suppression respectivement des déviations relatives de la fréquence de crête (atténuation de l'importance des pics d'amplitude) et de sa dérivée temporelle par rapport aux valeurs médianes correspondantes.

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

Les méthodes ont été testées sur un signal modulé sinusoïdalement en amplitude et en fréquence et avec un deuxième composant sinusoïdal d'amplitude moindre. Le deuxième signal de test est un signal réel d'électrocardiogramme. Du bruit gaussien d'écart type 0.6 et 0.3 est respectivement additionné au premier et au second signal.




Figure 2 : Transformée en ondelette des signaux 1 et 2

La méthode d'évaluation compare la courbe extraite avec celle qui serait extraite dans le cas d'un signal sans bruit qui n'est pas équivalent à la vraie valeur de fréquence instantanée du signal.

Conclusion et remarques :

Cet article propose une méthode d'extraction de fréquence instantanée à partir de la représentation temps fréquence d'un signal.

On va distinguer trois limitations à l'application de cet algorithme à des signaux radars LPI :

- Choisir la résolution des transformées en ondelette peut être compliquée lorsqu'on n'a aucune information sur le signal à analyser
- L'acquisition radar peut présenter des signaux autres que ceux d'intérêt dont l'amplitude est plus grande comparée aux signaux LPI. L'extraction de courbe de fréquence se réalisera alors sur le mauvais signal et des algorithmes de suppression de signaux encombrants seraient nécessaire en amont de l'application de $II(1,1)$
- Les signaux modulés en phase seraient potentiellement moins aptes à être caractérisés
- La multi-détection sur une même acquisition n'est pas réalisable avec l'algorithme proposé

A Deep Learning Framework for Signal Detection and Modulation Classification

[2]

Dans cet article, les auteurs proposent un cadre d'apprentissage profond pour la détection de signaux multiples et la reconnaissance de modulations. Ils utilisent un réseau de détection d'objets appelé "Single Shot Multibox Detector" (SSD) pour détecter l'emplacement de chaque signal. Ils

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

utilisent le spectre temps-fréquence extrait à partir d'une STFT comme représentation caractéristique du signal. Pour la reconnaissance de modulations telles que MPSK, MAPSK et MQAM, ils conçoivent un modèle CNN à entrées multiples pour extraire et cartographier les caractéristiques des signaux.

Les contributions principales de cet article sont les suivantes :

- Proposition d'un cadre d'apprentissage profond complet pour la détection de signaux et la reconnaissance de modulations
- Établissement de différentes stratégies de représentation des signaux adaptées aux différentes tâches
- Proposition d'un modèle de CNN à entrées multiples pour extraire et cartographier les caractéristiques des signaux de différentes dimensions.




Figure 3 : Diagramme du processus de génération de données d'entraînement

Pour les données simulées, il peut exister plusieurs signaux dans la même bande de fréquence mais chaque signal est décalé en fréquence afin d'éviter les chevauchements dans le domaine fréquentiel. Une STFT est appliquée sur l'ensemble de la largeur de bande. On notera le temps de début et de fin, la fréquence porteuse et la bande passante de chaque signal.

Plusieurs types de CNN sont utilisés dans la littérature pour la tâche de détection, notamment les algorithmes basés sur la recommandation de région (RCNN, Fast RCNN etc...) et les algorithmes basés sur la régression (YOLO, SSD). Pour des raisons de complexité calculatoire, les auteurs ont décidé d'utiliser les SSD. Les réseaux SSD génèrent une série de cadres de taille fixe et estiment la probabilité de présence de la cible dans chaque cadre. Malgré un temps de calcul plus lent, des tests avec des fast RCNN obtiennent de meilleurs résultats.

Les étapes de mise en œuvre des réseaux SSD pour la détection et la reconnaissance des signaux sont les suivantes :

- Extraction des caractéristiques à partir des réseaux VGG16
- Conception des boîtes par défaut pour différentes échelles de caractéristiques

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

- Prédiction de la catégorie et de la localisation des signaux à l'aide de noyaux de convolution
- Application de l'algorithme "Non-maximum suppression" pour sélectionner les meilleures prédictions.




Figure 4 : Le modèle utilisé pour la détection de signaux

En amont de la tâche de classification, un algorithme de traitement de la donnée est appliqué sur le diagramme en œil et le diagramme vectoriel du signal. Le processus est résumé sur l'image ci-dessous.




Figure 5 : Processus de traitement d'image pour la classification

Les auteurs ont décidé d'utiliser un CNN à plusieurs entrées prenant en paramètre le diagramme vectoriel et les diagrammes en œil Q et I du signal. Des blocs de ResNet sont incorporés dans la structure CNN pour éviter la dégradation d'apprentissage lié à la profondeur du réseau.

Le processus complet envisagé est le suivant :

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

- Construire les réseaux de détection et classification et les entraîner avec les données simulées
- Effectuer la transformation de Fourier à court terme (STFT) sur les signaux à large bande et utiliser les réseaux SSD entraînés pour détecter les signaux dans le spectre temps-fréquence. Obtenir la fréquence centrale et les temps de début et de fin de chaque signal.
- Utiliser les caractéristiques prédites pour filtrer l'enveloppe spectrale du signal ciblé et appliquer un filtre adaptatif puis générer les diagrammes en œil et vectoriel.
- Utiliser le CNN à multiple entrée afin d'accomplir la tâche de classification

Pour évaluer les résultats, un score mAP (mean average precision) est appliqué pour la détection. On évalue ensuite la précision des paramètres estimés (fréquence porteuse, temps de départ et de fin). L'accuracy est ensuite utilisé pour évaluer les performances du modèle de classification.

Conclusion et remarques :

Cet article aborde la problématique de détection et de classification d'ondes modulées notamment dans le cas du contexte télécoms. Une première chaîne de détection comprend un algorithme SSD et une deuxième chaîne de classification propose un algorithme de CNN multi-inputs. Il ne traite néanmoins pas des cas classiques de modulation polyphasique ou polytime et le SNR considéré reste trop élevé pour le contexte du radar LPI.

Deep Learning-Based Approach for Low Probability of Intercept Radar Signal Detection and Classification

[3]

Ce papier propose une méthode de détection et classification de signaux radars LPI en très faible SNR grâce à des méthodes d'apprentissage profond (GoogleNet et AlexNet) appliquées sur des images temps fréquence (STFT) d'**un seul cycle** des signaux.

Cet article propose la reconnaissance de 9 types de signaux LPI :

- Modulation de fréquence linéaire
- Modulation polyphasique (P1, P2, P3, P4)
- Modulation polytime (T1, T2, T3, T4)

Tableau 1: Caractéristiques des signaux

Modulation type	SNR, dB	F_s , MHz	f_c , MHz	BW, MHz	m
LFM	-10 ~ 0	200	1-50	1-20	—
P1,P2,P3,P4	-10 ~ 0	200	Constant	1-20	16, 25, 36
T1,T2,T3,T4	-10 ~ 0	200	Constant	1-20	2 : 10

La principale contribution du papier est son utilisation des méthodes de DL GoogleNet et AlexNet à des images temps-fréquence de signaux afin de les détecter et de les classifier. Les mesures d'évaluation utilisées sont l'accuracy et la probabilité de détection.

Pour la tâche de détection, le modèle est entraîné sur 90 000 images contenant un signal dans un SNR de -15dB à 0dB et 90 000 images de bruit blanc divisées en 90% d'images d'entraînement et 10% d'images de validation et de test. 100% d'accuracy est atteint même pour -15dB de SNR.

Pour la partie de classification, 20 000 images par classe sont utilisées pour l'entraînement. On considère le bruit blanc seul comme une classe. Les tests sont réalisés pour des SNR allant de -20dB à 0dB et donc 2000 images avec le même SNR par classe. Là encore, les auteurs ont divisé la base de données en 90% d'entraînement et 10% de validation. L'accuracy est d'environ 100% pour un SNR à -8dB.

Conclusion et remarques :

Cet article propose d'utiliser les modèles de GoogleNet et AlexNet à la détection et la classification de formes d'ondes radar LPI dans du SNR faible. Le preprocessing de la donnée comprend l'utilisation du spectrogramme du signal (carré de la STFT) puis une phase de normalisation. Il n'est pas précisé si le preprocessing est le même pour la tâche de détection et celle de classification.

ACF-Based Classification of Phase Modulated Waveforms

[4]

Ce papier présente une méthode pour classifier les signaux modulés en phase à faible SNR en se basant sur la fonction d'autocorrélation des signaux détectés. Si plusieurs impulsions sont détectées, la superposition des impulsions permet d'améliorer les résultats de classification.

Il est supposé que dans le récepteur, le processeur d'impulsion effectue une détection de l'enveloppe et un seuillage pour identifier les fronts montants et descendants de chaque impulsion. Les impulsions sont ensuite segmentées en observations d'impulsion indépendantes. Un délai temporel est utilisé pour permettre des erreurs dans la détection des fronts d'impulsion, ainsi chaque impulsion détectée aura une longueur plus longue que l'impulsion réelle. L'ensemble des impulsions est ensuite entré dans l'algorithme de classification. Vingt-et-unes formes d'ondes ont été simulées et sont listées dans le tableau ci-dessous.

Tableau 2: Table des formes d'ondes

c	Modulation Type	Code Length	Training τ (μsec)	Testing τ (μsec)
1	Barker	7	1.75	7.0
2	Barker	11	2.75	11.0
3	Barker	13	3.25	13.0
4	Combined Barker	16	2.0	8.0
5	Combined Barker	49	6.13	2.11
6	Combined Barker	169	22.1	84.6
7	Maximum Length Pseudo Random	16	1.5	4.5
8	Maximum Length Pseudo Random	64	3.5	10.5
9	Maximum Length Pseudo Random	256	6.3	18.9
10	Minimum Peak Sidelobe	10	1.4	4.2
11	Minimum Peak Sidelobe	25	2.5	10.0
12	Minimum Peak Sidelobe	48	4.8	19.2
13	T1	NA	4.0	16.0
14	T2	NA	3.0	12.0
15	T3	NA	8.0	2.0
16	Polyphase Barker	7	1.75	7.0
17	Polyphase Barker	20	2.0	8.0
18	Polyphase Barker	40	4.0	16.0
19	P1	NA	10.0	20.0
20	P2	NA	6.4	25.6
21	P3	NA	6.4	25.6
22	P4	NA	10.0	29.0
23	Minimum Shift Key	64	18.9	8.0

La fonction d'autocorrélation de chaque impulsion est calculée puis, afin de diminuer l'impact du bruit, une moyenne est calculée sur l'ensemble du train d'impulsion. La variance du bruit est diminuée d'un facteur égal au nombre d'impulsion. On sélectionne ensuite le logarithme de la moyenne de l'ensemble des ACF, que l'on a normalisé au préalable pour obtenir des piques unitaires.

Afin de compresser la donnée, il est proposé de donner au classifieur une représentation fréquentielle de ces fonctions d'autocorrélation en leur appliquant une FFT. Les coefficients obtenus sont ensuite passés dans un FLD (Fisher Linear Discriminant) pour la classification.

Les résultats obtenus sont résumés dans le tableau ci-dessous.

Tableau 3: Table des résultats

SNR (dB)	1 Chain P_t	5 Chain P_t	10 Chain P_t	20 Chain P_t
-10	0.0429	0.0616	0.1073	0.1648
-8	0.0721	0.1925	0.3905	0.7275
-6	0.1578	0.6233	0.8336	0.9055
-4	0.4000	0.9026	0.9727	0.9969
-2	0.7396	0.9824	0.9974	0.9986
0	0.8910	0.9954	0.9983	0.9984
2	0.9515	0.9967	0.9982	0.9982
4	0.9807	0.9972	0.9976	0.9981
6	0.9905	0.9968	0.9974	0.9983
8	0.9921	0.9970	0.9967	0.9980
10	0.9940	0.9962	0.9960	0.9987

Conclusion et remarques :

Cet article propose de se baser sur la fonction d'autocorrélation afin de classifier des signaux modulés en phase. Une image temps fréquence de la fonction normalisée de l'autocorrélation du signal est passée en entrée d'un algorithme de classification FLD. En moyennant la fonction d'autocorrélation sur l'ensemble des impulsions reçu, le bruit est atténué et une meilleure classification est proposée.

Les remarques sont les suivantes :

- Il est précisé dans l'article que cette approche est applicable principalement pour les formes d'ondes modulées en phase et qu'elle n'est pas forcément pertinente pour celles en fréquence. Ils proposent l'utilisation d'un deuxième algorithme qui distingue les deux types de modulation.
- Il est aussi mentionné que le classificateur utilisé n'est pas issu d'une recherche du meilleur algorithme de classification. Il peut certainement être amélioré.
- La tâche de détection n'est pas abordée et la multi-classification ne l'est pas non plus

Deep Learning for real-time gravitational wave detection and parameter estimation: Results with Advanced LIGO data

[4]

Détecter et estimer les caractéristiques d'ondes gravitationnelles est une problématique qui se rapproche grandement de la détection et classification d'ondes radar LPI. Dans cet article, la technique proposée est un ensemble de deux CNN, un détecteur et un estimateur de caractéristiques.

Cette solution a été envisagée pour analyser les signaux d'ondes gravitationnelles dans le bruit réel de LIGO (l'observatoire avancé d'ondes gravitationnelles par interférométrie laser). Ils démontrent pour la première fois que le Deep Learning peut être utilisé à la fois pour la détection de signaux et pour l'estimation de plusieurs paramètres à partir de signaux temporels extrêmement faibles, noyés dans un bruit hautement non gaussien et non stationnaire. Les CNN profonds atteignent des performances comparables aux méthodes de filtres adaptatifs, tout en étant plusieurs ordres de grandeur plus rapides et beaucoup plus résilients aux artefacts de bruit transitoire tels que les "glitches".

Le détecteur est d'abord appliqué au flux continu de données via une fenêtre glissante. S'il y a détection, l'estimateur est ensuite appliqué au même signal d'entrée pour déterminer les paramètres de la source. Dans un scénario multi-détecteurs, les CNN Deep Filtering peuvent être appliqués séparément à chaque flux de données, et la coïncidence des détections avec des paramètres similaires renforce la confiance en une véritable détection, qui peut ensuite être rapidement vérifiée par le filtre adaptatif.

Un bruit différent a été appliqué sur les données d'entraînement et de validation que sur les données de test, ainsi si les résultats sont convaincants sur les données de test, ils le seront certainement sur les données réelles sans nécessiter de réentraînement. D'ailleurs une

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

augmentation de donnée a été réalisée en simulant pour un même signal plusieurs répartition de bruit différentes.

La stratégie d'entraînement utilisée permet de réduire le temps d'entraînement en prenant en compte moins de données et d'améliorer les résultats. La stratégie, "curriculum learning strategy", consiste à fournir au modèle des signaux dont le SNR diminue petit à petit. Un apprentissage par transfert ("transfer learning") est appliqué sur l'estimateur de caractéristiques avec initialement un réseau entraîné sur des données sans bruit. Les poids sont conservés puis le réseau est entraîné sur un ensemble de donnée contenant 90% de bruit. (En apprendre davantage sur curriculum learning strategy)

Dans cet article, l'auteur aborde la reconnaissance des "glitches", qui sont des perturbations transitoires non gaussiennes présentes dans les données de LIGO. L'étude montre que la méthode utilisée est capable de reconnaître automatiquement ces glitches et de les classer comme du bruit. Cette méthode a réussi à distinguer facilement les nouveaux glitches des vrais signaux, avec un taux de fausses alarmes inférieur à 1% en utilisant uniquement les entrées d'un seul détecteur. En comparaison, l'algorithme de filtrage adapté traditionnel a classé environ 30% des glitches comme des signaux en raison de leur SNR élevé.

	Input	vector (size: 8192)
1	Reshape	matrix (size: 1 × 8192)
2	Convolution	matrix (size: 64 × 8177)
3	Pooling	matrix (size: 64 × 2044)
4	ReLU	matrix (size: 64 × 2044)
5	Convolution	matrix (size: 128 × 2014)
6	Pooling	matrix (size: 128 × 503)
7	ReLU	matrix (size: 128 × 503)
8	Convolution	matrix (size: 256 × 473)
9	Pooling	matrix (size: 256 × 118)
10	ReLU	matrix (size: 256 × 118)
11	Convolution	matrix (size: 512 × 56)
12	Pooling	matrix (size: 512 × 14)
13	ReLU	matrix (size: 512 × 14)
14	Flatten	vector (size: 7168)
15	Linear Layer	vector (size: 128)
16	ReLU	vector (size: 128)
17	Linear Layer	vector (size: 64)
18	ReLU	vector (size: 64)
19	Linear Layer	vector (size: 2)
	Output	vector (size: 2)

Figure 6: Architecture du CNN utilisé pour la détection




Figure 7: Signal d'entrée. En bleu l'onde gravitationnelle à prédire et en rouge le bruit

Conclusions et remarques :

Bien que la reconnaissance d'onde gravitationnelle dans cet article s'adresse dans une zone SNR plus grande que celle des signaux radars LPI, cet article est intéressant car il présente les avantages du Deep Learning pour la détection et la classification de signaux dans des conditions bien plus particulières que la plupart des articles abordés précédemment.

Ici l'objectif est de réaliser de la détection sur un flux de donnée en temps réel et la complexité calculatoire est prise en compte. La stratégie utilisant deux CNN, chacun ayant une tâche spécifique permet d'améliorer les performances en termes de détection, d'estimation et de temps de calcul.

Aussi la prise en compte d'un bruit particulier, non gaussien et non stationnaire, dont la distribution spectrale varie permet de remarquer que le deep learning est résilient à ce type de condition. L'ajout de signaux perturbateur, considéré comme du bruit, n'impacte pas tellement les prédictions réalisées. C'est un point non négligeable pour la détection et la classification de signaux LPI qui sont émis dans des bandes de fréquence utilisés par d'autres appareils.

[An overview of speech endpoint detection algorithms](#)

[5]

Cet article présente l'état de l'art (jusqu'en 2020) des techniques de détections des points de début et de fin de parole. Les algorithmes utilisés doivent être adaptés aux environnements bruyants, en utilisant des caractéristiques dans le domaine temporel et/ou fréquentiel pour améliorer la performance. L'entrée de la détection de points de début et de fin de la parole est un signal bruité qui est un mélange de parole claire et de bruit dans la vie réelle.

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

Le résumé des techniques présentés dans cet état de l'art est condensé dans les deux tableaux qui suivent.

Tableau 4 : évaluation de la détections des points de début et de fin d'algorithmes basés sur des caractéristiques de temps courts

Noise Type	SNR	Short-time energy + ZCR	Autocorr- elation	Energy-zero ratio	Spectral variance	Sub-band energy entropy ratio	MFCC cepstrum distance
WGN	-5dB	76.80	85.29	84.79	90.77	91.52	77.83
	0 dB	77.81	87.78	89.03	92.27	94.76	85.14
	5 dB	78.30	89.03	89.08	94.26	95.76	88.25
	10 dB	81.30	92.27	90.27	96.01	97.51	90.22
	15 dB	82.12	92.52	90.77	96.51	97.76	93.71
	20 dB	82.45	92.77	92.77	97.26	97.90	94.79
AVE PINK	-5dB	73.61	89.94	89.45	94.51	95.86	88.32
	0 dB	68.95	73.61	72.82	78.78	76.26	77.26
	5 dB	67.49	77.73	82.72	81.43	80.76	80.37
	10 dB	71.65	79.94	78.33	85.13	79.88	83.19
	15 dB	74.95	84.72	82	86.64	84.23	85.88
	20 dB	79.54	87.15	84.78	88.11	86.32	89.52
AVE BABBLE	-5dB	86.02	89.89	88.27	89.66	91.49	89.79
	0 dB	74.76	82.18	81.49	84.95	83.16	84.34
	5 dB	66.45	75.66	71.27	76.45	77.23	74.91
	10 dB	74.97	78.21	73.84	81.17	80.01	78.30
	15 dB	78.01	82.49	76.23	82.56	83.16	79.70
	20 dB	82.24	85.92	77.08	82.85	84.21	83.34
AVE MACHINEGUN	-5dB	83.31	85.84	81.85	84.91	86.78	85.03
	0 dB	85.75	88.39	85.43	88.45	90.61	86.98
	5 dB	78.45	82.75	77.62	82.73	83.67	81.38
	10 dB	69.92	72.52	74.32	73.20	76.33	82.44
	15 dB	74.65	74.83	73.71	77.72	80.57	84.00
	20 dB	78.79	80.09	74.38	79.36	81.75	83.67
AVE	0 dB	79.61	84.20	76.87	82.18	83.80	84.84
	5 dB	85.24	85.82	80.41	82.78	86.36	86.98
	10 dB	86.19	87.81	82.72	85.61	87.61	86.99
	20 dB	79.07	80.88	77.07	80.14	82.73	84.82

Les différents algorithmes sont testés sur des SNR et des types de bruits différents :

- White Gaussian Noise (WGN) : Bruit blanc gaussien
- Pink Noise : Bruit rose
- Babble Noise : Bruit de brouhaha
- Machine Gun Noise : Bruit de mitrailleuse

Les algorithmes mentionnés dans le tableau sont :

1. Short-time energy : Il s'agit d'une mesure de l'énergie contenue dans des segments de signal courts. Elle est calculée en utilisant la somme des carrés des échantillons du signal sur une fenêtre de temps donnée.
2. Zero Crossing Rate (ZCR) : Il s'agit du nombre de fois que le signal traverse zéro dans une fenêtre de temps donnée. Cette mesure peut être utilisée pour caractériser le taux de variation du signal et en général est utilisé avec un seuil prédéfini équivalent à la valeur moyenne du niveau du bruit.
3. Autocorrelation : L'autocorrélation est une mesure de la similitude entre un signal et une version retardée de lui-même. Elle peut être utilisée pour identifier des motifs périodiques ou réguliers dans le signal.
4. Energy-zero ratio : Cette mesure compare l'énergie du signal à la quantité d'énergie présente dans la composante de fréquence zéro du signal. Elle peut être utilisée pour détecter la présence de composantes continues ou constantes dans le signal.

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

5. Spectral variance : Cette mesure évalue la variabilité du spectre de fréquence du signal. Elle peut être utilisée pour caractériser les variations de fréquence ou les fluctuations dans le contenu spectral du signal.
6. Sub-band energy entropy ratio : Cette mesure évalue la répartition de l'énergie du signal dans différentes sous-bandes de fréquence. Elle peut être utilisée pour détecter des modèles spécifiques dans le spectre de fréquence du signal.
7. MFCC cepstrum distance : Les coefficients cepstraux de fréquence de Mel (MFCC) représentent les amplitudes des spectres de transformation en cosinus discret. La distance du cepstrum mesure les différences entre les spectres des signaux et est utilisée pour détecter les points de terminaison en analysant les variations de distance du cepstrum entre les trames de signal et de bruit.

Tableau 5 : évaluation de la détections des points de début et de fin d'algorithmes basés sur des caractéristiques de temps longs et de Machine Learning

Noise Type	SNR	LTSV	LSFM	LSVM	BP	SVM	DNN
WGN	−5dB	90.66	88.75	91.57	80.87	78.55	76.98
	0 dB	95.27	95.21	96.73	84.45	84.25	82.62
	5 dB	97.66	97.98	98.56	86.35	85.84	87.11
	10 dB	98.37	98.72	98.76	88.74	88.57	90.63
	15 dB	97.84	97.96	96.44	89.63	89.94	92.37
	20 dB	97.46	97.61	96.44	90.14	90.16	92.84
AVE PINK		96.21	96.04	96.42	86.70	86.22	87.09
	−5dB	88.41	87.23	91.31	72.26	78.39	75.79
	0 dB	96.55	95.91	96.98	82.67	80.39	79.06
	5 dB	98.24	98.40	98.72	82.95	84.37	83.68
	10 dB	98.40	98.77	98.78	87.91	88.18	88.98
	15 dB	98.76	98.76	96.09	89.63	89.31	91.18
AVE BABBLE	20 dB	98.76	98.76	96.09	90.64	89.71	93.18
		96.52	96.31	96.33	84.34	85.06	85.31
	−5dB	78.54	78.14	78.68	76.98	78.28	75.79
	0 dB	81.67	81.86	85.58	79.82	80.56	77.91
	5 dB	86.19	86.69	90.33	82.04	81.64	83.98
	10 dB	90.27	91.35	92.38	86.24	85.16	87.62
AVE MACHINEGUN	15 dB	82.89	92.53	93.25	87.66	87.04	90.59
	20 dB	82.89	93.01	93.25	89.71	88.69	91.90
		83.74	87.26	88.91	83.74	83.56	84.63
	−5dB	76.09	76.96	81.75	81.80	82.04	85.63
	0 dB	77.95	79.68	90.09	83.34	85.39	88.17
	5 dB	78.78	80.54	94.98	85.56	86.30	90.00
AVE	10 dB	80.21	81.77	96.36	89.08	88.29	90.04
	15 dB	82.58	75.44	95.93	88.57	89.26	92.12
	20 dB	81.88	75.26	95.93	90.68	89.77	93.68
		79.58	78.28	92.51	86.51	86.84	89.94

Le second tableau présente d'autres algorithmes temps/fréquence :

1. LTSV (Long term signal variability) : Il mesure la variabilité à long terme du signal vocal en analysant les différences entre les trames de signal adjacentes sur une période de temps prolongée.
2. LSFM (Long Term Signal Measure) : Pas d'informations fournies dans l'article. Se référer à : Ghosh PK, Tsiartas A, Narayanan S. Robust voice activity detection using longterm signal variability. J Audio Speech Lang Process IEEE Trans 2011;19 (3):600–13.
3. LSVM (Long Term Variability Measure) : Pas d'informations fournies ici non plus. Se référer à : Ma Y, Nishihara A. Efficient voice activity detection algorithm using long-term spectral flatness measure. J Eurasip J Audio Speech Music Process 2013;2013 (1):1–18.
4. BP (Bayesian Probability) : Cet algorithme utilise des modèles probabilistes pour détecter les points de début et de fin. Il évalue la probabilité que chaque échantillon du signal soit un point de début ou de fin, en utilisant des caractéristiques statistiques du signal.

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

5. SVM (Support Vector Machine) : C'est un algorithme d'apprentissage supervisé utilisé pour la classification et la régression. Il construit un hyperplan optimal qui sépare les données en différentes classes en maximisant la marge entre les échantillons les plus proches de chaque classe. Ici il est utilisé sur une transformée en ondelette du signal.
6. DNN (Deep Neural Network) : Les réseaux de neurones profonds ont été abordés à plusieurs reprises précédemment dans cet état de l'art.

Conclusion et remarques :

Cet article est intéressant car il met en avant quelques techniques de détection de signaux vocaux, y compris ceux dans du SNR faible. Les algorithmes avec les meilleures performances sont les algorithmes utilisant les caractéristiques à temps long des signaux. Une recherche approfondie sur la nature de ces caractéristiques et sur ces algorithmes semble nécessaire.

Ici on a listé les différents algorithmes présents dans cet état de l'art mais l'article étant déjà un résumé des différentes techniques, il n'est certainement pas pertinent de résumer les techniques plus que ce que je fais déjà cet article.

A survey of spectrogram track detection algorithms

[6]

Un spectrogramme est une représentation visuelle de la répartition de l'intensité d'un signal selon les fréquences et au fil du temps. L'axe vertical du spectrogramme représente généralement le temps, l'axe horizontal représente les différentes fréquences, et la puissance détectée est représentée comme l'intensité à chaque point temps-fréquence. Ce papier aborde la détection de signaux à partir du spectrogramme issu d'une FFT d'une acquisition réalisée.

L'estimateur par maximum de vraisemblance (MLE) est la première des techniques abordées. Elle est utilisée pour détecter des signaux dans un spectrogramme en comparant les données observées avec des modèles statistiques. Cette méthode permet de détecter des pistes temporellement invariantes, mais elle est limitée aux cas de rapport signal sur bruit élevé. Une approche basée sur la corrélation avec un spectrogramme de référence sans bruit permet de détecter des pistes à faible rapport signal sur bruit, mais elle nécessite un ensemble de référence important, ce qui rend son application en temps réel difficile.

Ensuite il est présenté plusieurs algorithmes de traitement d'image par des méthodes statistiques. La première d'entre elle est un test statistique de vraisemblance. Ce test utilise la distribution de probabilité d'un signal et du bruit pour détecter les pistes, mais il peut produire des pistes fragmentées et des fausses détections isolées.

La seconde approche est un processus de décision en plusieurs étapes pour la détection de pistes spectrales. Ils définissent une fonction de coût basée sur l'amplitude, la continuité et la courbure de la piste, qui est appliqué sur un algorithme d'optimisation de chemins. Cependant, cette méthode

présente des limitations, notamment en termes de mesure de continuité et de détection de pistes à faible amplitude ou de bruit à amplitude élevée mais de courbure élevée.

L'approche suivante utilise des filtres orientables ("steerable filters") pour détecter les contours dans un spectrogramme et extraire les pistes correspondantes. Elle permet d'améliorer la qualité de l'image en lissant les données et en détectant les contours à l'aide de filtres spécifiques. Cependant, elle nécessite une étape de seuillage manuel et peut être sensible à la présence de bruit à haute amplitude dans les régions détectées.

L'algorithme TPSW (Two-Pass Split-Window) permet d'estimer le bruit de fond à large bande dans un spectrogramme. Cette méthode permet de nettoyer l'image en soustrayant cette estimation du bruit, ce qui permet de mettre en évidence les pistes étroites. En définissant un seuil filtre la sortie et permet de détecter le signal mais si le seuil est mal sélectionné, le signal peut être éliminé en même temps que le bruit lorsqu'on est dans une situation de SNR faible.

La dernière méthode utilise des filtres gaussiens pour lisser le spectrogramme qui sera ensuite comparé à une mesure de bruit de fond. S'il cette mesure dépasse un seuil, on estime qu'il s'agit d'un signal. Encore une fois, dans du SNR faible, le signal peut évidemment ne pas dépasser la valeur seuil requise.

La partie qui suit dans l'article aborde les réseaux de neurones de classification supervisée ou non supervisée. L'article n'étant pas le plus récent et les techniques de Deep Learning supervisées appliquées à la détection et à la classification de signaux en faible SNR ayant déjà été abordés précédemment, nous ne les détailleront pas plus ici.

Il est ensuite présenté un ensemble de modèles statistiques dont le premier est une approche de programmation dynamique pour l'extraction de pistes basée sur la modélisation d'une piste de fréquence comme une marche aléatoire. L'approche consiste à définir une fonction de vraisemblance logarithmique qui prend en compte l'estimation de l'état de fréquence discrète, les probabilités de transition, l'écart type du bruit et le décalage de phase. L'objectif est de trouver la piste la plus probable qui maximise cette fonction de vraisemblance.

Les prochains algorithmes présentés sont basés sur les chaînes de Markov cachées (hidden Markov chains). Les premiers algorithmes abordent le traçage d'un signal unique dans une bande large de fréquence. On va supposer que dans le contexte du radar LPI, l'acquisition peut contenir plusieurs signaux d'intérêt et on se concentrera alors plutôt sur les chaînes de Markov appliquées au « multiple tracking ». Le premier de ces algorithmes cité dans l'article utilise une variation de l'algorithme F-B (forward-backward) utilisant le taux de variation de fréquence par piste. Un autre algorithme propose une approche "mixte" où le Viterbi est utilisé pour estimer les pistes potentiellement mixtes en utilisant la sortie seuillée de la STFT. Ils utilisent ensuite des informations sur l'amplitude et les probabilités de transition pour séparer les pistes mixtes en pistes individuelles. Enfin le dernier algorithme propose plusieurs HMM indépendant pour suivre plusieurs pistes puis un test de rapport de vraisemblance généralisé permet de déterminer les pistes à conserver.

L'algorithme abordé par la suite est celui du filtre à particule utilisé pour suivre les chemins de fréquence spectre par spectre. On estime le chemin que prendra une piste sur le spectre des acquisitions qui vont suivre puis dès que de nouvelles acquisitions sont disponibles, on met à jour le modèle. Cet algorithme est une généralisation du filtre de Kalman.

Enfin, les derniers algorithmes présentés ne sont à priori pas pertinent dans notre cas car ils réalisent du traçage sur une piste unique et émet donc l'hypothèse qu'il existe un et seulement un signal dans l'acquisition.

Tableau 6 : Récapitulatif des techniques abordées

Algorithm	C1 low SNR	C2 temporal noise variability	C3 birth/death tracks	C4 multiple tracks	C5 closely spaced tracks	C6 crossing tracks	C7 high track variability	C8 no a priori shape assumption	C9 track association	C10 computationally cheap
Maximum likelihood										
Single frequency [22]	N	Y	Y	N	N	N	Y	Y	Y	Y
Multi-harmonic [24]	N	Y	Y	N	N	N	Y	Y	Y	Y
Correlation [23]	-	N	Y	Y	Y	Y	Y	N	N	N
Image processing techniques										
Likelihood ratio and morphological operators [25]	-	Y	Y	Y	Y	Y	N	Y	Y	-
Multistage decision process [27]	-	Y	Y	Y	Y	Y	Y	Y	N	Y
Steerable filter and multistage decision [28,29]	N	Y	Y	Y	N	N	Y	Y	N	Y
Two-pass split-window [5]	N	Y	Y	Y	N	N	Y	Y	N	Y
Edge detector [30]	N	Y	Y	Y	N	Y	Y	Y	N	Y
Neural networks										
ASM and MLP [31]	N	-	N	N	N	N	N	N	Y	-
Multi-layer perceptron [32]	N	-	Y	Y	Y	-	N	N	N	-
MLP using Ockham's networks [33]	N	-	Y	Y	N	Y	Y	N	N	Y
Kohonen self-organising map [35]	N	Y	Y	Y	N	N	N	Y	N	-
MNET1 [34]	N	-	N	N	N	N	N	N	Y	Y
MNET2 [34]	N	-	N	N	N	N	N	Y	Y	Y
RNET [34]	Y	-	N	N	N	N	N	N	Y	Y
Statistical models										
Dynamic programming [36]	-	N	N	N	N	N	N	Y	Y	-
Viterbi and max amplitude [37]	-	N	Y	N	N	N	Y	Y	Y	-
Viterbi, "mixed" track and threshold [38]	-	N	Y	Y	Y	Y	N	Y	Y	-
Viterbi and "mixed" track [39]	-	N	Y	Y	Y	Y	N	Y	Y	-
Viterbi and double threshold [40]	-	Y	Y	Y	Y	N	N	Y	Y	-
Viterbi and PDA [41]	N	Y	N	N	N	N	N	Y	Y	-
Parallel, multi-model detection [42]	-	N	Y	Y	-	-	Y	Y	Y	-
F-B linking, SNR estimate and track gradient [43]	Y	Y	Y	Y	-	Y	Y	Y	Y	N
F-B linking and SNR estimate [44]	Y	Y	N	N	N	N	Y	Y	Y	N
Viterbi and SNR estimate [44]	Y	Y	N	N	N	N	N	Y	Y	N
F-B linking and spectrum interpolation [45]	-	Y	N	N	N	N	Y	Y	Y	-
Tracking algorithms										
Particle filter [10]	-	Y	Y	Y	N	N	Y	Y	Y	N
Relaxation methods										
Simulated annealing [46]	-	Y	N	Y	Y	N	N	Y	Y	N
Expert systems										
Double threshold and priority ranking [47]	-	-	Y	Y	Y	Y	Y	Y	N	Y

Conclusion et remarques :

Cet article est un état de l'art des différentes méthodes de détection et de traçage de signaux dans des spectrogrammes. De nombreux articles utilisent une image temps fréquence à base de spectrogramme pour détecter des signaux radars LPI, il est donc intéressant d'avoir une vision large et un historique de ces méthodes. Nous avons réalisé une description restreinte des différents algorithmes présents dans cet article.

Polyphase coded low probability of intercept signals detection and estimation using time–frequency rate distribution

[7]

Cet article aborde la détection et la caractérisation de signaux LPI modulés en code polyphasique. Les formes d'ondes abordées sont Frank, P1-P4. L'article propose l'utilisation de distributions de temps- ratio de fréquence (TFR). Par une transformée de Wigner-Ville et un spectrogramme (le carré de la STFT), les auteurs montrent que la concentration d'énergie est beaucoup plus faible

ETAT DE L'ART SUR LES TECHNIQUES DE DETECTION ET DE CLASSIFICATION DE SIGNAUX

pour les codes polyphasiques que pour les signaux modulés linéairement en fréquence, ce qui rend difficile l'extraction des caractéristiques du signal à l'aide de représentations temps-fréquence, notamment sous l'effet du bruit.

L'article propose d'utiliser à la place la TFR.

$$TFR(t, r) = \int x(t + \sqrt{\tau})x(t - \sqrt{\tau})e^{-irt} d\tau$$

Il est mentionné que cette technique est moins efficace pour détecter des LFM plutôt que d'utiliser la distribution de Wigner-Ville.

Le seuil de détection h_1 d'un signal est défini selon la valeur normalisée de l'enveloppe de détection $I(r)$:

$$I(r) = \int |TFR(t, r)| dt$$

Les valeurs de crête de la TFR se trouvent aux instants $n=ck/f$ avec c le CPP (nombre de cycle par phase) et f la fréquence normalisée (fréquence porteuse/fréquence d'échantillonnage). On peut donc estimer la f/c . Or comme sa valeur est égal à 0 pour un signal LFM, si sa valeur estimée dépasse un seuil h_2 , le signal est identifié comme étant un code polyphase. Ainsi, deux seuils sont initiés : h_1 pour déterminer si un signal est présent, h_2 pour déterminer s'il s'agit un signal polyphasique ou un signal LFM. Ce processus de détection est illustré sur le diagramme qui suit.




Figure 8 : Chaîne de détection des signaux à code polyphasique




Figure 9 : Performance pour la détection des formes d'onde polyphasique

Il est ensuite présenté différentes techniques afin d'estimer le nombre de code de phase dans le signal en se basant notamment sur la fréquence normalisée relative estimée et sur la durée de l'impulsion. Afin d'améliorer la précision de l'estimation il est proposé d'utiliser des distributions TFR d'ordre supérieur.

Une problématique est que le nombre de cycle par phase et la fréquence porteuse ne peuvent être distingués dans cette approche. Il est donc proposé réaliser une méthode cyclostationnaire pour estimer la fréquence porteuse puis de remonter au nombre de cycle par phase.

Conclusion et remarques :

Cet article présente une méthode de détection et de caractérisation basée sur la TFR plutôt qu'une classique distribution temps-fréquence. Elle ne s'adresse qu'aux signaux polyphasique et la caractérisation est partielle, manquant notamment l'estimation de la fréquence porteuse. L'algorithme a été testé sur des signaux dans un SNR bas et présente des résultats satisfaisant mais il semble être mention uniquement d'un unique signal dans du bruit et l'algorithme ne traite pas le cas de la détection de plusieurs signaux dans une même bande de fréquence.

Estimation of Modulation Parameters of LPI Radar Using Cyclostationary Method

[8]

Les méthodes T-F couramment utilisées comprennent la distribution de Choi-Williams (CWD), la distribution de Wigner-Ville (WVD), le banc de filtres en miroir en quadrature (QMFB), la méthode cyclostationnaire (CS), les techniques de transformation en ondelettes (WT) et la transformée en S-

modifiée (MST). Dans cette étude, la méthode cyclostationnaire est utilisée pour estimer les paramètres des signaux de radar LPI codés en Polytime.

L'analyse cyclostationnaire consiste à traiter les signaux comme des signaux périodiques pour exploiter leurs caractéristiques périodiques. Dans le cas des radars LPI, toutes les formes d'onde sont périodiques. Cette analyse transforme le signal dans le domaine de fréquence cyclique ou bifréquence, offrant ainsi des propriétés supplémentaires non disponibles dans le domaine temps-fréquence. Une propriété clé de l'analyse cyclostationnaire est la corrélation spectrale avec des versions décalées en fréquence du signal à certaines fréquences. Les propriétés spectrales du signal peuvent être observées à travers la fonction de densité de corrélation spectrale (SCD).

La fonction d'auto-corrélation cyclique (CACF) de $x(t)$ est donnée par :

$$CACF(\tau)_x^\alpha = \lim_{\tau \rightarrow \infty} \int_{-\frac{T}{2}}^{\frac{T}{2}} x\left(t - \frac{\tau}{2}\right) x^*\left(t + \frac{\tau}{2}\right) e^{-j2\alpha} dt$$

La fonction de densité spectrale (SCD) est obtenue en calculant la transformée de Fourier de la CACF.

La méthode DFS (direct frequency-smoothing) est appliqué pour calculer les coefficient de la SCD.

Une analyse complète des 4 types de modulations polytime (T1, T2, T3, T4) est ensuite présenté dans l'article. La stratégie présentée dans l'article consiste à tracer les contours de la SCD puis de mesurer les caractéristiques suivantes du signal : fréquence porteuse, largeur de bande et nombre de phase par code.

La stratégie est résumée sur le diagramme ci-dessous, elle est valable pour toutes les modulations polytime.




Figure 10 : Diagramme mesurant les paramètres de T1

Les résultats estiment qu'il est nécessaire d'avoir une fréquence d'échantillonnage d'au moins trois fois la fréquence porteuse pour obtenir une erreur acceptable de 10% sur les paramètres estimés.

Conclusion et remarques :

Cet article propose un algorithme basé sur une analyse cyclostationnaire des signaux polytime afin d'estimer leur fréquence porteuse, bande passante et nombre de cycle par phase. Les simulations n'ont pas pris en considération le SNR faible qui peut avoir lieu pour des signaux radars LPI. L'article ne considère pas non plus la tâche de détection en amont.

Bibliographies

- [1] D. Iatsenko, P. V. E. McClintock, et A. Stefanovska, « Extraction of instantaneous frequencies from ridges in time–frequency representations of signals », *Signal Processing*, vol. 125, p. 290-303, août 2016, doi: 10.1016/j.sigpro.2016.01.024.
- [2] X. Zha, H. Peng, X. Qin, G. Li, et S. Yang, « A Deep Learning Framework for Signal Detection and Modulation Classification », *Sensors*, vol. 19, n° 18, Art. n° 18, janv. 2019, doi: 10.3390/s19184042.
- [3] G. Ghadimi, Y. Norouzi, R. Bayderkhani, M. M. Nayebi, et S. M. Karbasi, « Deep Learning-Based Approach for Low Probability of Intercept Radar Signal Detection and Classification », *J. Commun. Technol. Electron.*, vol. 65, n° 10, p. 1179-1191, oct. 2020, doi: 10.1134/S1064226920100034.
- [4] D. George et E. A. Huerta, « Deep Learning for Real-time Gravitational Wave Detection and Parameter Estimation: Results with Advanced LIGO Data », *Physics Letters B*, vol. 778, p. 64-70, mars 2018, doi: 10.1016/j.physletb.2017.12.053.
- [5] « An overview of speech endpoint detection algorithms - ScienceDirect ». <https://www-sciencedirect-com.ezproxy.universite-paris-saclay.fr/science/article/pii/S0003682X19309521> (consulté le 12 juin 2023).
- [6] T. A. Lampert et S. E. M. O'Keefe, « A survey of spectrogram track detection algorithms », *Applied Acoustics*, vol. 71, n° 2, p. 87-100, févr. 2010, doi: 10.1016/j.apacoust.2009.08.007.
- [7] L. Jiang, L. Li, et G. Zhao, « Polyphase coded low probability of intercept signals detection and estimation using time–frequency rate distribution », *IET Signal Processing*, vol. 10, n° 1, p. 46-54, 2016, doi: 10.1049/iet-spr.2014.0020.
- [8] R. K. Chilukuri, H. K. Kakarla, et K. Subbarao, « Estimation of Modulation Parameters of LPI Radar Using Cyclostationary Method », *Sens Imaging*, vol. 21, n° 1, p. 51, oct. 2020, doi: 10.1007/s11220-020-00313-3.