

Académie de Nantes

THÈSE DE DOCTORAT DE L'UNIVERSITÉ DU MAINE

Spécialité : Acoustique

par

Mohamad DARWICHE

pour obtenir le titre de Docteur d'Université

**Apprentissage statistique pour l'évaluation
et le contrôle non destructifs : application
à l'estimation de la durée de vie restante des
matériaux par émission acoustique sous fluage**

Soutenue le 04 Juin 2013 devant le jury composé de :

S. HARIRI	Professeur, École des Mines de Douai, <i>Rapporteur</i>
N. GODIN	HDR, INSA Lyon, <i>Rapporteur</i>
R. EL GUERJOURMA	Professeur, Président de l'université du Maine, <i>Directeur de thèse</i>
D. SCHANG	HDR, Université François Rabelais de Tours, <i>Rapporteur</i>
G. BOUSALEH	Professeur, LOMC, Université du Havre, <i>Examinatrice</i>
J. IDIER	Enseignant-chercheur, ESEO, Angers, <i>Co-directeur de thèse</i>
N. CHEBBO	Professeur, GAUS, Université de Sherbrooke, Canada, <i>Invité</i>
M. KARAMA	Professeur, LAUM, Université du Maine, <i>Directeur de thèse</i>
J.H. THOMAS	Professeur, LAUM, Université du Maine, <i>Directeur de thèse</i>
M. BENTAHAR	Professeur, LAUM, Université du Maine, <i>Directeur de thèse</i>

Remerciements

Tout d'abord, je tiens à exprimer mes profonds remerciements à mon directeur de thèse, le professeur Rachid El Guerjouma, et mon co-directeur, Daniel Schang, et mon encadrant, Ghazi Bousaleh, pour la confiance qu'ils m'ont accordée, leurs disponibilités et leurs conseils avisés.

J'adresse mes sincères remerciements au professeur Saïd Hariri et l'HDR Nathalie Godin pour avoir accepté d'être rapporteurs de cette thèse et pour leurs précieuses recommandations et observations qui m'ont permis d'améliorer ce manuscrit.

Je remercie également le directeur de recherche Jérôme Idier, les professeurs Moussa Karama et Nazir Chebbo, et les collègues du LAUM Mourad Bentahar et Jean-Hugh Thomas, qui ont fait l'honneur de participer au jury de cette thèse. Pour leur aide et leur participation à ce projet, je remercie les membres du Laboratoire d'Acoustique de l'Université du Maine et particulièrement Rachid Berbaoui.

Je tiens à remercier tout le personnel du Groupe ESEO, et en particulier son directeur Monsieur Jacky Charruault, pour m'avoir permis de préparer cette thèse. Je souhaite vivement remercier mes collègues du Groupe Signal Image et Instrumentation, pour l'aide qu'ils m'ont apportée, et en particulier Guy Plantier, responsable du Département Électronique et Sciences Physiques, qui m'a permis de finaliser ce travail dans de bonnes conditions.

Merci également à mon cousin Samir Mourad et à mes amis qui m'ont apporté soutien et détente durant ces années de thèse ; Sami Laham, Ahmed et Mouhammed Gharba, Ghassan, Ahmad, Walid, Zaher, Hédi, et tous ceux qui s'y reconnaîtront. J'aimerais remercier du fond du cœur mes parents et mes frères et sœurs pour leur soutien moral et, bien sûr, pour leur relecture de mon travail.

Résumé

Les matériaux composites se caractérisent par une forte dispersion de leur durée de vie qui peut s'étendre de quelques minutes à plusieurs semaines lors d'un test de fluage. Lors d'un essai en fluage de ces matériaux nous distinguons trois phases de temps caractérisées chacune par une activité acoustique propre. Dans la première phase, le taux d'apparition des signaux d'EA est important, puis le taux diminue et atteint une valeur constante relativement faible durant la seconde phase, ensuite ce taux d'apparition s'accélère annonçant la troisième phase qui se termine par la rupture. Les caractéristiques des signaux d'émission acoustique (EA) émis dans la phase précédant la rupture sont différentes de celles des autres phases.

Le premier volet de cette étude consiste à utiliser des méthodes d'apprentissage relevant de l'intelligence artificielle (réseaux de neurones, machines à vecteurs de support et classifieurs bayésiens) afin de prédire si les signaux recueillis à partir d'un matériau sous test se trouve dans la phase de pré-rupture ou non. Ce sont des méthodes qui, appliquées à l'émission acoustique, permettent d'identifier parmi un grand nombre de signaux, caractérisés par des paramètres principaux, des classes de signaux ayant des paramètres voisins et donc provenant probablement de la même phase. Ces méthodes se sont avérées très performantes en classification, nous atteignons avec les SVM une sensibilité de 82 % et une spécificité de 84 % pour les résultats en validation croisée, et une sensibilité de 90 % et une spécificité de 94 % pour les résultats en test, avec un temps de calcul acceptable.

Le deuxième volet de l'étude effectué dans le cadre de cette thèse concerne l'estimation de la durée de vie restante des les matériaux composites. La normalisation des courbes cumulées des signaux d'émission acoustique en fonction du temps prouve que les réponses en fluage des éprouvettes mises en test sont parfaitement ressemblantes. Un modèle a été établi pour caractériser le comportement de ce matériau lors de ce test. Deux approches sont utilisées pour déterminer le temps de rupture. Par rapport à la littérature, la première approche proposée améliore la détection des temps de transition des différentes phases. Cette approche fournit également une meilleure corrélation avec le temps de rupture. La deuxième approche est fondée sur la corrélation du temps de rupture avec le temps de référence correspondant à la diminution de la vitesse d'un certain pourcentage. Les résultats de cette der-

nière approche sont très intéressants : l'estimation du temps de rupture pour une éprouvette ayant une durée de vie de 1 heure peut être possible dès les 15 premières secondes, avec une erreur de l'ordre de 4 %.

Mots-clefs

prédiction de durée de vie, émission acoustique, fluage, apprentissage statistique, matériaux composites, rupture.

Abstract

The composite materials are characterized by a high dispersion of their lifetime, which may extend from several minutes to several weeks in a creep test. When tested in creep of these materials we distinguish three phases, each characterized by its own acoustic activity. In the first phase, the occurrence rate of the AE signals is important, and then the rate drops to a relatively low constant value during the second phase, then this occurrence rate accelerates announcing the third phase which ends by a rupture. The characteristics of the acoustic emission (AE) signals in the phase preceding the rupture are different from those of other phases.

The first part of this study is to use learning methods from artificial intelligence (neural networks, support vector machines and Bayesian classifier) to predict if the signals collected from the material under test in the pre-rupture or not. These are methods which, when applied to acoustic emission, identify among a large number of signals, characterized by key parameters, classes of signals having similar parameters and thus probably from the same phase. These methods have proved highly effective in classification; we reach the SVM with a sensitivity of 82 % and a specificity of 84 % for cross-validation results, and a sensitivity of 90 % and a specificity of 94 % for test results, with an acceptable calculation time.

The second part of the study in the framework of this thesis concerns the estimation of the remaining life of composites. Standardization of signals accumulated acoustic emission curves as a function proves that the responses of the creep test pieces are set perfectly similar. A model was developed to characterize the behavior of this material during this test. Two approaches are used to determine the time of rupture. Compared to the literature, the first proposed approach improves the detection time of transition phases. This approach also provides a better correlation with the rupture time. The second approach is based on the correlation of rupture time with the reference time corresponding to the decrease of the speed by a percentage. The results of this latter approach is very interesting : the estimation of the rupture time for a test piece having a life of one hour may be possible from the first 15 seconds, with an error of about 4 %.

Mots-clefs

lifetime prediction, acoustic emission, creep test, statistical Learning, composite materials, rupture.

Table des matières

Remerciements	iii
Résumé	v
Abstract	vii
Introduction générale	1
1 Matériaux composites	5
1.1 Introduction	6
1.2 La matrice	6
1.2.1 Les résines thermodurcissables	7
1.2.2 Les résines thermoplastiques	7
1.2.3 Propriétés	7
1.3 Les renforts	8
1.3.1 Les fibres de verre	9
1.3.2 Autres types de fibres	9
1.3.3 Les interfaces	10
1.4 Comportement sous sollicitation mécanique	10
1.4.1 Comportement en fluage	11
1.4.2 Endommagement	12
1.4.2.1 Microfissure de la résine ou fissuration matricielle	13

1.4.2.2	Délaminage	13
1.4.2.3	Rupture de fibres	14
1.4.2.4	Rupture des interfaces ou décohésion fibre-matrice	14
1.4.2.5	Influence de la direction des fibres sur les modes d'endommagement	14
1.5	Émission acoustique	15
1.5.1	Définition	15
1.5.2	Effet Kaiser et rapport Felicity	16
1.5.3	Dispositif expérimental	17
1.5.3.1	Élaboration des éprouvettes	17
1.5.3.2	Chaines d'acquisition d'EA	18
1.5.3.3	Paramétrage du logiciel d'acquisition	19
1.5.3.4	Paramètres temporels	20
2	Endommagement des matériaux sous fluage : identification des signaux d'EA précurseurs de la rupture	23
2.1	État de l'art sur la discrimination des classes	24
2.1.1	Analyse temporelle	24
2.1.2	Analyse statistique multivariable	27
2.2	Problématique et méthodologie	29
2.3	Apprentissage artificiel et discrimination	31
2.3.1	Approches pour la discrimination	31
2.3.2	Classifieurs bayésiens	31
2.3.3	Machines à Vecteurs de Support	33
2.3.3.1	Cas des données linéairement séparables	34
2.3.3.2	Cas des données linéairement non-séparables	37
2.3.4	Réseaux de neurones artificiels	38

2.3.4.1	Introduction	38
2.3.4.2	Principe du neurone artificiel	40
2.3.4.3	Architecture	42
2.3.4.4	Apprentissage	44
2.3.4.5	Type d'apprentissage	45
2.3.5	Prédiction	46
2.3.5.1	Introduction	46
2.3.5.2	Régression linéaire	47
2.3.6	Mesures des performances d'un test	48
2.3.6.1	Indices synthétiques de la performance d'un test . . .	48
2.3.6.2	Courbes de ROC	51
2.3.6.3	Comparaison de modèles par analyse des courbes de ROC	52
2.4	Application	53
2.4.1	Sélection des signaux d'EA	54
2.4.2	Extraction des paramètres	54
2.4.3	Normalisation des données	56
2.4.4	Données aberrantes	57
2.4.5	Réduction du nombre des paramètres	59
2.4.6	Validation croisée	60
2.4.7	Résultats et discussions	61
2.4.7.1	Résultats de la validation croisée	62
2.4.7.2	Résultats du test final	64
2.5	Conclusion	65
3	Estimation par émission acoustique de la durée de vie des maté- riaux sous fluage	67

3.1	Introduction	67
3.2	État de l'art de l'estimation de la rupture	70
3.3	Analyse et modélisation de l'évolution du nombre de signaux d'EA . .	73
3.3.1	Traitements préliminaires des signaux d'EA	73
3.3.2	Normalisation	73
3.3.3	Caractérisation du phénomène d'EA	75
3.3.4	Vitesse d'apparition des signaux acoustiques	77
3.4	Estimation de la durée de vie	79
3.4.1	Estimation à partir du temps de transition	80
3.4.1.1	Détection des temps de transition	80
3.4.1.2	Estimation à partir des moyennes des temps de transition	81
3.4.1.3	Estimation à partir des temps de transition de la courbe moyenne	83
3.4.2	Estimation en étudiant la vitesse d'apparition des signaux d'EA	86
3.4.2.1	Estimation à partir des moyennes des temps de référence	87
3.4.2.2	Estimation à partir des temps de référence de la courbe moyenne	90
3.5	Conclusion	92
	Conclusion générale et perspectives	95

Introduction générale

Les matériaux composites sont très utilisés dans des domaines d'application industriels très variés. On les trouve dans les avions, les automobiles, les bateaux, les cartes des circuits imprimés, voire même des structures de génie civil tels que les ponts. Ces matériaux sont caractérisés par leur résistance mécanique remarquable associée à une légèreté qui est très recherchée. Au vu de ces propriétés, les industriels cherchent de plus en plus à élargir leurs domaines d'application. Ainsi se sont-ils intéressés au remplacement des matériaux métalliques par des composites plus légers et tout aussi résistants. En outre, un enjeu majeur réside dans l'évaluation du comportement à long terme de ces matériaux. Durant ces dernières années, la durée de vie des structures en matériaux composites fut une problématique importante pour les chercheurs. Les efforts exercés dans les techniques d'élaboration pour améliorer la durabilité de ces matériaux n'ont pas abouti à des solutions exemptes de défauts. Ceci tient en partie à la constitution hétérogène de ces matériaux et à leur complexité structurale. Ainsi, le contrôle de l'état de santé de ces matériaux devient une nécessité incontournable pour garantir une sécurité accrue. Une des techniques de contrôle non destructif est l'analyse de l'émission acoustique du matériau sous test. Elle se réfère à la génération d'ondes élastiques transitoires produites par une redistribution brutale des contraintes dans un matériau. L'émission acoustique (EA), contrairement à la plupart des autres techniques de contrôle non destructif (CND), se rapporte à l'origine du signal. Ainsi, au lieu de fournir de l'énergie à l'objet en cours de test ; l'EA écoute simplement l'énergie libérée par l'objet. L'EA est caractérisée par sa sensibilité aux endommagements locaux dans les matériaux.

Dans notre étude, des essais de fluage par traction, avec enregistrement des données d'EA, ont été menés sur des éprouvettes constituées de composites de fibre de verre unidirectionnelles renforcées avec de la résine. Pour étudier la durabilité des matériaux composites, notamment sous sollicitation de fatigue, il est important de détecter la limite de leur résistance mécanique, signalant la fin de leur durée de vie pour éviter de mettre en danger la structure complète. Des études précédentes [Anastassopoulos and Philippidis, 1995, Ono and Huang, 1994, Nechad, 2004] ont étudié l'évolution des mécanismes d'endommagement dans les matériaux durant l'avancement de l'essai de fatigue. Les auteurs ont démontré que les paramètres tels

que l'amplitude ou l'énergie, par exemple, des signaux d'EA qui précèdent la rupture ont des valeurs très importantes par rapport aux paramètres de signaux qui apparaissent bien avant la rupture. Dans notre étude, nous avons établi une discrimination des signaux en rapport avec leur instant d'apparition. Plus précisément, nous avons discriminé les signaux en deux familles : celle qui précède la rupture et celle qui est bien avant la rupture. Pour atteindre notre objectif, nous avons utilisé des machines d'apprentissage statistique comme les machines à vecteurs de support, les réseaux de neurones et les classifieurs bayésiens. Ce sont des méthodes qui relèvent de l'intelligence artificielle et qui sont très performantes pour discriminer les signaux identifiés selon certains paramètres. La discrimination des signaux d'EA selon leurs mécanismes d'endommagement a été l'objet de plusieurs études [Benzegagh and Barre, 1994, Chen et al., 1992, Kim and Lee, 1997, Godin et al., 2004]. Ces chercheurs ont utilisé un ou plusieurs paramètres calculés sur les salves d'EA. Dans notre travail, la discrimination de ces signaux a été fondée sur l'utilisation de paramètres temporels pertinents.

Un autre point intéressant pour les industriels réside dans l'évaluation du comportement des matériaux composites à long terme afin d'estimer leur durée de vie restante. Il existe peu de travaux de recherche dans ce domaine [Thummen, 2004, Nechad, 2004, Berbaoui et al., 2009]. Notre contribution se situe également dans ce cadre. Nous avons proposé un modèle normalisé de la caractéristique d'EA, ce modèle a été établi à partir des résultats des essais effectués. Le modèle proposé donne une description précise du comportement du matériau composite testé en fluage. En effet, l'analyse de l'apparition des signaux d'EA à partir du modèle proposé, nous renseigne sur les propriétés et le comportement des composites testés, permettant ainsi, de prédire le moment de la rupture du matériau et donc d'évaluer dans la suite la durée de vie restante pour les matériaux en service.

On notera que nous avons décidé d'organiser ce manuscrit de façon non conventionnelle en proposant une étude bibliographique diffuse au sein des différents chapitres.

Le premier chapitre présente une synthèse bibliographique portant sur les matériaux composites. Il comporte une description des différents constituants des matériaux de types matrice-renfort. Dans ce chapitre, nous exposons le comportement des matériaux sous essai de fatigue à l'aide de techniques expérimentales non destructives comme l'émission acoustique, et le suivi et la caractérisation des endommagements résultants.

Le deuxième chapitre est consacré à l'étude qui permet de savoir si le matériau est en fin de vie ou non et de prédire ainsi si la rupture est imminente ou non. Ce chapitre débute par une exposition d'un état de l'art des travaux effectués pour la discrimination des mécanismes d'endommagement. Nous détaillons ensuite les

machines d'apprentissage statistique utilisées pour la discrimination des signaux (les machines à vecteurs de support, les réseaux de neurones et les classifieurs bayésiens). La technique utilisée pour la prédiction de la rupture est présentée ensuite. L'analyse et le traitement des signaux d'EA pour extraire les données utiles afin d'obtenir les meilleurs résultats de prédiction sont détaillés. Nous présentons, par la suite, la technique de validation de nos résultats pour chaque outil utilisé ainsi que les résultats des tests sur de nouvelles données. Une comparaison des résultats des différentes méthodes est fournie en fin de ce chapitre.

Le troisième chapitre est consacré à l'établissement et l'exploitation d'un modèle normalisé de la caractéristique d'EA pour les matériaux composites. Dans un premier temps, l'analyse de la réponse en fluage des matériaux en termes d'émission acoustique est élaborée. Puis, nous exposons le modèle mathématique standard construit à partir des courbes cumulées normalisées des signaux d'EA. Ensuite, nous détaillons les deux nouvelles méthodes que nous avons proposées pour estimer la durée de vie restante. La première méthode se base sur la détermination du temps de rupture à partir des temps de transition. La deuxième méthode s'appuie sur la détermination du temps de rupture à partir des temps de références qualifiants le gradient de la courbe d'EA dans la première phase. Les deux méthodes utilisées sont validées par la suite à l'aide de la technique de validation croisée. Une comparaison des techniques utilisées dans chacune des deux méthodes est également détaillée dans ce chapitre.

Chapitre 1

Matériaux composites

Les matériaux composites sont de plus en plus utilisés dans l'industrie [Marec et al., 2008]. Leurs premiers développements ont été liés aux besoins de l'industrie aérospatiale pour des applications où sont recherchés des matériaux caractérisés par une haute performance mécanique associée à un faible poids (figure 1.1).

Dans ce chapitre, nous présentons des généralités sur la composition des matériaux composites, leurs comportements et les mécanismes d'endommagement sous sollicitation mécanique. Nous détaillons également la technique des tests fondée sur l'enregistrement des émissions acoustiques qui sera utilisée pour prédire la durée de vie restante du matériau.

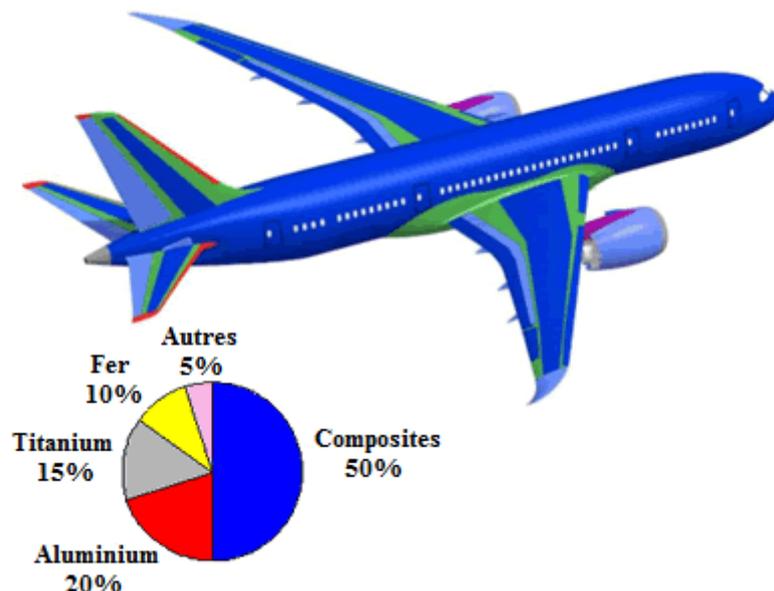


FIGURE 1.1 – Les matériaux composites représentent 50% de la constitution d'un avion [Ouahbi, 2013].

1.1 Introduction

Un matériau composite est constitué du mélange de deux ou de plusieurs matériaux de natures différentes. Le matériau composite présente des performances mécaniques supérieures à celles de ses composants pris séparément. Un matériau composite est constitué souvent d'un matériau de base nommé la matrice (résine, métal) renforcé par des fibres et/ou des inclusions (comme le verre, le carbone et les roches) nommés les renforts (figure 1.2). Le rôle des renforts est d'augmenter les propriétés mécaniques du matériau. La matrice permet d'assembler ces renforts tout en assurant la transmission des sollicitations mécaniques vers ces derniers. Ces matériaux sont très utilisés dans l'industrie dans différents domaines d'application :

- électricité (isolant électrique) et électronique (connecteurs composites),
- bâtiment (béton) et travaux publics (câbles des ponts),
- transports routiers, ferroviaires, maritimes, aériens et spatiaux (figure 1.1), sports et loisirs (skis, raquette de tennis, planche à voile, surf, club de golf, aviron).

L'utilisation massive de ces composites provient de leurs propriétés : légèreté, résistance à la fatigue, résistance à la corrosion, dureté et souplesse, isolation, facilité de mise en œuvre.

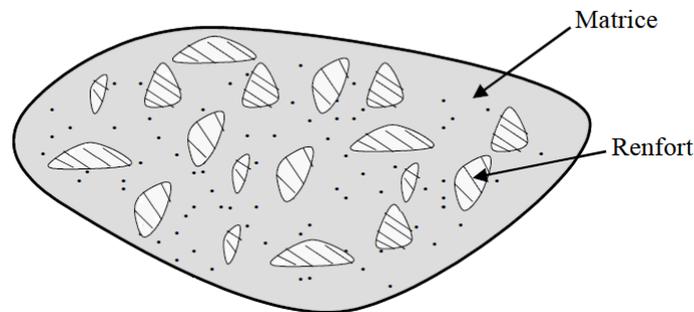


FIGURE 1.2 – Composition des matériaux composites en général [Nechad, 2004].

1.2 La matrice

La matrice est un matériau organique léger, c'est le constituant de base des matériaux composites. Cette matrice est relativement déformable et a comme principales fonctions la répartition de la charge mécanique vers tous les renforts et la protection des renforts contre les changements environnementaux [Chevalier, 1988].

Il existe deux grandes familles de matrices pour les composites à polymère : les résines thermodurcissables et les résines thermoplastiques.

1.2.1 Les résines thermodurcissables

Les résines thermodurcissables sont des polymères qui se transforment en produits essentiels infusibles et insolubles après un traitement thermique. Ces résines, sous forme liquide à l'état initial, passent à l'état solide en subissant une transformation irréversible. On distingue deux familles de résines thermodurcissables [Berthelot, 1996] : les polyesters insaturés (polyesters condensés, vinylesters, etc. . .) et les résines époxydes.

Les polyesters, les plus utilisés, sont généralement renforcés par des fibres de verre (pare-chocs, carrosserie, coques de bateaux, piscines, éléments de tramway ou de TGV).

Les époxydes, aux caractéristiques mécaniques supérieures, sont généralement renforcés par des fibres de carbone ou de verre (longerons, dérives, nacelles, voilure, bateaux et automobiles de compétition).

1.2.2 Les résines thermoplastiques

À l'état initial, les résines thermoplastiques sont sous forme de granulés, de fibres courtes et longues. Ces résines présentent une aptitude, à l'état liquide, à se mouler facilement par plasticité. Leur mise en œuvre se fait en général par injection à haute pression. Les principales résines thermoplastiques sont à base de polyamide, polyéthylène, polycarbonate et polychlorure de vinyle (PVC).

Ces résines, à l'inverse des thermodurcissables, sont déjà polymérisées : elles sont soumises à un échauffement et elles conservent leur forme après refroidissement.

1.2.3 Propriétés

Les principales caractéristiques des résines thermodurcissables et des résines thermoplastiques sont présentées dans le tableau 1.1. La matrice constituant le matériau composite de notre étude est une résine thermodurcissable de polyester insaturée.

TABLE 1.1 – Caractéristiques des résines thermoplastiques et des résines thermodurcissables [Berthelot, 1996].

Critères essentiels	Matrices thermoplastiques	Matrices thermodurcissables
Etat de base	Solide (prêt à emploi : polymérisé)	Liquide visqueux à polymériser
Stockage matière de base	Illimité	Temps réduit (précautions à prendre)
Mouillabilité des renforts	Difficile	Aisée
Moulage	Chauffage (fusion + refroidissement de fixation)	Chauffage continu
Cycle	Plus long (refroidissement)	Court
Tenue en choc	Assez bonne	Limitée
Tenue thermique	Réduite	Meilleure
Chute et déchets	Recyclables	Perdus

1.3 Les renforts

Ce sont des fibres d'origine minérale, organique ou végétale qui assurent la résistance aux efforts et participent à la rigidité. Le rôle du renfort est d'augmenter les propriétés mécaniques des matériaux composites grâce à ses caractéristiques mécaniques élevées (modules et limite d'élasticité, résistance mécanique) [Gay, 1997]. Il existe deux types de renforts : les fibres courtes et longues (continues).

- Les fibres courtes : ces fibres sont utilisées pour les pièces de petite taille avec les résines thermoplastiques. Ces pièces, moulées par injection, ont des caractéristiques mécaniques réduites (cache-culbuteurs, tubulures d'admission, pales de ventilateur...). Avec les résines thermodurcissables, les fibres courtes sont utilisées pour des températures supérieures à 150 °C.
- Les fibres longues : ces fibres, associées à une matrice polyester, sont réservées aux pièces de grande diffusion (skis, planches de surf). En les associant à une matrice époxyde, ces fibres sont réservées aux pièces nécessitant des performances élevées (par exemple, rampe accès de l'avion de transport militaire A400M, renforts de ponts).

1.3.1 Les fibres de verre

Les fibres de verre sont les plus utilisées actuellement dans les composites à matrice polymère ; ceci est dû à leur excellent rapport qualité/prix (cf. figure 1.3). Ce sont les premiers matériaux de renfort utilisés dans les composites dès les années quarante. Elles sont élaborées à partir d'un verre filable (textile) composé de silice, alumine, chaux, magnésie, etc. Elles possèdent une résistance élevée à la rupture. Les fibres sont sensibles aux endommagements superficiels (rayures) qui limitent leur résistance mécanique et créent des zones de concentration de contraintes. Dans le but de remédier à ce problème, un enduit est utilisé lors de la fabrication pour recouvrir les fibres afin d'empêcher tout contact entre les fibres favorisant ainsi l'adhésion entre les fibres et la matrice [Marec et al., 2008].

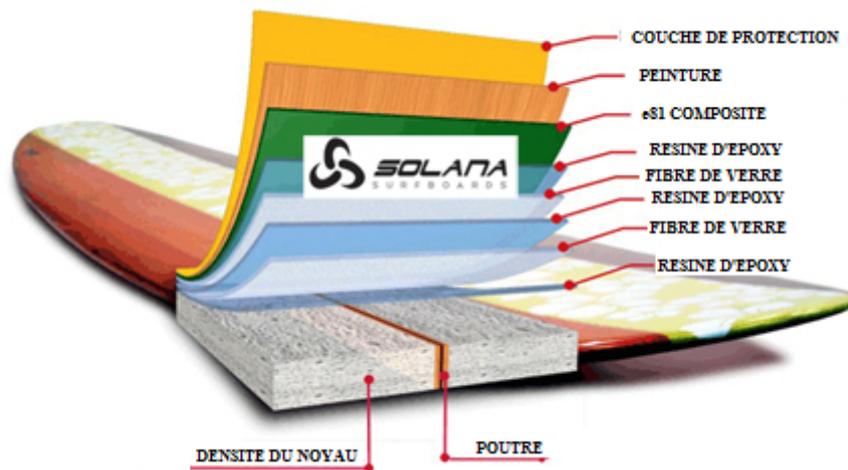


FIGURE 1.3 – La résine et les fibres de verre sont les constituants principaux d'une planche de surf [Solana, 2013].

D'une manière générale, elles présentent une résistance élevée à la rupture, une masse volumique faible (voisine de $2,5 \text{ g/cm}^3$) et une rigidité relativement plus faible que celles des autres renforts [Nechad, 2004].

1.3.2 Autres types de fibres

Il existe des fibres de polymère connues pour leur faible rigidité allant de 1 à 20 GPa. Ces fibres sont souvent utilisées dans les renforcements. Néanmoins, de nouvelles fibres polymères de type polyamide aromatique, connues sous le nom de « Kevlar », sont essentiellement utilisées dans la fabrication des câbles, des pneumatiques (à la place des fibres d'acier) et comme renforts à haute performance. Ces fibres polyamides aromatiques ont une rigidité supérieure à celle des fibres de verre (130 GPa).

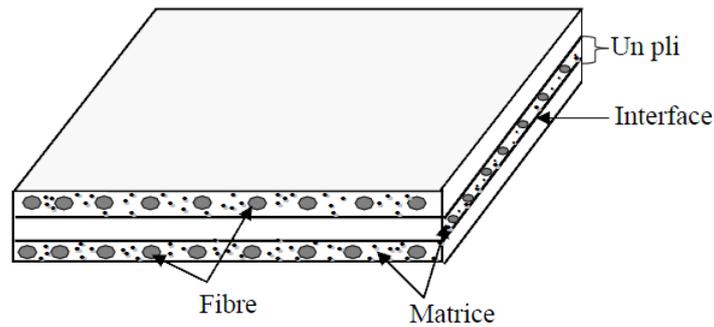


FIGURE 1.4 – Micro-structure d'un matériau composite [Nechad, 2004].

Il existe des fibres de carbone qui sont fabriquées suite à une carbonisation des fibres polymères. Elles ont des propriétés remarquables du fait d'une forte orientation préférentielle des cristallites parallèlement à l'axe des fibres. Cela se traduit par une rigidité et une résistance très élevées dans la direction longitudinale, associées à un très faible coefficient de dilatation linéique dans cette direction. Selon le procédé de fabrication, leur module de Young peut monter jusqu'à 420 GPa [Dorlot et al., 1986].

1.3.3 Les interfaces

L'interface a pour but de protéger la fibre ou de contrôler la liaison interfaciale, ou bien encore de contribuer à améliorer la compatibilité chimique fibre/matrice. Elle assure la compatibilité renfort-matrice, en transmettant les contraintes de l'un à l'autre, sans déplacement relatif (interphase). Elle est souvent considérée comme une surface de contact, mais pas au sens géométrique du terme.

L'interface peut être considérée, du fait de sa structure, comme un point faible du composite d'un point de vue mécanique [Khavandi, 1997]. Dans le transfert d'effort orienté dans le sens de l'axe de la fibre, l'interface est considérée comme une couche de cisaillement. Lorsqu'il n'y a pas de décohésion interfaciale, le comportement est élastique : le cisaillement interfacial est linéairement proportionnel à la différence de déplacement entre la matrice et la fibre au niveau de leur paroi interfaciale [Kafrou, 2006] (figure 1.4).

1.4 Comportement sous sollicitation mécanique

Lorsqu'ils sont soumis à des contraintes extérieures, les matériaux composites subissent divers types de dégradations résultant des endommagements de la matrice, des fibres et de l'interface fibre-matrice [Kharoubi et al., 2010, Nechad, 2004,

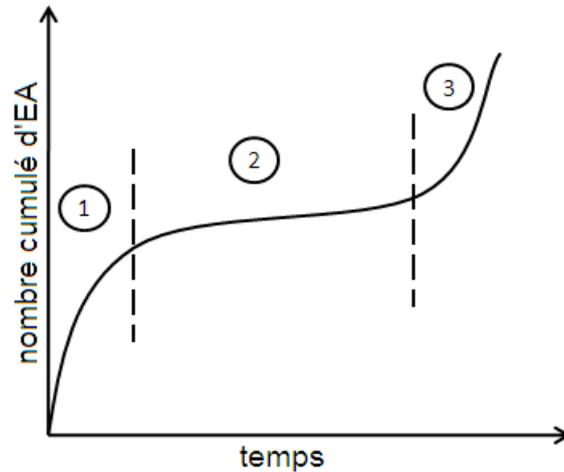


FIGURE 1.5 – Courbe typique d'EA d'un test de fluage.

Bentahar, 2005]. De manière générale, ces mécanismes se produisent simultanément, réduisant ainsi les propriétés mécaniques du matériau composite. Ces mécanismes de dégradation dépendent de la nature des matériaux et des conditions de stress mécaniques imposées. Dans un matériau composite, la redistribution des contraintes, et par conséquent le processus de rupture qui en résulte, dépend principalement des caractéristiques de rupture des fibres, de la capacité des matrices à absorber l'énergie libérée, des propriétés d'interface de fibre-matrice, de la densité volumique en fibres, et des conditions de stress mécaniques imposées [Thummen, 2004, Godin, 2009].

1.4.1 Comportement en fluage

Le fluage est la déformation lente d'un matériau qui se produit sous l'effet d'une contrainte mécanique à température constante [Journaux 1999]. Dans les métaux, le fluage n'intervient généralement qu'à haute température. Le fluage à température ambiante, qui concerne surtout les matières plastiques, est appelé « fluage à froid » ou « déformation sous charge ». Les résultats d'un essai de fluage sont généralement présentés sous la forme d'une courbe représentant le nombre cumulé de salves acoustiques en fonction du temps. Cette courbe est obtenue à contrainte et à température constantes. La pente de la courbe représente la vitesse de fluage et son point final représente l'instant de la rupture. Comme l'indique la figure 1.5, le fluage d'un matériau peut être décomposé en trois étapes. La première étape, ou fluage primaire, commence à vitesse très rapide puis ralentit avec le temps. La deuxième étape (fluage secondaire) s'effectue à vitesse relativement constante. La troisième étape (fluage tertiaire) présente une accélération soudaine et s'achève avec la rupture du matériau.

Phase 1 : l'application de la contrainte, à l'instant $t = 0$, provoque une déformation instantanée élastique, suivie d'une déformation dépendant du temps (zone 1 de la figure 1.5) il s'agit du fluage primaire ou transitoire. Cette zone s'étend sur un intervalle de temps d'autant plus réduit que les conditions de sollicitation sont sévères. Certains auteurs [Shen and Rutherford, 1972] expliquent ce phénomène comme suit : initialement, les liaisons du réseau macromoléculaire ne sont pas orientées, il y a donc peu de mouvement ce qui explique que la vitesse de fluage primaire est importante. Ensuite il y a une réorganisation du matériau (alignement des fibres et orientation de la structure moléculaire des matrices) qui a pour effet d'augmenter la résistance au fluage provoquant ainsi une baisse de la vitesse de déformation.

Phase 2 : c'est une zone très étalée dans le temps et donc la plus longue durant tout l'essai de fluage, appelée zone de fluage secondaire ou stationnaire. La déformation varie linéairement en fonction du temps, en d'autres termes la vitesse de déformation est constante. Il est par ailleurs établi que les mécanismes d'endommagement qui se produisent dans cette zone contrôlent la suite du test de fluage [Nechad, 2004].

Phase 3 : la zone de fluage tertiaire est caractérisée par une accélération brutale et continue de la vitesse de déformation (zone 3 de la figure 1.5). Cette zone est associée à l'apparition d'un endommagement croissant allant jusqu'à la rupture du matériau.

1.4.2 Endommagement

La sollicitation des matériaux composites exposés à des contraintes externes provoque différents types de dégradations résultant de l'endommagement local au niveau de la matrice, des fibres et de l'interface fibre-matrice. Dès que les premiers endommagements apparaissent, ils commencent à se développer à l'échelle microscopique en devenant des microfissures, mais ces dernières sont habituellement trop petites pour causer la rupture finale du composite. Ainsi, un nombre important de ces microfissures s'accumulent dans le composite causant la rupture finale. Le processus de rupture des fibres dépend principalement de la contrainte imposée, de la capacité de la matrice à absorber l'énergie libérée, des propriétés de l'interface fibre-matrice, de la fraction volumique des fibres ainsi que de l'état et des conditions de sollicitation mécanique imposées. Finalement, on constate que l'accumulation de différents types d'endommagements cause la rupture dans les matériaux composites [Nechad, 2004]. Quatre modes d'endommagement principaux peuvent être présents, notamment dans les composites base polymère soumis à une sollicitation mécanique (figure 1.6) [Marec et al., 2008, Marec, 2008] : la fissuration matricielle, la rupture des fibres, la décohésion interfaciale (fibre-matrice) et les délaminages.

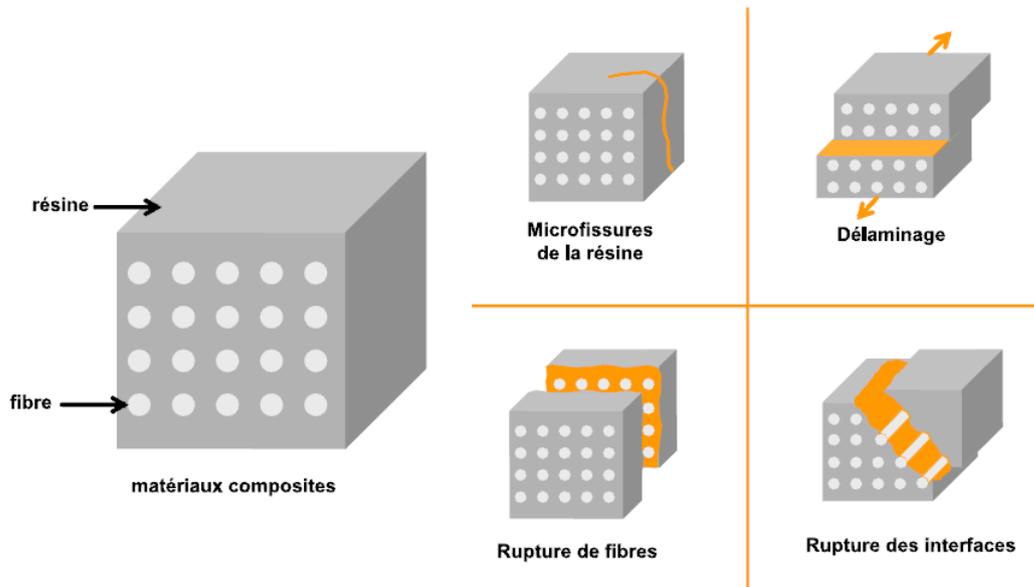


FIGURE 1.6 – Matériaux composites composés de résine renforcée par des fibres de verre et principaux modes d’endommagement [Marec, 2008].

1.4.2.1 Microfissure de la résine ou fissuration matricielle

Les endommagements apparaissant au sein de la matrice se présentent soit par des fissurations transverses soit par des fissurations longitudinales. Les premières se produisent lorsque la contrainte en traction atteint la contrainte de rupture de la matrice, alors que les secondes ont lieu généralement au voisinage d’une fibre lorsque la contrainte de décohésion est supérieure à celle du cisaillement. Ces fissurations se propagent perpendiculairement à la direction de la sollicitation et elles peuvent provoquer des décohésions fibre-matrice [Berthelot, 1996].

Les résistances à la rupture des composites industriels à fibres de verre peuvent être limitées par une déformabilité trop faible de la matrice. Il est donc nécessaire d’adapter au mieux les propriétés de la matrice à celles des fibres pour optimiser les performances des matériaux composites.

1.4.2.2 Délaminage

Le délaminage est un type d’endommagement entre couches qui intervient dans le cas d’un stratifié. Il résulte de l’accumulation de plusieurs types d’endommagement et dépend de la nature des constituants, du mode de sollicitation imposée et de l’architecture des couches. Le délaminage apparaît par des fissurations interlaminaires. Ces fissurations sont considérées comme la première cause de l’évolution de l’endommagement. Après la phase d’endommagement intra-laminaire, qui est également induite par les fissures inter-laminaires (causées par les ruptures de ma-

trice, de fibre et d'interface), le délaminage commence souvent sur les bords avant de s'étendre sur toute l'éprouvette. Il correspond à une fissuration qui a tendance à séparer les plis ou couches du composite. Ce type d'endommagement contribue largement à la dégradation des propriétés mécaniques de la structure.

1.4.2.3 Rupture de fibres

Dans les matériaux composites, la rupture des fibres est souvent présente lorsque l'orientation des fibres est dans la direction de la sollicitation. Elle a lieu lorsque la contrainte de rupture de la fibre est atteinte. L'évolution de la rupture de fibres provoque l'endommagement du voisinage comme la fissuration matricielle. L'endommagement produit ne cesse de progresser tant que la contrainte est appliquée, en provoquant finalement la rupture du matériau.

1.4.2.4 Rupture des interfaces ou décohésion fibre-matrice

Les constituants des matériaux comme les fibres et la matrice doivent être soigneusement choisis en les soumettant à des contrôles précis. Cependant dans la pratique, la zone d'interface issue de leur interaction ne peut pas être totalement maîtrisée [Favre, 1992]. C'est dans cette zone où s'effectue le transfert de charge de la matrice vers le renfort ou vice versa. L'évolution de l'endommagement évolue selon la nature de l'adhésion fibre-matrice. Dans le cas d'un composite à fibres unidirectionnelles sollicité parallèlement aux fibres, si l'interface est très forte, on aura une propagation de la fissure initiée soit par rupture de fibres, soit par rupture de la matrice comme si elle n'avait rencontré aucun obstacle, la rupture observée sera de type fragile. Mais si l'interface est très faible, la fissuration matricielle est déviée vers l'interface et la décohésion fibre-matrice s'étend sur une très grande distance. Finalement, si l'interface a des propriétés intermédiaires, la fissure au contact d'une fibre dévie dans un plan perpendiculaire en provoquant un décollement de la matrice au niveau de l'interface.

1.4.2.5 Influence de la direction des fibres sur les modes d'endommagement

Lors d'un essai de traction dans le sens de l'axe des fibres, trois modes d'endommagement apparaissent. Au début, des fissurations de matrice se développent perpendiculairement aux fibres et entraînent des décohésions au niveau des interfaces. L'accumulation de l'endommagement crée des zones de concentration de contraintes et provoque en fin d'essai la rupture des fibres.

Dans le sens perpendiculaire à l'axe des fibres, seules la matrice et les interfaces sont sollicitées, des microfissures s'y développent au niveau des défauts ; la qualité d'adhésion fibre/matrice détermine ensuite quel type de microfissures se propagera provoquant la rupture de l'échantillon.

La répartition entre les modes d'endommagement varie en fonction de l'inclinaison des fibres par rapport à la direction de sollicitation [Thummen, 2004]. Par conséquence, les tests sur des fibres avec une inclinaison de 45° par rapport à l'axe de traction entraînent le maximum de risques au niveau du cisaillement [Gay, 1997]. Cette configuration est donc la plus favorable au développement d'un endommagement inter-facial par cisaillement [Kawai, 1999].

1.5 Émission acoustique

L'émission acoustique est une des techniques de contrôle non destructif qui permet de surveiller l'endommagement en temps réel dans les matériaux composites. L'intégration d'une des méthodes non destructives comme l'émission acoustique est devenue nécessaire afin de suivre l'état de dégradation des matériaux composites. Cette technique est très utilisée au sein de nombreux domaines d'application : les infrastructures de transport (secteurs automobiles, ferroviaire, aérien) et d'habitat, les matériaux aéronautiques, pour ne citer que les principaux.

1.5.1 Définition

Selon la norme française AFNOR, « le phénomène d'émission acoustique correspond à un phénomène de libération d'énergie élastique sous forme d'ondes élastiques transitoires au sein d'un matériau ayant des processus dynamiques de déformation » [Roget, 1988, Jacquesson, 2000]. Ces ondes élastiques se propagent dans le matériau et peuvent éventuellement être recueillies par des capteurs piézo-électriques une fois qu'elles atteignent la surface. Les signaux recueillis seront par la suite amplifiés puis enregistrés (figure 1.7).

Les premières expériences d'émission acoustique datent des années 1950, elles ont été réalisées en Allemagne lors d'études sur des métaux effectués par Kaiser [Kaiser, 1950].

Lors de l'application d'une charge sur un matériau composite, un endommagement va se développer en fonction des sollicitations imposées. Dans un essai, plusieurs types d'endommagement sont présents sous forme de salves d'EA. On se place dans l'hypothèse où chaque salve d'EA correspond à un événement physique dans le matériau et où la forme de la salve est directement liée aux caractéristiques de

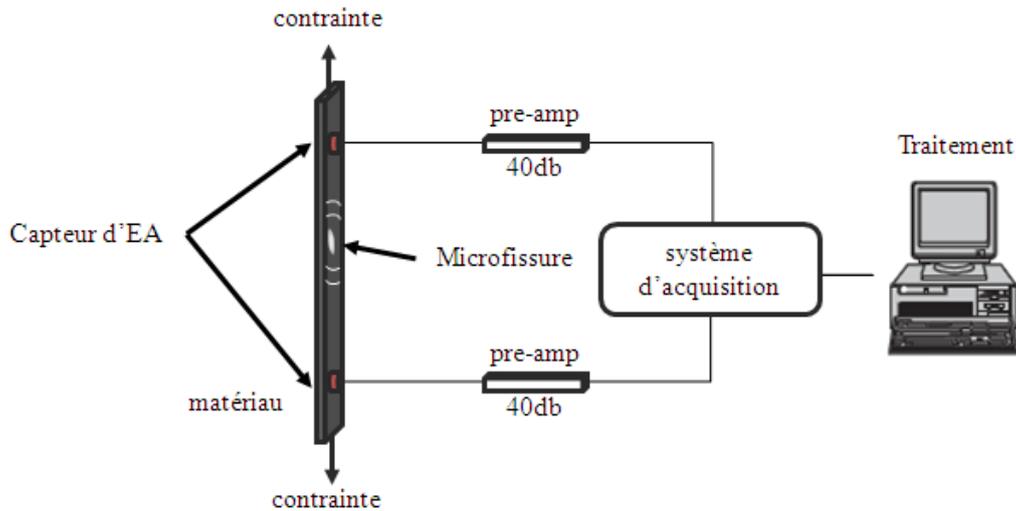


FIGURE 1.7 – Diagramme du système.

cet évènement [Huguet, 2002]. Comme cité précédemment, les différents mécanismes d'endommagement que l'on peut rencontrer dans ces matériaux sont principalement la fissuration de la matrice, le décollement à l'interface fibre/matrice (déchaussement), le délaminage et la rupture de fibres.

Il existe deux types d'EA. Le premier type est discret et dépend des capteurs utilisés : sinusoïdes amorties (salves) dans le cas de capteurs résonnants, impulsions courtes dans le cas de capteurs large bande (figure 1.11). Le deuxième type est continu, il est présent lorsque les signaux sont fréquents et se chevauchent, il n'est pas possible de séparer les signaux en salves. Ce dernier type d'EA est principalement observé dans les matériaux métalliques [Ono, 1997]

Dans les matériaux composites, les mécanismes d'endommagement présentés précédemment constituent les principales sources d'EA. Ces sources sont liées à des phénomènes irréversibles, elles sont définies par l'effet Kaiser que nous allons détailler ci-après.

1.5.2 Effet Kaiser et rapport Felicity

L'effet Kaiser [Kaiser, 1950] traduit l'irréversibilité du phénomène de génération d'EA. Cette irréversibilité se traduit par : « pour une structure déjà sollicitée, aucune activité acoustique ne sera détectée tant que le niveau de contrainte ne dépasse pas le niveau maximal de contrainte atteint précédemment » [Bertin, 2011]. Ainsi, lorsqu'un matériau subit une charge P_1 puis est déchargé, l'émission acoustique ne reprend que si la nouvelle charge P_2 est plus grande que P_1 ($P_2 > P_1$). Le rapport

Felicity (Rf) est défini par : $Rf = \frac{P_2}{P_1}$; tant que $Rf < 1$ l'émission acoustique ne reprend pas [Huguet, 2002].

1.5.3 Dispositif expérimental

1.5.3.1 Élaboration des éprouvettes

Les éprouvettes des matériaux objets de notre étude ont été fabriquées par moulage sous vide au Laboratoire d'Acoustique de l'Université du Maine, Le Mans. Elles ont été laminées par l'empilement de 8 plis [Kharoubi et al., 2010], renforcées par de la fibre de verre unidirectionnelle avec une masse de flux UDG 300 g/m² et de la résine époxyde SR 1500 / SD 2505. Ces composants sont des produits de la société SICOMIN. Les plis ont été laminés et imprégnés à la température ambiante, puis placés sous vide avec une dépression de -30 kPa pendant 8 heures entre le moule et le contre moule, suivi d'une polymérisation de 8 heures à 80°C dans un four électrique. Les coupes ont été faites en utilisant une lame de scie en diamant. Les dimensions de chaque échantillon étaient de $2 \times 20 \times 200$ mm (figure 1.8).

1.5.3.2 Chaines d'acquisition d'EA

Une campagne de tests de fluage par traction (figure 1.9) a été effectuée. Les tests ont été réalisés sur une machine de type Instron équipée d'une cellule de charge de 100 kN et contrôlée par ordinateur (figure 1.7). Un dispositif d'acquisition d'émission acoustique [Nechad et al., 2005, Thummen, 2004, Berbaoui et al., 2010, Journaux, 1999] de deux canaux a été utilisé. A plusieurs reprises, des descripteurs ont été calculés par le système d'acquisition pour chaque évènement EA : l'amplitude, l'énergie, la durée, le temps de montée, le nombre de fois que l'amplitude de l'évènement dépasse le seuil d'amplitude donné (appelé nombre de coups). Ces paramètres ont été utilisés comme descripteurs d'entrée dans les méthodes de classification. Lors des essais de traction, il s'est avéré que toutes les éprouvettes de ce matériau subissent une rupture quasi instantanée si on leur applique une force de 30 kN. Le test de fluage a été effectué en appliquant 90 % de la force maximale que le matériau peut supporter, soit 27 kN, constant jusqu'à la rupture.

Pour des essais similaires, on utilise des capteurs piézoélectriques pour capter les ondes élastiques à la surface d'un matériau. On utilise aussi de la graisse à base de silicone pour garantir le couplage ; elle a comme rôle d'améliorer la transmission des ondes entre la surface de l'échantillon et le capteur.

D'habitude deux types de capteurs sont utilisés en EA :

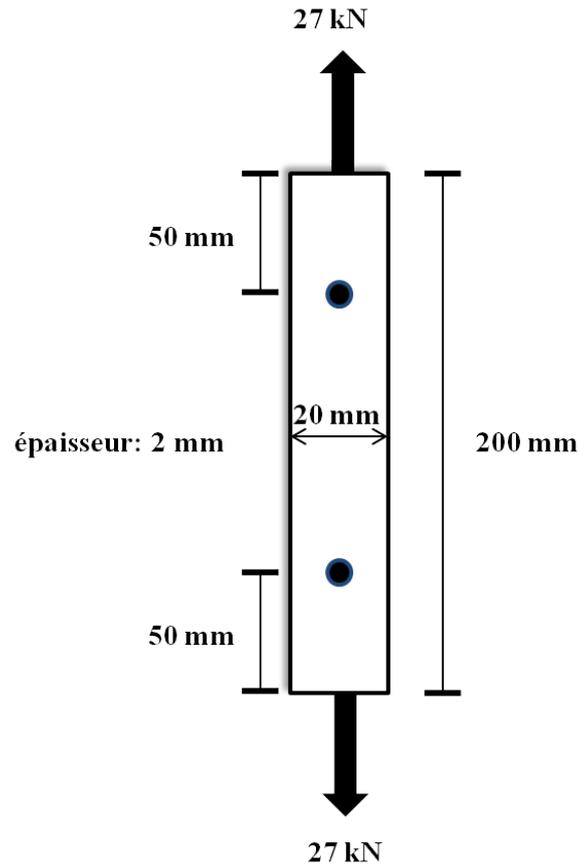


FIGURE 1.8 – Dimensions des éprouvettes de composites unidirectionnels et position des capteurs d’EA pour un essai de traction (vue de haut). Les flèches indiquent la direction de sollicitation en traction.

Large bande : ce sont des capteurs qui possèdent une bande étendue et large pouvant aller jusqu’au MHz. Leur avantage principal est de ne pas modifier ou peu la forme réelle du signal.

Résonnants : ils ont une bande passante moins large et un pic de la fonction de transfert aux alentours d’une certaine fréquence. Ce pic de réponse entraîne une modification de l’allure des signaux et de leur contenu fréquentiel. Ces capteurs sont cependant les plus utilisés car ils présentent une meilleure sensibilité et permettent de détecter des signaux de plus faible amplitude [Nechad, 2004].

Pour ce travail de recherche, les mesures d’EA ont été obtenues par le biais de deux micro-capteurs à résonance avec une bande de fréquence comprise entre 100 kHz et 1 MHz et présentant un pic de résonance autour de 300 kHz.

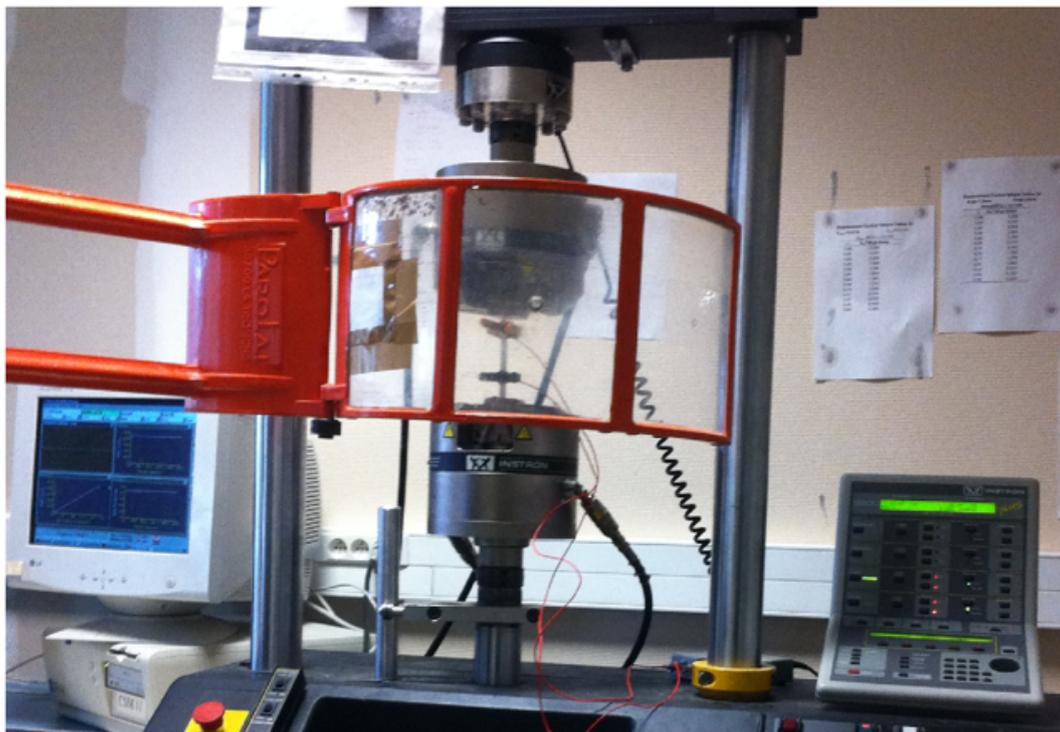


FIGURE 1.9 – Essai de fluage par traction (machine, éprouvette et capteurs).

1.5.3.3 Paramétrage du logiciel d'acquisition

L'ordinateur de stockage des signaux d'EA est muni du système MISTRAS 2001 développé par European Physical Acoustic (EPA) qui permet l'acquisition et le traitement des données d'EA. Ce logiciel nécessite un réglage des paramètres d'acquisition des salves. Les PDT (Peak Definition Time), HDT (Hit Definition Time) et HLT (Hit Lockout Time) sont les paramètres à régler (figure 1.10).

Ces paramètres sont définis par :

- Le **PDT** est un intervalle de temps. Le PDT débute exactement lorsque le signal dépasse pour la première fois un certain seuil. La fin du PDT est définie par le temps correspondant à l'amplitude maximale. Ainsi, il permet de détecter le temps de montée de la salve d'EA. Il est utilisé pour séparer les salves les unes des autres [Tran, 2011].
- Le **HDT** est le paramètre qui détecte la fin de la salve et permet donc d'en déduire sa durée. Le HDT se déclenche à chaque dépassement de seuil et déclare la fin de la salve s'il n'y a pas un autre dépassement avant la fin du HDT. Le HDT doit être aussi court que possible afin d'éviter que deux salves ne soient considérées comme une seule.

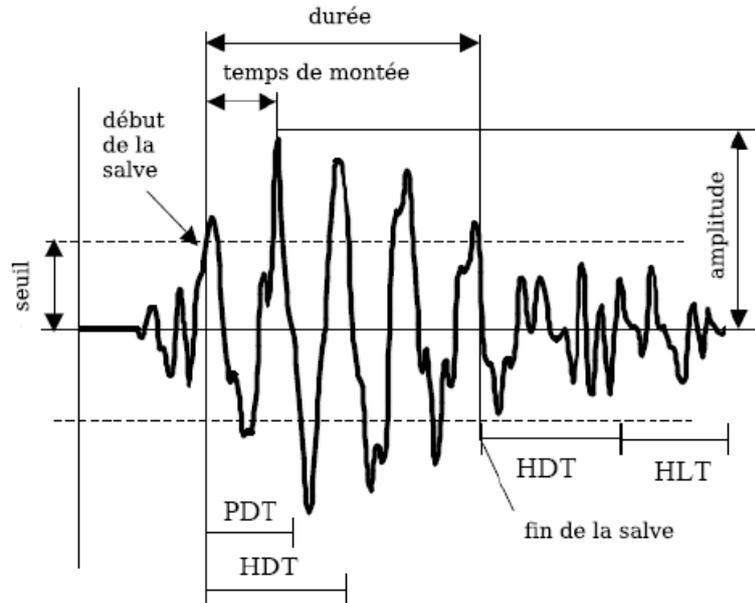


FIGURE 1.10 – Paramètres d’acquisition des salves d’EA : PDT (Peak Definition Time), HDT (Hit Definition Time) et HLT (Hit Lockout Time) [Marec, 2008].

- Le **HLT** permet d’exclure d’éventuelles réflexions tardives dans les signaux d’EA. Le HLT débute à la fin du dernier HDT.

Ces trois valeurs vont définir la manière dont seront calculés les paramètres sur les signaux d’EA. Les valeurs retenues évaluées expérimentalement sont :

- PDT : $50 \mu s$
- HDT : $100 \mu s$
- HLT : $300 \mu s$

1.5.3.4 Paramètres temporels

On s’intéresse ici aux signaux de type discret. On se place dans l’hypothèse où chaque salve correspond à un évènement physique dans le matériau et où la forme de la salve est directement liée aux caractéristiques de cet évènement. Dès lors il est important de relever tous les paramètres pouvant permettre de caractériser un type de signal dans le but de remonter jusqu’à l’identification des différents mécanismes mis en jeu. Les principaux paramètres exploitables sont représentés par la figure 1.11. La plupart de ces paramètres sont définis par rapport à un seuil d’acquisition.

Il existe plusieurs méthodes pour fixer ce seuil, la plus courante consiste à le régler à une valeur légèrement supérieure au bruit de fond. Les paramètres classiques enregistrés en temps réel sont les suivants :

- l’amplitude : représente l’amplitude maximale calculée sur l’ensemble du signal

$$A = \log \left(\frac{\text{amplitude maximale}}{10^{-3}} \right), \quad (1.1)$$

- la durée du signal : représente le temps qui sépare le premier et le dernier dépassement de seuil,
- le nombre de coups ou le nombre d’alternances : correspond au nombre de franchissements de seuil par le signal sur toute sa durée,
- le nombre de coups au pic : correspond au nombre de franchissements de seuil par le signal entre le premier dépassement de seuil et l’amplitude maximale,
- le temps de montée exprimé en microsecondes : correspond au temps qui sépare le premier dépassement de seuil et l’amplitude crête du signal,
- la fréquence moyenne : cette valeur donnée par la plupart des systèmes d’acquisition ne correspond pas à la transformée de Fourier du signal mais au nombre de coups d’une salve divisé par sa durée,

- l’énergie du signal :

$$E(T) = \int_T A dt \quad (1.2)$$

- l’énergie absolue du signal :

$$E_{abs}(T) = \int_T |A|^2 dt \quad (1.3)$$

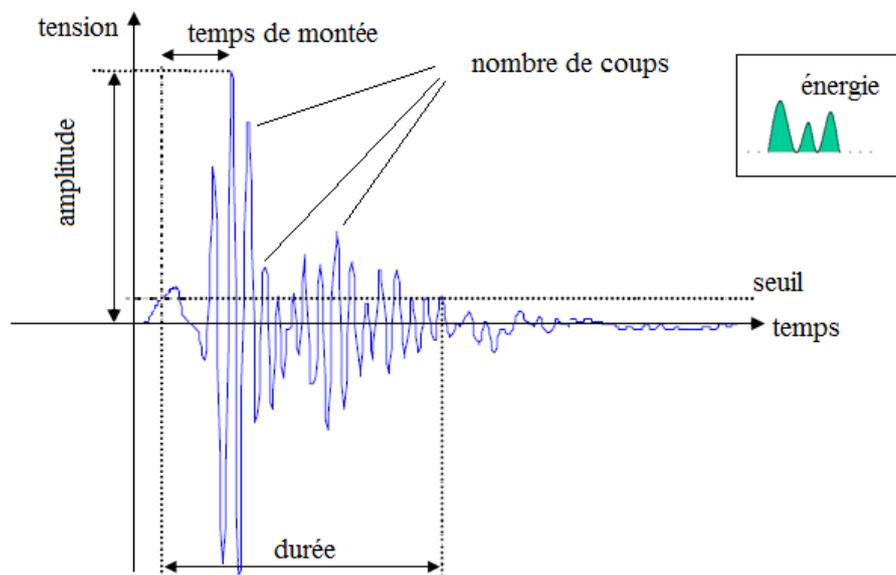


FIGURE 1.11 – Paramètres d'une salve d'EA.

Chapitre 2

Endommagement des matériaux sous fluage : identification des signaux d'EA précurseurs de la rupture

Les travaux présentés dans ce chapitre portent sur la prédiction de la rupture des matériaux composites. Rappelons que lors des tests de fluage, les éprouvettes testées ont des durées de vie largement différentes (voir chapitre 1). La réponse en fluage des matériaux est composée de trois phases (section 1.4.1) dont la troisième est considérée comme la phase de rupture. Notre but est de prédire si une éprouvette en cours de test est dans la phase de rupture ou non. Dans la section 2.1, nous présentons un état de l'art des études réalisées afin d'identifier les différents mécanismes d'endommagement sources d'EA. Certaines de ces études montrent que les caractéristiques des signaux d'EA de la phase de rupture sont différentes de celles des deux autres phases [Nechad, 2004]. Par conséquent, nous allons procéder à la classification des signaux d'EA entre phase de rupture et phase de non-rupture.

Pour répondre à cette problématique de classification nous utilisons des méthodes d'apprentissage artificiel telles que les réseaux de neurones, les machines à vecteurs de support et les classifieurs bayésiens naïfs. Ce sont des méthodes de l'intelligence artificielle qui, appliquées à l'émission acoustique, permettent d'identifier parmi un grand nombre de signaux, caractérisés par un certain nombre de paramètres, des classes de signaux ayant des paramètres proches et donc provenant de la même phase.

La problématique étudiée est détaillée dans la section 2.2. Enfin une explication des méthodes d'apprentissage artificiel est donnée dans la section 2.3.

2.1 État de l'art sur la discrimination des classes

Dans le contexte de discrimination de classes, des études ont été faites afin de pouvoir identifier et discriminer les différents mécanismes d'endommagement [Marec et al., 2008]. Il existe différentes formes de signaux d'EA ; ces signaux contiennent des informations utiles inhérentes aux différents mécanismes d'endommagement. Une analyse des paramètres extraits des salves d'EA est nécessaire afin de les relier aux sources d'EA. Ces paramètres changent d'un type de matériau à un autre. Ils dépendent du système d'acquisition, des géométries des éprouvettes et des capteurs utilisés [Marec et al., 2008].

Les études réalisées afin d'identifier les mécanismes « sources » d'EA se divisent en trois grandes catégories : la première consiste à utiliser les paramètres temporels calculés sur les signaux d'EA, la deuxième utilise le domaine fréquentiel, enfin la troisième repose sur l'analyse statistique multivariée des paramètres temporels et/ou fréquentsiels [Ramirez-Jimenez et al., 2004, Bohse, 2004, Marec et al., 2008].

2.1.1 Analyse temporelle

Plusieurs études [Chen et al., 1992, Benzeggagh and Barre, 1994, Ceysson et al., 1996, Kim and Lee, 1997, Kotsikos et al., 1999] sont fondées sur un ou plusieurs paramètres temporels calculés sur les salves d'EA (présentés en section 1.5.3.4) pour pouvoir identifier les mécanismes sources des signaux d'EA recueillis lors d'essais sur des matériaux composites sous charge. La plupart de ces études utilise l'amplitude comme paramètre discriminant.

L'évolution de l'amplitude des signaux d'EA a été étudiée aussi par [Chen et al., 1992] lors d'essais de flexion et de traction sur des composites à fibres courtes de carbone et à matrice en verre. Les auteurs ont identifié que les fissurations matricielles ont une amplitude de 60 dB à 80 dB, et de 70 dB à 90 dB pour les déchaussements (*pull-out*) et les ruptures de fibres.

Dans le travail de [Benzeggagh and Barre, 1994], l'étude était réalisée sur l'amplitude des signaux d'EA de composites à fibres de verre et à matrice polypropylène soumis à des tests de fatigue et de traction statique. Les résultats obtenus montrent que les signaux d'EA s'identifient de la façon suivante : les fissurations matricielles génèrent des signaux d'amplitudes comprises entre 40 dB et 55 dB, les décohésions entre 60 dB et 65 dB, les déchaussements (*pull-out*) de 65 dB à 85 dB et les ruptures de fibres entre 85 dB et 95 dB.

[Ceysson et al., 1996] ont étudié des stratifiés composés de fibres de carbone et de matrice époxy soumis à différents types d'essais de flexion. Ils ont mis en évidence

TABLE 2.1 – Synthèse des valeurs d'amplitude de différents mécanismes d'endommagement obtenues pour différents types de composites soumis à diverses sollicitations mécaniques [Marec et al., 2008].

références	Benzeggagh and Barre [1994]	Chen et al. [1992]	Kotsikos et al. [1999]	Kim and Lee [1997]	Ceysson et al. [1996]
composites	verre/ polypropylène	carbone/ verre	verre/ polyester	carbone/ époxy	carbone/ époxy
fissurations matricielles	40 dB – 55 dB	60 dB – 80 dB	40 dB – 55 dB	40 dB – 70 dB	50 dB
décohésions	60 dB – 65 dB				
délaminages			55 dB – 70 dB		62 dB
ruptures de fibre	85 dB – 95 dB	70 dB – 90 dB	> 80 dB	60 dB – 100 dB	

que les fissurations matricielles ont des amplitudes centrées sur 50 dB et sur 62 dB pour les délaminages.

[Kim and Lee, 1997] ont réalisé des essais de mises en charge successives sur des composites à fibres de carbone et à matrice polymère à plis croisés [0°C–90°C]. Les fissurations matricielles ont été reliées aux signaux de faible amplitude (40 dB à 70 dB) et les ruptures de fibres à ceux de forte amplitude (60 dB à 100 dB).

[Kotsikos et al., 1999] ont effectué des tests de fatigue sur des composites stratifiés [0°C–90°C] à fibres de verre et à matrice polyester. Ils ont pu dissocier trois types de mécanismes sources des signaux d'EA : les fissurations matricielles ont des amplitudes comprises entre 40 dB et 55 dB, ceux des délaminages entre 55 dB et 70 dB et ceux des ruptures de fibres ont des amplitudes qui dépassent les 80 dB.

Pour résumer et comparer les résultats obtenus dans la littérature, nous avons construit le tableau 2.1 qui présente les zones d'amplitude associées à différents mécanismes d'endommagement pour différents types de composites soumis à différents modes de sollicitation.

Nous pouvons classer par amplitude croissante les mécanismes d'endommagement rencontrés dans les composites, obtenus dans les études précédentes (fissurations matricielles, décohésions et délaminages, ruptures de fibres). Cependant ces distributions d'amplitude varient selon le matériau et le type d'essai. Les distributions d'amplitude obtenues dans les études de [Benzeggagh and Barre, 1994, Kotsikos et al., 1999, Ceysson et al., 1996] pour chaque mécanisme d'endommagement sont assez similaires mais il semble difficile de pouvoir les discriminer. De plus les distributions d'amplitude entre les différents modes d'endommagement présentent des recouvrements dans la plupart de ces études, ce qui rend incertain l'attribution d'un signal à un mécanisme d'endommagement.

Ainsi, afin d'améliorer la caractérisation des mécanismes sources d'EA, d'autres études ont porté sur l'analyse simultanée de plusieurs paramètres.

[Ativitavas et al., 2004] ont réalisé des tests de traction sur des composites stratifiés unidirectionnels à fibres de verre et à matrice plastique. Des observations micrographiques à différents stades des essais, associés à une analyse de l'amplitude et de l'énergie des signaux, ont montré que les microfissurations matricielles apparaissent en premier dans les essais, suivies par des ruptures de fibres qui engendrent des décohésions. Puis, en fin d'essai, des délaminages sont détectés ce qui a conduit à la rupture du composite. Dans cette étude les ruptures de fibres sont associées aux événements d'amplitude, supérieure à 74 dB, et d'énergie élevées et les autres mécanismes d'endommagement aux événements d'amplitude inférieure à 74 dB, mais sans pouvoir les dissocier car leurs distributions se recouvrent.

[Godin et al., 2004] ont effectué des essais de traction sur des matériaux composites unidirectionnels fibre de verre/matrice polyester et fibre de verre/matrice époxy. Ils ont procédé à une analyse conventionnelle simultanée de plusieurs paramètres extraits des signaux d'EA résultants. Tout d'abord pour identifier les signaux caractéristiques des microfissurations matricielles, ils ont mené des essais sur des matériaux composés de matrice seule. Pour identifier les signaux d'EA correspondant à des décohésions fibre-matrice, ils ont mené des essais sur des éprouvettes unidirectionnelles avec une orientation des fibres à 90° et 45° par rapport à l'axe de sollicitation. D'autres essais ont été effectués sur des composites mono-filamentaires pour identifier les signaux correspondant aux ruptures des fibres. Enfin, afin de retrouver des signaux correspondant aux délaminages entre les plis, [Godin et al., 2004] ont mené des essais sur des composites stratifiés à plis croisés. Une analyse paramétrique des signaux d'EA a été effectuée afin d'identifier les types de signaux en considérant l'amplitude, le temps de montée, la durée et l'énergie. Cette étude a permis d'identifier quatre types de signaux qu'ils ont appelés type A, B, C et D. Leurs principales caractéristiques sont (figure 2.2) :

- signaux de type A (microfissurations matricielles) : ils sont caractérisés par des amplitudes comprises entre 50 dB et 70 dB, de faible durée, avec un temps de montée assez lent et une énergie relativement faible.
- Signaux de type B (décohésions) : ils sont caractérisés par des amplitudes comprises entre 70 dB et 100 dB, des temps de montée assez courts et des énergies plus élevées que pour les signaux de type A.
- Signaux de type C (ruptures de fibres) : ces signaux sont très proches des signaux de type B. Leur temps de montée ainsi que leurs temps de décroissance sont relativement courts avec des amplitudes et des énergies assez importantes.

- Signaux de type D (délaminages) : ils ont de très longues durées, des temps de montée lents, ainsi que des énergies assez élevées avec une gamme d'amplitude assez large.

TABLE 2.2 – Caractéristiques des signaux de type A, B, C, D identifiés par [Huguet, 2002].

	Temps de montée	Durée du signal	Décroissance du signal	Type du signal
Type A	Moyen	Moyenne	Lente	Résonnant
Type B	Court	Moyenne	Courte	Résonnant
Type C	Court	Courte	Courte	Impulsionnel
Type D	Lent	Très longue	Lente	Résonnant

[Nechad et al., 2005] ont étudié des composites verre/polyester unidirectionnels à plis croisés et des composites SMC soumis à des essais de fluage en traction. Ils ont réalisé une étude paramétrique en considérant l'amplitude, l'énergie absolue et la durée des signaux d'EA. Dans cette étude, l'évolution des différents mécanismes d'endommagement dans ces matériaux soumis à un fluage a été mise en évidence de manière qualitative.

Ces différents travaux montrent la nécessité d'analyser les signaux d'EA en prenant en compte plusieurs paramètres afin de pouvoir étudier l'évolution des modes d'endommagement lors d'essais sur des matériaux ou des structures plus complexes que sur des échantillons « écoles ».

2.1.2 Analyse statistique multivariable

D'autres études [Likas et al., 2003, Anastassopoulos and Philippidis, 1995] ont été menées pour évaluer l'importance relative des modes d'endommagement identifiés et leur cinétique d'évolution en cours d'essai. Ces méthodes sont basées sur des méthodes d'analyse statistique multivariable afin d'améliorer la classification des événements d'EA. Ces méthodes utilisent plusieurs paramètres (ou descripteurs) pour définir les ressemblances ou les différences entre les données des signaux d'EA. Ces méthodes d'analyse statistique multivariable sont des méthodes de reconnaissance des formes qui permettent, quand elles sont appliquées aux signaux d'EA, de prédire l'appartenance des données d'EA à des classes représentatives des différents mécanismes d'endommagement. Dans cette section, les travaux relatifs à l'utilisation des méthodes de reconnaissance des formes sont utilisés dans le but d'identifier la signature acoustique des différents mécanismes sources résultant de l'endommagement dans les matériaux composites sollicités par des contraintes extérieures.

[Anastassopoulos and Philippidis, 1995] ont effectué des essais de traction sur des composites verre/époxy et carbone/carbone. Ils ont utilisé deux algorithmes de segmentation des données (MaxMin distance [Dubes and Jain, 1976] et une version modifiée de la méthode des K -moyennes [Likas et al., 2003]) dans le but de classifier les signaux d'EA résultants. Dans le même but, ces deux algorithmes ont été utilisés par [Kostopoulos et al., 2003] pour des composites oxyde/oxyde sollicités en traction. [Anastassopoulos and Philippidis, 1995] ont classé les signaux en utilisant quatre paramètres (temps de montée, amplitude, temps de décroissance et durée). Ils ont pu identifier six classes et ils ont suivi leur évolution en fonction de l'avancement des essais, permettant d'établir un critère d'approche de la rupture du matériau. [Kostopoulos et al., 2003] ont relié les différentes classes obtenues aux possibles mécanismes d'endommagement intervenant dans ces matériaux en établissant une procédure qui permet de choisir le nombre de descripteurs temporels pertinents.

[Ono and Huang, 1994] ont effectué des essais sur des composites carbone/époxy unidirectionnels, à plis croisés et à fibres courtes dispersées, ainsi que sur des stratifiés verre/époxy à plis croisés. Une classification visuelle des différents types de signaux d'EA collectés a été d'abord effectuée en fonction du matériau sollicité et de l'endommagement prépondérant lui correspondant. Ainsi, ils ont identifié six types de signaux pour les stratifiés carbone/époxy et trois pour les stratifiés verre/époxy. Ensuite, pour classer les signaux provenant d'essais supplémentaires dans une des classes établies visuellement, ils ont utilisé la technique des K plus proches voisins [Hattori and Takahashi, 1999] permettant de suivre l'évolution des modes d'endommagement.

[Pappas et al., 1998] ont utilisé la méthode des K -moyennes pour la segmentation des données d'EA en analysant cinq paramètres temporels des signaux d'EA acoustiques collectés lors de tests de traction sur des composites carbone/carbone sollicités. Ils ont obtenu cinq classes et les ont associées à cinq mécanismes d'endommagement différents.

[Godin et al., 2005] ont utilisé les réseaux de neurones de Kohonen [Kohonen and Somervuo, 2002] associés à un algorithme des K -moyennes pour classifier les données d'EA. L'identification des sources d'EA pour des composites fibre-matrice unidirectionnels à plis croisés sollicités en traction ont donné des résultats intéressants. Cependant, pour des matériaux plus complexes tels que les SMC et les composites à plis croisés soumis à des tests de fluage, cette méthode s'est avérée moins efficace.

[Marec, 2008] a réduit le nombre de paramètres extraits des signaux d'EA en utilisant l'analyse en composantes principales (ACP) [Jolliffe, 2002, Oja, 1991]. L'ACP est effectuée à partir de signaux d'EA de composites fibre de verre-matrice époxy à différentes orientations de plis, d'une part, et de béton polymère soumis à des char-

gements quasi-statiques de traction et de flexion trois points, d'autre part. Ensuite, les auteurs ont appliqué la technique de coalescence floue [Bezdek, 1981, Oja, 1991] à ces données pour pouvoir classer les signaux. Une autre méthode a été appliquée par [Marec, 2008]. Cette méthode est fondée sur l'extraction des paramètres par une analyse en transformées d'ondelettes. Ensuite, une analyse statistique multivariable est appliquée à ces paramètres et les résultats ont été comparés avec ceux obtenus par l'analyse paramétrique conventionnelle. Elle a montré que la réduction du nombre de paramètres du vecteur d'entrée avant la classification permet d'améliorer les résultats. Elle a aussi mis en évidence l'efficacité de la classification utilisant des paramètres extraits et de la décomposition en ondelettes.

[Gutkin et al., 2011] ont effectué des essais sur des composites stratifiés carbone-époxy soumis à des tests de traction et de flexion. Ils ont testé la performance de trois techniques de reconnaissance de formes : les K -moyennes, les cartes de Kohonen combinées aux K -moyennes et les réseaux de neurones compétitifs [Bishop et al., 1998]. La méthode qui s'est avérée la plus efficace, pour décrire la cinétique d'endommagement des matériaux étudiés, est celle des cartes de Kohonen combinées aux K -moyennes. Ensuite cette approche a été appliquée pour classer les signaux d'EA en utilisant des paramètres fréquentiels. Les auteurs ont réussi à identifier les mécanismes d'endommagement liés à la fissuration matricielle, à la décohésion et aux ruptures de fibres.

En partant de ces méthodes de classification citées dans cette section, nous présentons dans la section 2.2 la problématique étudiée dans ce chapitre.

2.2 Problématique et méthodologie

Les différentes études présentées dans la section 2.1 montrent que les mécanismes d'endommagement au sein d'un matériau composite sous charge peuvent être caractérisés à partir des signaux d'EA. Nous avons cité plusieurs études reposant sur l'utilisation de l'amplitude pour décrire les signaux d'EA. Ces études montrent que l'utilisation d'un seul paramètre (amplitude) est insuffisant pour la discrimination des modes d'endommagement, notamment pour des matériaux complexes pour lesquels les distributions des paramètres se recouvrent. L'utilisation de plusieurs paramètres des signaux d'EA donne des résultats plus performants pour des géométries d'échantillons simples et des matériaux composites connus.

L'évolution des mécanismes d'endommagement dans les matériaux a aussi été étudiée dans plusieurs travaux. Parmi ceux-ci citons : [Anastassopoulos and Philippidis, 1995, Ono and Huang, 1994, Nechad, 2004, Nechad et al., 2005]. Ces auteurs ont classé les signaux d'EA et ont suivi leur évolution en fonction de l'avancement

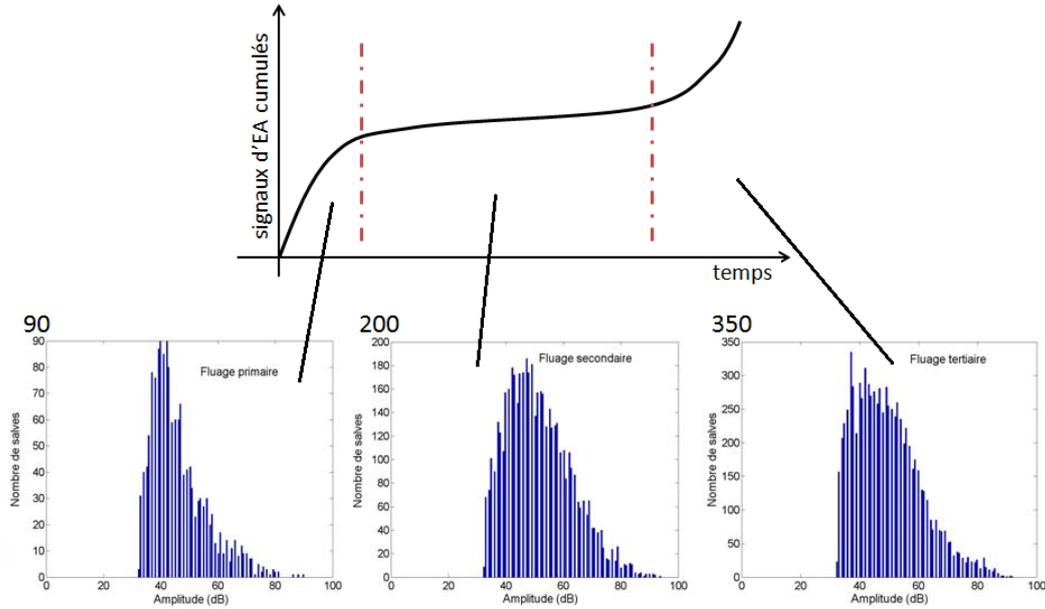


FIGURE 2.1 – Distribution des amplitudes des signaux d'EA dans les trois zones de fluage.

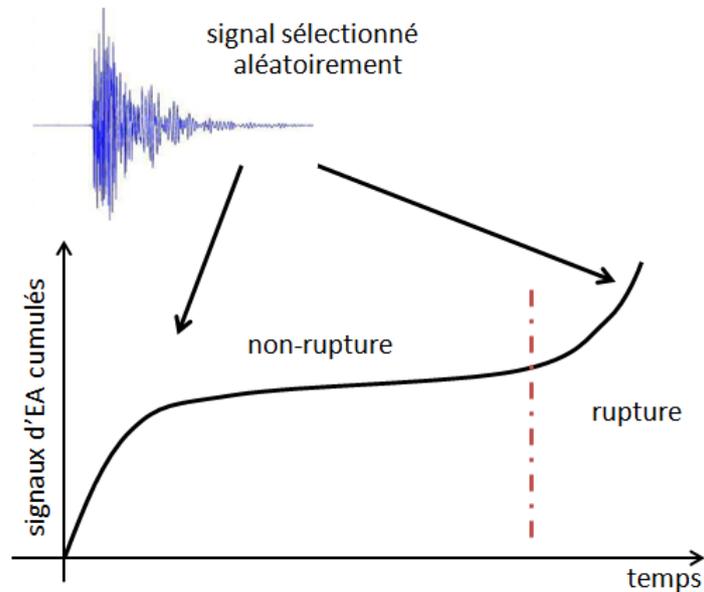


FIGURE 2.2 – Discrimination entre la phase de rupture et la phase de non-rupture.

des essais. Par exemple, dans le travail de thèse de [Nechad, 2004], le suivi de l'apparition des salves acoustiques en fonction du temps permet de visualiser les différentes gammes d'amplitude dans chacune des zones de fluage (primaire, secondaire et tertiaire). La figure 2.1 représente cette répartition.

Notre étude porte sur la discrimination des signaux selon leurs phases d'apparition et particulièrement la phase qui précède la rupture. Nous définissons notre problématique comme suit :

« Prédire si un signal d'EA, sélectionné aléatoirement dans un essai, appartient à la phase de rupture ou non ».

Un schéma explicatif du problème est montré à la figure 2.2. Sur ce schéma, nous essayons de prédire si un signal d'EA sélectionné aléatoirement à l'instant t appartient à la phase de rupture ou de non-rupture.

Plusieurs méthodes de classification peuvent être appliquées pour répartir les signaux entre les phases (rupture ou non-rupture). C'est le cas d'une classification binaire, le résultat est soit positif, soit négatif. Les techniques utilisées sont basées sur des approches discriminantes. Ainsi, parmi les méthodes suivantes, nous utilisons celle qui donnent les meilleurs résultats : les classificateurs naïfs de Bayes, les SVM et les réseaux de neurones. Les détails de ces méthodes sont donnés dans la suite de ce chapitre.

2.3 Apprentissage artificiel et discrimination

2.3.1 Approches pour la discrimination

Il existe beaucoup de techniques de discrimination ; leur nombre rend difficile l'établissement d'une bonne taxinomie. À l'image de [Tufféry, 2007], nous pouvons différencier les techniques transductives des techniques inductives. Les techniques transductives déterminent directement l'appartenance aux classes d'une observation sans passer par une phase d'apprentissage et donc sans créer de modèle. La méthode des K -plus proches voisins, certainement la plus connue, détermine la classe d'une nouvelle observation en regardant parmi les observations connues et déjà classées, c'est à dire les classes des K observations qui sont ses plus proches voisins. Les techniques inductives évaluent l'appartenance aux classes d'une nouvelle observation à partir d'un modèle élaboré durant une phase d'apprentissage. Cette phase définit les relations entre les variables d'entrée et les variables de sortie à partir des observations disponibles. C'est dans ce cadre qu'apparaît le principe de l'induction qui, comme le définit [Cornuéjols, 2005], consiste à produire une connaissance générale à partir de faits particuliers, afin de pouvoir faire des prédictions sur des événements futurs.

Parmi les techniques inductives, nous pouvons retrouver un ensemble de méthodes dites génératives. Ces dernières créent des modèles de discrimination en établissant des règles d'affectation, en estimant des densités de probabilité [Stoppiglia,

1997, Dreyfus et al., 2002] à partir de la distribution des observations. Ces approches recherchent alors à minimiser le recouvrement des densités de probabilité des classes.

Avant de poursuivre, nous noterons \mathbf{X} , la **matrice** contenant n observations x_1, \dots, x_n , chacune décrite par p variables. Le vecteur $x_i = (x_{i1}, \dots, x_{ip})^T$ donne alors les p éléments de l'observation i , et l'élément (i, j) de X (noté x_{ij}) correspond à la j -ème variable de la i -ème observation.

2.3.2 Classifieurs bayésiens

Les approches génératives sont fondées sur le calcul de plusieurs paramètres à partir de la distribution des observations. Ce type de méthodes repose sur l'idée que les variables et les classes peuvent être traitées comme des variables aléatoires. Ainsi, l'appartenance à la classe d'une observation tirée au hasard dans l'espace des observations de l'échantillon est une réalisation d'une variable aléatoire dont la valeur est le numéro de la classe (variable discrète).

Dans la théorie de la décision [Bishop, 2006], la règle de décision de Bayes fournit la limite théorique du taux d'erreur d'un modèle. [Dreyfus et al., 2002] proposent la définition de la règle suivante : « Pour affecter une observation à une classe, nous minimisons le risque d'erreur en prenant la décision d'affecter l'observation à la classe dont la probabilité *a posteriori* est la plus grande ».

Cette limite est obtenue par la connaissance exacte de la distribution des observations pour chacune des classes. Ainsi, les fonctions de densités de probabilité conditionnelles des K classes $p(\mathbf{x}|\mathcal{C}_k)$, dites aussi fonctions de vraisemblance, et les probabilités *a priori* $P(\mathcal{C}_k)$ sont connues. Dès lors, en manipulant les règles de la théorie des probabilités, [Bishop, 2006] montre que le théorème de Bayes (équation 2.1) permet d'obtenir l'affectation d'une nouvelle observation aux classes, par l'intermédiaire des probabilités *a posteriori*,

$$P(\mathcal{C}_k|\mathbf{x}) = \frac{p(\mathbf{x}|\mathcal{C}_k)P(\mathcal{C}_k)}{p(\mathbf{x})}, \quad (2.1)$$

où $p(\mathbf{x})$ est le facteur de normalisation équivalent à $\sum_{k=1}^K p(\mathbf{x}|\mathcal{C}_k)P(\mathcal{C}_k)$. Ainsi, selon la règle de décision, l'observation \mathbf{x} est affectée à la classe \mathcal{C}_k , où la probabilité *a posteriori* $P(\mathcal{C}_k|\mathbf{x})$ est maximale.

La combinaison du théorème de Bayes et de la règle de décision de Bayes constituent ce que nous pouvons appeler le classifieur de Bayes. Il présente théoriquement le meilleur outil de classification si les probabilités *a priori* et les vraisemblances sont connues exactement. La figure 2.3 compare deux frontières de décision, l'une

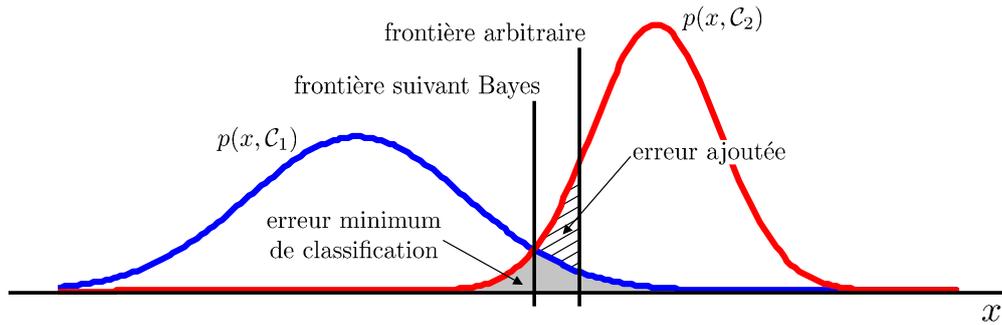


FIGURE 2.3 – Règle de décision de Bayes pour un problème à deux classes. La surface grisée représente la probabilité d’erreur obtenue par la règle de décision de Bayes. La surface hachurée représente la probabilité d’erreur ajoutée à la précédente par le choix d’une autre frontière de décision

obtenue par la règle de Bayes et l’autre de manière arbitraire. Ainsi, pour la frontière arbitraire, nous pouvons observer l’erreur ajoutée à l’erreur de Bayes sur le recouvrement des densités de probabilité conjointe $p(x, \mathcal{C}_k) = p(x|\mathcal{C}_k) P(\mathcal{C}_k)$.

L’estimation des probabilités *a posteriori* est correcte si les variables obéissent aux mêmes vraisemblances de l’échantillon utilisé pour les estimer. Or, il est rare de connaître précisément les fonctions de vraisemblance et les probabilités *a priori*. C’est pourquoi il est nécessaire de les estimer à partir des observations de l’échantillon. La difficulté majeure, dans l’utilisation des classifieurs bayésiens, demeure l’estimation des densités de probabilité. En effet, leur estimation est susceptible de se heurter au problème connu sous le nom de la « malédiction de la dimensionnalité¹ ». Les observations sont représentées par des vecteurs de variables dont la dimension peut être très grande. Or, dès que la dimension devient importante, l’estimation des densités de probabilité est très difficile et peut devenir très approximative dès lors que l’échantillon ne possède pas suffisamment d’observations.

Le classifieur de Bayes naïf permet d’éliminer ce problème. Cette méthode de classification probabiliste est simple. Elle est liée au théorème et à la règle de décision de Bayes. Ce classifieur fait l’hypothèse d’indépendance entre les variables, permettant ainsi de simplifier considérablement la détermination des densités de probabilité. En effet, $\hat{p}(\mathbf{x}|\mathcal{C}_k)$ la densité de probabilité conditionnée à chacune des classes est estimée à partir des densités univariées $p(x_j|\mathcal{C}_k)$, $j = 1, \dots, p$. Ce point est intéressant, car il implique l’estimation individuelle des p variables, donc en une

1. [Bellman, 1961] a introduit l’expression « malédiction de la dimensionnalité » (*curse of dimensionality*), révélant le problème causé par des formes représentées dans de grandes dimensions, lorsque le nombre d’observations est limité. Il spécifiait notamment, que le nombre d’échantillons nécessaires pour estimer précisément une distribution de données augmente exponentiellement avec la dimension. Ainsi, plus le nombre de variables augmente, plus le nombre d’échantillons devrait être important.

dimension, évitant ainsi la malédiction de la dimensionnalité. La densité associée à chaque classe $p(\mathbf{x}|\mathcal{C}_k)$ est alors estimée par :

$$\hat{p}(\mathbf{x}|\mathcal{C}_k) = \prod_{j=1}^p p(x_j|\mathcal{C}_k). \quad (2.2)$$

Une fois les densités de probabilité estimées, il suffit de déterminer les probabilités *a posteriori* pour obtenir l'affectation d'une observation aux classes en suivant la règle de Bayes.

2.3.3 Machines à Vecteurs de Support

Dans cette partie, nous abordons les Machines à Vecteurs de Support (séparateurs à vaste marge). Un séparateur à vaste marge est un algorithme qui utilise une fonction mathématique pour projeter les données d'apprentissage originales vers une dimension plus élevée. Au sein de la nouvelle dimension, cet algorithme cherche à définir l'hyperplan qui sépare d'une manière optimale deux classes (c'est-à-dire, une frontière de décision séparant les données d'une classe d'une autre classe). Avec une classification non-linéaire, les données de deux classes peuvent toujours être séparées par un hyperplan. Les SVM trouvent cet hyperplan à l'aide des vecteurs de support en optimisant la marge.

Les premières études sur les machines à vecteurs de support ont été présentées en 1992 par Vladimir Vapnik et ses collègues Bernhard Boser et Isabel Guyon [Vapnik, 1991]. On notera que les bases des SVM ont été posées dans les années 1960-1970 avec les premiers travaux de [Vapnik and Chervonenkis, 1974] sur la théorie de l'apprentissage statistique. L'avantage des SVM réside dans le fait qu'ils ont beaucoup moins tendance au surapprentissage que les autres méthodes [Feuillo, 2009]. Les vecteurs de support trouvés fournissent également une description compacte du modèle. Les SVM ont été appliqués à un certain nombre de domaines, y compris la reconnaissance de chiffres, la reconnaissance d'objets, l'identification de locuteur ainsi que les tests de référence de prédiction de séries temporelles [Dreyfus et al., 2002].

2.3.3.1 Cas des données linéairement séparables

Pour expliquer les mécanismes sous-jacents aux SVM, examinons tout d'abord le cas le plus simple : un problème à deux classes linéairement séparables. Soit D un ensemble de données défini par $(x_1, y_1), (x_2, y_2), \dots, (x_D, y_D)$, où x_i est l'ensemble d'apprentissage avec des classes étiquetées par y_i . Supposons que chaque y_i

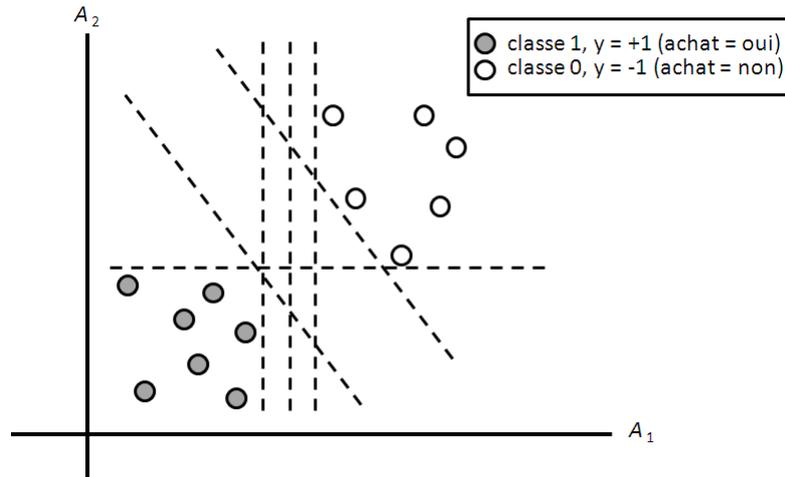


FIGURE 2.4 – Les données 2-D d'apprentissage sont linéairement séparables. Il existe un nombre infini d'hyperplans de séparation possibles.

puisse prendre une des deux valeurs, $+1$ ou -1 ($y_i \in \{+1, -1\}$), correspondant aux classes *achat = oui* et *achat = non*, respectivement. Pour faciliter la visualisation, on considère un exemple basé sur deux attributs d'entrée, A_1 et A_2 , comme le montre la figure 2.4. À partir du graphique, on peut voir que les données réparties en 2 dimensions sont linéairement séparables parce que l'on peut facilement tracer une ligne droite afin de séparer les données de classe $+1$ de celles de classe -1 . Il existe un nombre infini de lignes de séparation possibles. On cherche à trouver la « meilleure », c'est-à-dire celle, qui minimise l'erreur de classification des données non-vues précédemment. Notons que si nos données étaient en 3 dimensions (équivalent à trois attributs), nous souhaiterions trouver le meilleur plan de séparation. En généralisant pour n -dimensions, nous aimerions trouver le meilleur hyperplan séparateur. Nous allons alors utiliser le terme « hyperplan » pour désigner la frontière de décision recherchée, quel que soit le nombre d'attributs d'entrée.

Les SVM abordent ce problème en recherchant l'hyperplan de marge maximale. Considérons la figure 2.4, qui montre deux hyperplans séparateurs possibles et leurs marges associées. Les deux hyperplans peuvent classer correctement toutes les données fournies. Cependant, nous prévoyons intuitivement que le séparateur de plus grande marge permettra de classer plus précisément des données futures que celui présentant la plus petite marge. C'est pour cela que durant la phase d'apprentissage les SVM recherchent l'hyperplan avec la plus grande marge, appelé « Hyperplan avec la Marge Maximale ». La marge maximale associée fournit alors la meilleure séparation entre les classes. La notion de marge peut être définie comme la plus courte distance entre le séparateur et la plus proche donnée d'apprentissage des classes.

L'équation d'un hyperplan de séparation peut être écrite comme suit :

$$W \cdot X + b = 0, \quad (2.3)$$

où $W = \{w_1, w_2, \dots, w_n\}$ est un vecteur de poids, n le nombre d'attributs et b un scalaire. Pour faciliter la visualisation, on considère 2 attributs d'entrées, A_1 et A_2 , comme dans la figure 2.5. Les données d'apprentissage sont en 2-D, $X = (x_1, x_2)$, où x_1 et x_2 sont les valeurs des attributs A_1 et A_2 , respectivement. Si on considère que b est un poids additionnel w_0 , alors on peut écrire l'équation de l'hyperplan de séparation comme suit :

$$w_0 + w_1 x_1 + w_2 x_2 = 0. \quad (2.4)$$

Ainsi, tout point se trouvant au-dessus de l'hyperplan de séparation satisfait l'inéquation :

$$w_0 + w_1 x_1 + w_2 x_2 > 0. \quad (2.5)$$

De même, tout point se trouvant au-dessous de l'hyperplan de séparation satisfait l'inéquation :

$$w_0 + w_1 x_1 + w_2 x_2 < 0. \quad (2.6)$$

Les poids peuvent être choisis de telle sorte que les hyperplans définissant les côtés de la marge obéissent aux inéquations suivantes :

$$H_1 : w_0 + w_1 x_1 + w_2 x_2 \geq 1, \text{ pour } y_i = +1 \text{ et} \quad (2.7)$$

$$H_2 : w_0 + w_1 x_1 + w_2 x_2 \leq -1, \text{ pour } y_i = -1. \quad (2.8)$$

C'est-à-dire, tout ensemble de données qui se situe au-dessus de H_1 appartient à la classe +1 et tout ensemble de données qui se situe au-dessous de H_2 appartient à la classe -1. En combinant les inégalités 2.7 et 2.8, on obtient :

$$y_i(w_0 + w_1 x_1 + w_2 x_2) > 1, \forall i \quad (2.9)$$

Tous les ensembles de données d'apprentissage qui se situent sur les hyperplans H_1 ou H_2 définissant les côtés de la marge et qui satisfont à l'équation 2.9, sont appelés vecteurs de support.

À partir de ce qui précède, nous pouvons établir une mise en équation de la marge et obtenir une formulation de la taille maximale de la marge. La distance de l'hyperplan à un point quelconque H_1 est $1/\|W\|$, où $\|W\|$ est la norme euclidienne de W , définie par $\sqrt{W \cdot W} = \sqrt{w_1^2 + w_2^2 + \dots + w_n^2}$. Elle est donc égale à la distance d'un point quelconque sur H_2 à l'hyperplan de séparation. Donc, la marge maximale est $\frac{2}{\|W\|}$.

2.3.3.2 Cas des données linéairement non-séparables

Dans la section 2.3.3.1, nous avons explicité le fonctionnement des SVM linéaires valables pour des données linéairement séparables, mais que faire si les données ne

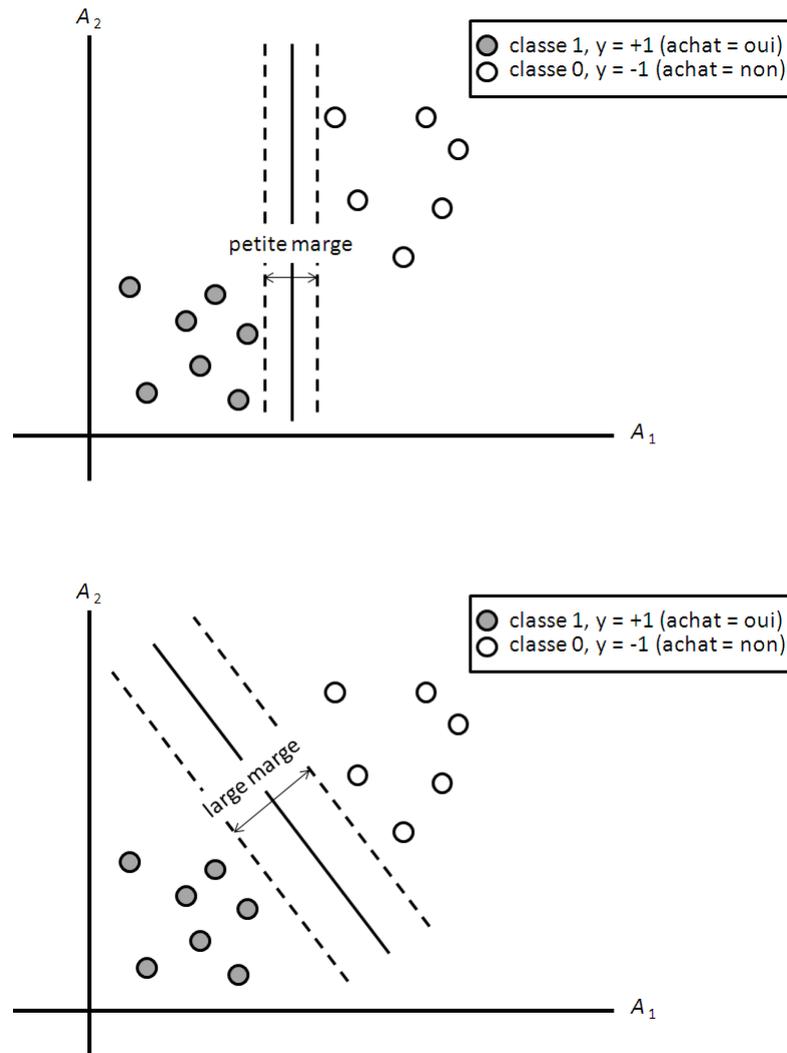


FIGURE 2.5 – Ici présentons deux hyperplans de séparation possibles et leurs marges associées. Celui qui possède la plus large marge présente une meilleure précision de classement.

sont pas linéairement séparables, comme dans la figure 2.7? Aucune ligne droite ne peut être trouvée pour séparer les classes. Les SVM linéaires présentés ne sont pas en mesure de trouver une solution de classification.

Cependant, l'approche décrite pour les SVM linéaires peut être étendue pour créer un SVM non-linéaire permettant aussi la classification des données linéairement inséparables. On obtient un SVM non-linéaire en étendant l'approche de SVM linéaire en deux étapes principales. Dans la première, on transforme les données d'entrée d'origine en un espace de plus grande dimension à l'aide d'une transformation non linéaire. Une fois les données transformées, la deuxième étape cherche un hyperplan de séparation dans le nouvel espace. À nouveau on se retrouve avec un problème d'optimisation quadratique qui peut être résolu en utilisant la formu-

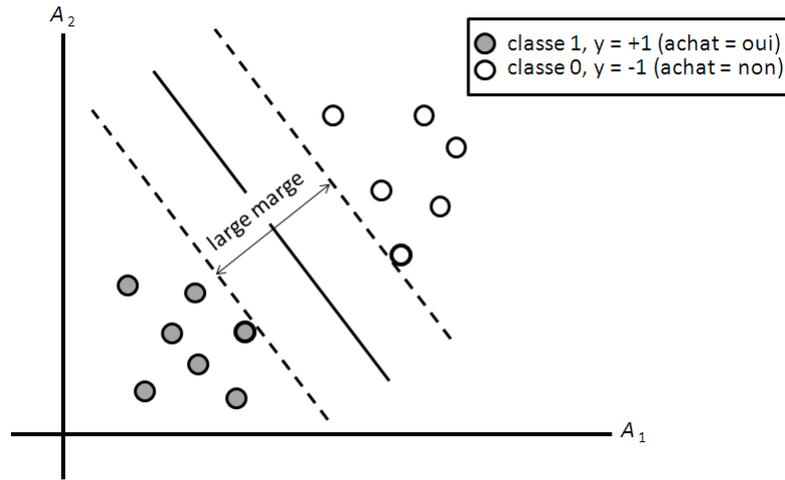


FIGURE 2.6 – Le SVM trouve l’hyperplan à séparation maximale, c’est-à-dire, celui qui a la distance maximale entre les ensembles d’apprentissages les plus proches. Les vecteurs de support sont affichés avec une bordure plus épaisse.

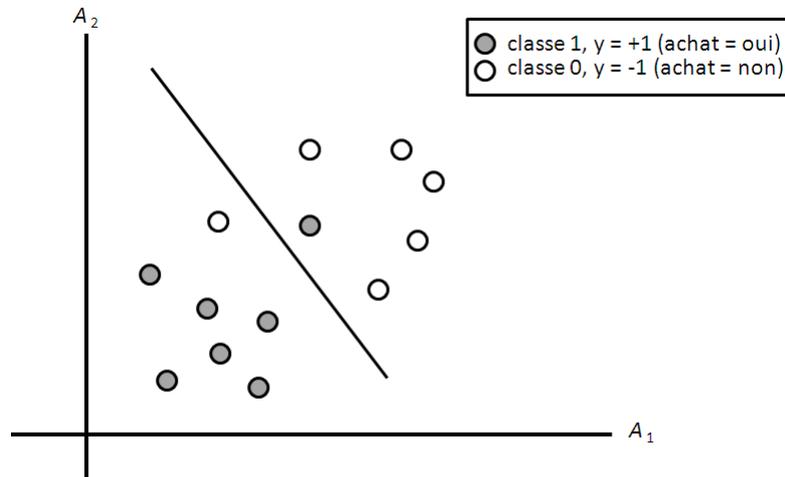


FIGURE 2.7 – Les données 2-D d’apprentissage sont linéairement inséparables.

lation SVM linéaire. L’hyperplan à marge maximale trouvé dans le nouvel espace correspond à une frontière de séparation non-linéaire dans l’espace original (figure 2.8).

2.3.4 Réseaux de neurones artificiels

2.3.4.1 Introduction

Les réseaux de neurones artificiels, également appelés réseaux connexionnistes, sont des structures qui s’inspirent directement du fonctionnement du système nerveux [Asselin de Beauville and Kettaf, 2005]. L’analogie entre l’approche biologique

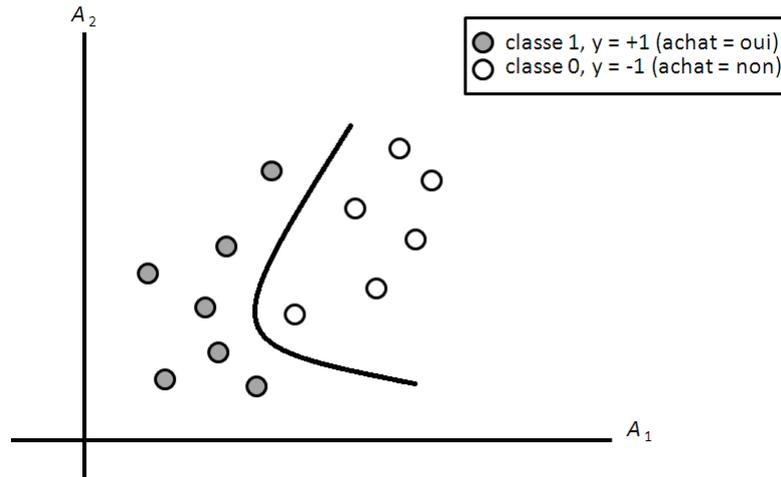


FIGURE 2.8 – Les données 2-D d'apprentissage séparées par un SVM non-linéaire.

des neurones et le développement théorique des réseaux de neurones artificiels est détaillée par [Jodouin, 1994], qui propose tout au long de son ouvrage de judicieux parallèles. Un bref historique des réseaux de neurones est présenté dans les paragraphes suivants. Ces historiques peuvent être complétés par les ouvrages de [Jodouin, 1994, Abdi, 1994, Rennard, 2006].

Les recherches menées dans le domaine du connexionnisme ont débuté avec la présentation en 1943 des travaux de [McCulloch and Pitts, 1943]. Ces auteurs ont construit un modèle simplifié de neurone biologique communément appelé neurone formel. Ils ont montré théoriquement que les réseaux de neurones peuvent réaliser des fonctions logiques et arithmétiques. La structure employée, fondée sur des neurones logiques ou binaires interconnectés, ne connaissent que les réponses 0 ou 1. Ce modèle a inspiré la création du perceptron de [Rosenblatt, 1958] et de l'Adaline [Widrow and Hoff, 1960].

Le perceptron de [Rosenblatt, 1958] a été une étape importante dans l'histoire des réseaux de neurones. Il a été le premier réseau apprenant. Dans un contexte d'apprentissage supervisé, à partir d'observations étiquetées, le perceptron est capable d'ajuster les poids d'un neurone afin de converger vers une configuration apte à réaliser des opérations de classification, par exemple. L'Adaline est vu comme une extension du perceptron et de sa loi d'apprentissage. Il a été mis en œuvre par [Widrow and Hoff, 1960].

Une seule couche de neurones, pour ces deux types de réseaux, ne peut partitionner l'espace d'entrée que de manière linéaire. Pour dépasser les limites de ces réseaux monocouches, la seule alternative est d'augmenter le nombre de couches de neurones entre les entrées et la couche de neurones de sortie. Néanmoins, à la fin des années soixante, il n'existait pas encore un algorithme capable de faire apprendre un tel réseau de neurones [Minsky and Papert, 1969]. La méthode d'apprentissage

ne fut découverte que bien après par [Rumelhart et al., 1986] ; elle porte le nom de rétropropagation du gradient.

De nombreux modèles sont apparus depuis la recrudescence des travaux réalisés autour des réseaux de neurones. Cependant, ils sont tous basés sur le modèle fondateur : le neurone de McCulloch-Pitts. Les neurones sont capables de faire des opérations élémentaires, pouvant aller jusqu'à la réalisation de fonctions non linéaires simples. Cependant, leur intérêt réside dans leur association qui permet de constituer un réseau [Dreyfus et al., 2002]. Cela amène naturellement à définir les réseaux de neurones artificiels, comme des modèles mathématiques, pouvant être vus comme des graphes dont les arêtes, orientées et pondérées, sont les liens synaptiques (connexions) et les noeuds sont les neurones. Cependant, la connaissance réside dans ces liens pondérés.

De nombreux types de réseaux ont été développés. Ils peuvent être classés en deux grandes catégories : les réseaux bouclés (réseaux dynamiques) et les réseaux non bouclés (dit aussi réseaux statiques) ; ceux-ci seront décrits dans la prochaine section. D'autre part, les réseaux de neurones peuvent aussi être caractérisés par :

- leur architecture, ou topologie, comprenant la structure d'interconnexion des neurones et les fonctions d'activation utilisées ;
- leur dynamique de propagation, vers l'avant (feedforward) ou avec retour en arrière (feedback) ;
- leur apprentissage, supervisé [Duda and Hart, 1973] ou non supervisé [Duda et al., 2001, Guérif, 2006].

2.3.4.2 Principe du neurone artificiel

Chaque neurone artificiel est un processeur élémentaire. Il reçoit des données d'un nombre variable d'entrées ; l'origine de ces entrées peut provenir de neurones en amont ou de capteurs composant la machine dont il fait partie. Un poids représentatif de la force de la connexion est associé à chacune de ses entrées. Chaque neurone est doté d'une sortie unique, qui se divise ensuite pour alimenter un nombre variable de neurones en aval. Un neurone est représenté à la figure 2.9.

Cette représentation est à l'origine de la première vague d'intérêt pour les neurones formels, dans les années 1940 à 1970 [McCulloch and Pitts, 1943, Minsky and Papert, 1969].

Le neurone procède alors à trois opérations sur ses entrées :

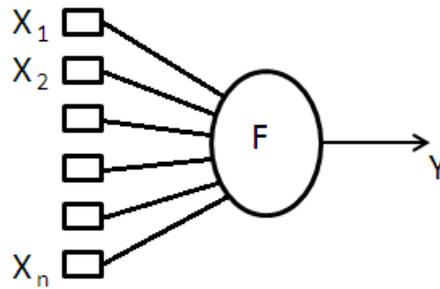


FIGURE 2.9 – Représentation d'un neurone artificiel.

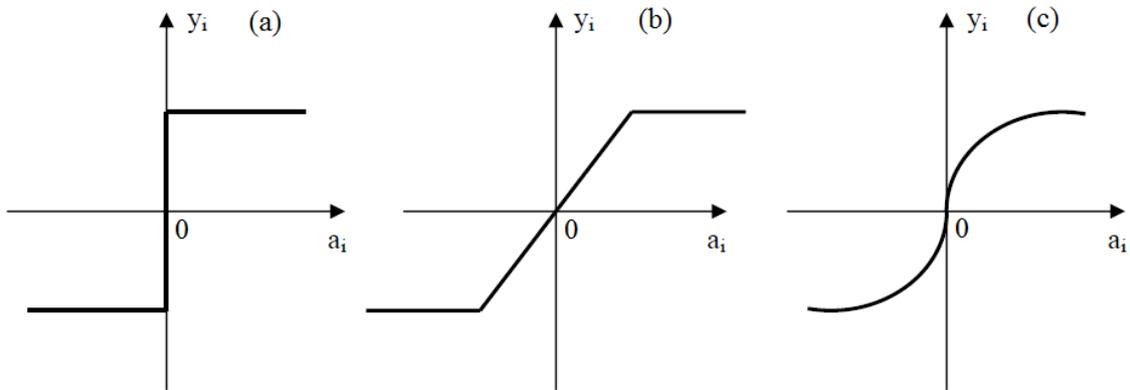


FIGURE 2.10 – Différents types de fonctions de transfert pour le neurone artificiel. (a) fonction à seuil, (b) fonction linéaire par morceaux, (c) fonction de type sigmoïde

- pondération : c'est la multiplication de chacune des entrées par le paramètre « poids de connexion » ;
- sommation : une sommation des entrées pondérées est effectuée ;
- activation : passage de cette somme dans une fonction, appelée fonction d'activation.

Ensuite, la valeur calculée à la sortie du neurone est transmise aux neurones suivants.

La fonction f est la fonction d'activation (figure 2.10). Elle peut être une fonction linéaire ou non-linéaire, ou une fonction à seuil. La fonction sigmoïde présente l'avantage d'être régulière, monotone, continûment dérivable, et bornée entre -1 et +1 :

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (2.10)$$

Plusieurs types de réseaux de neurones artificiels peuvent être utilisés. Ils diffèrent selon le type de connexions entre les neurones. Les types les plus utilisés dans le

domaine de la modélisation et de la commande des procédés sont, le perceptron de Roseblatt et les réseaux de Hopfield. Ils sont constitués de plusieurs couches et d'un nombre fini de neurones. Les couches adjacentes sont interconnectées par des poids. Ils sont de type « feedforward » c'est à dire que l'information dans le réseau se propage d'une couche à l'autre sans retour en arrière. Nous distinguons trois types de couches (figure 2.11) :

- couche d'entrée : les neurones de cette couche reçoivent les données d'entrée du réseau et les transmettent aux neurones cachés. Chaque neurone reçoit une valeur et ne fait donc pas de sommation ;
- couches cachées : chaque neurone de cette couche reçoit l'information de la couche d'entrée ou des couches précédentes. Il effectue la sommation pondérée par les poids, puis la transforme selon sa fonction d'activation. Par la suite, il envoie cette réponse aux neurones de la couche suivante ;
- couche de sortie : chaque neurone de cette couche reçoit l'information de la couche cachée. Cette couche joue le même rôle que les couches cachées ; la seule différence entre ces deux types de couches est que la sortie des neurones de la couche de sortie n'est liée à aucun autre neurone.

2.3.4.3 Architecture

Rappelons que l'on peut distinguer deux grandes catégories de réseaux de neurones :

- les réseaux de neurones statiques (ou acycliques, ou non bouclés) ;
- les réseaux de neurones dynamiques (ou récurrents, ou bouclés).

Dans les réseaux de neurones non bouclés (figure 2.11), le flux d'information circule des entrées vers les sorties sans retour en arrière. Ainsi, si on représente graphiquement un réseau non bouclé, son graphe est acyclique.

Il existe deux types de réseaux de neurones non bouclés : les réseaux à couches et les réseaux complètement connectés.

Les réseaux de neurones à couches, aussi appelés « perceptrons multicouches », sont caractérisés par des neurones cachés organisés en couches ; les neurones d'une même couche ne sont pas connectés entre eux. L'architecture des réseaux de neurones à une couche cachée et une sortie linéaire est très fréquemment utilisée. La figure 2.11 présente un schéma explicatif de cette architecture.

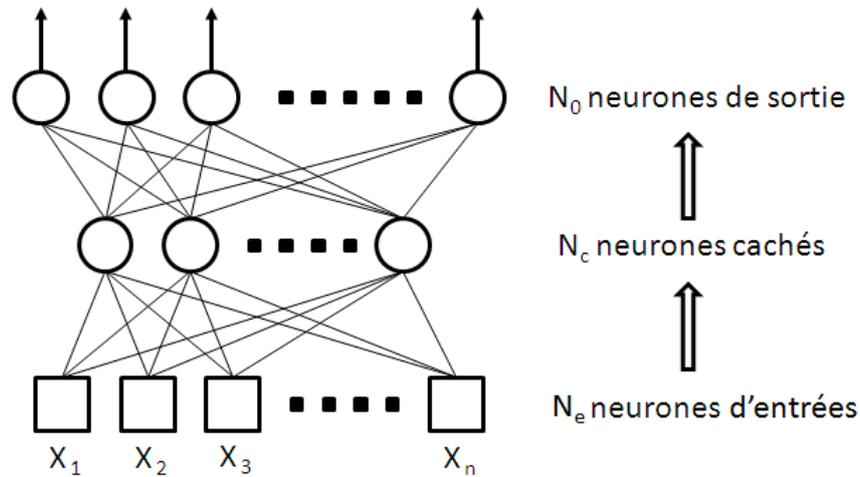


FIGURE 2.11 – Réseau de neurones non bouclé à une couche cachée.

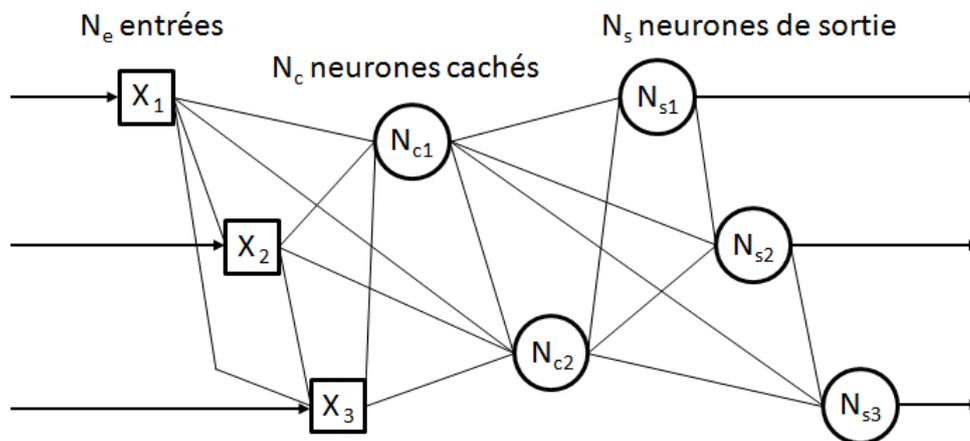


FIGURE 2.12 – Réseau de neurones non bouclé complètement connecté.

Les neurones cachés des réseaux à couches sont organisés en couches, les neurones d'une même couche n'étant pas connectés entre eux. De plus les connexions entre deux couches de neurones non consécutives sont éliminées. Cette architecture est très utilisée, surtout en raison de sa pertinence en classification [Dreyfus et al., 2002].

Enfin, pour les réseaux complètement connectés, les entrées de chaque neurone comprennent les entrées du réseau ainsi que les sorties des neurones de numéros inférieurs. Par ailleurs, la sortie de chaque neurone est connectée aux entrées de tous les neurones de numéros supérieurs. Un schéma détaillé de ce type d'architecture est représenté à la figure 2.12.

Dans les réseaux de neurones bouclés, appelés aussi réseaux récurrents (figure 2.13), on retrouve le même type d'interconnexion entre neurones, mais avec des possibilités de retours en arrière (*feedback*). Ces réseaux sont ainsi utilisés pour la

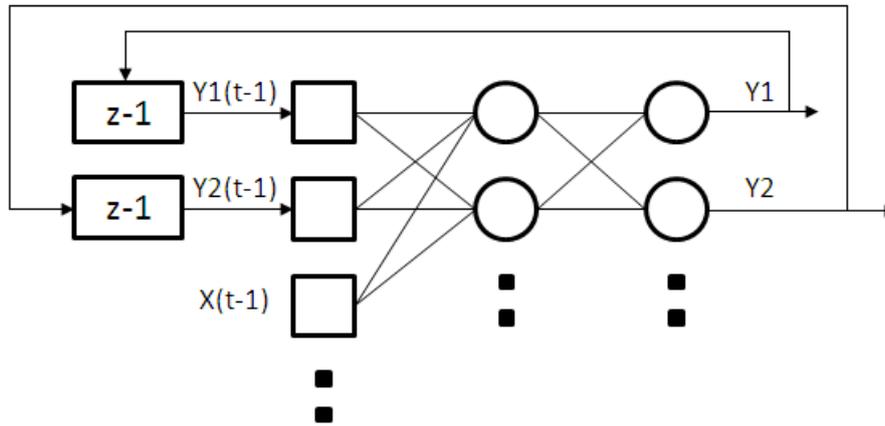


FIGURE 2.13 – Réseau de neurones bouclés.

modélisation et la commande dynamique de processus. Les rétroactions permettent à ce type de réseaux de présenter un comportement temporel [Jodouin, 1994].

2.3.4.4 Apprentissage

L'apprentissage constitue le point crucial du développement d'un réseau de neurones. Il est réalisé en ajustant l'intensité des connexions entre les neurones face à une source d'information [Hebb, 1949, Grossberg, 1992, Rumelhart et al., 1986]. [Haykin, 1999] définit l'apprentissage comme « le mécanisme par lequel les paramètres libres d'un réseau de neurones (poids) sont adaptés à travers un processus de stimulation par l'environnement dans lequel le réseau est intégré ». Le type d'apprentissage est déterminé par la façon dont les changements de paramètres sont mis en œuvre.

Dans la majorité des algorithmes d'apprentissage, les poids des connexions sont modifiés pendant l'apprentissage. Les poids sont initialisés avec des valeurs aléatoires. Puis on présente au réseau de neurones des exemples expérimentaux représentatifs du fonctionnement du procédé dans un domaine donné (des valeurs des vecteurs d'entrée et de sortie). Afin de minimiser l'écart entre les sorties calculées et les sorties expérimentales pendant la phase d'apprentissage, les poids sont modifiés au fur et à mesure des itérations pendant lesquelles la totalité des exemples est présentée.

Pour éviter les problèmes de surapprentissage, les données expérimentales sont divisées en deux parties : la base d'apprentissage et la base de test. L'amélioration des poids est réalisée sur la base d'apprentissage. Les poids pour lesquels l'erreur obtenue sur la base de test est la plus faible sont conservés. En effet, on obtient

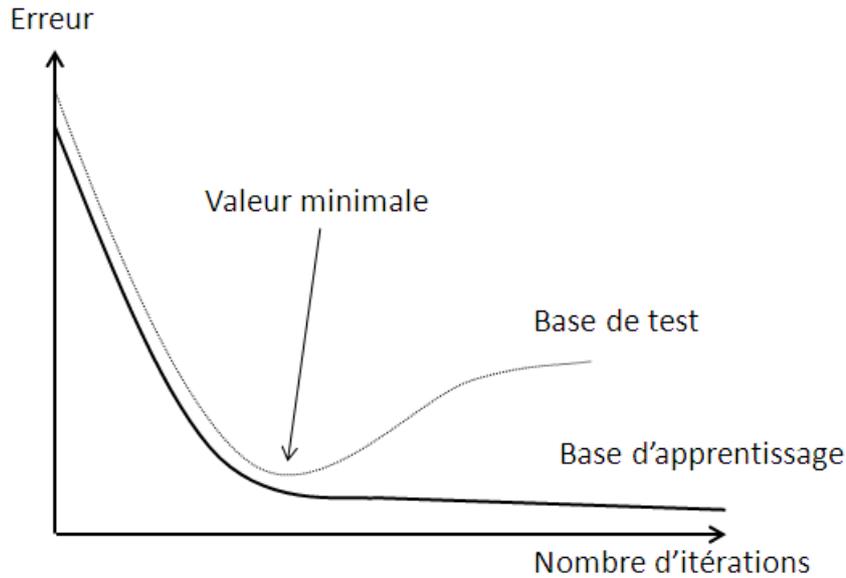


FIGURE 2.14 – Erreur moyenne sur la base d'apprentissage en fonction du nombre d'itérations.

une précision très satisfaisante sur tous les exemples de l'apprentissage si les poids sont optimisés, mais on risque de ne pas pouvoir généraliser le modèle à des données nouvelles. Après un certain nombre d'itérations, le réseau ne cherche plus l'allure générale de la relation entre les entrées et les sorties du système, mais s'approche trop près des points et « apprend » le bruit [Pollard et al., 1992, Van der Laan and Pollard, 2003].

Sur la figure 2.14 ci-dessous, on peut observer qu'au début de l'apprentissage, l'erreur sur la base d'apprentissage est grande. Ensuite, cette erreur diminue avec le nombre d'itérations. Alors que l'erreur sur la base de test diminue en atteignant une valeur minimale puis augmente à partir d'un certain nombre d'itérations. Lorsque l'erreur de la base de test commence à augmenter, on peut arrêter l'apprentissage et choisir le poids qui correspond à la valeur minimale de l'erreur sur la base de test.

Surapprentissage : l'apprentissage d'un réseau de neurones sur le même échantillon conduit à un phénomène qu'on appelle le surapprentissage. Le réseau de neurones qui a « sur-appris » ou appris par cœur et devient inapte à reconnaître autre chose que les éléments présents dans l'échantillon. Le réseau ne cherche plus des lois générales de la relation entre les entrées et les sorties du système, mais cherche à reproduire les mêmes lois qu'il a apprises par cœur. Ainsi, le réseau est devenu trop spécialisé et ne généralise plus correctement. De même, si on utilise trop d'unités cachées (de connexions), le phénomène du surapprentissage apparaît aussi.

Dans le paragraphe 2.4.6, nous renforcerons encore la robustesse de ces apprentissages ainsi que l'évaluation de la qualité des apprentissages par la technique de la validation croisée.

2.3.4.5 Type d'apprentissage

les types d'apprentissage peuvent être regroupés en trois catégories [Hassoun, 1995] : les règles d'apprentissage supervisées, non supervisées, et renforcées.

Apprentissage supervisé : un apprentissage est dit supervisé lorsque l'on guide le réseau de neurones vers des sorties désirées. Ce type d'apprentissage est réalisé à l'aide d'une base d'apprentissage, constituée de plusieurs exemples de type entrées-sorties (les entrées du réseau et les sorties désirées ou encore les solutions souhaitées pour l'ensemble des sorties du réseau). La procédure usuelle dans le cadre de la prévision est l'apprentissage supervisé (ou à partir d'exemples) qui consiste à associer une réponse spécifique désirée à chaque signal d'entrée. La modification des poids s'effectue progressivement jusqu'à ce que l'erreur (ou l'écart) entre les sorties du réseau (ou résultats calculés) et les résultats désirés sont minimisés. Cet apprentissage n'est performant que si un large jeu de données est disponible et si les solutions sont connues pour les exemples de la base d'apprentissage.

Apprentissage non supervisé : l'apprentissage non supervisé consiste à ajuster les poids à partir d'un seul ensemble d'apprentissage. Aucun résultat désiré n'est fourni au réseau. L'apprentissage consiste à détecter les similarités et les différences dans l'ensemble d'apprentissage. Les poids et les sorties du réseau convergent, en théorie, vers les représentations qui capturent les régularités statistiques des données [Fukushima, March 1988, Hinton, 1988]. Ce type d'apprentissage est également dit compétitif et (ou) coopératif [Grossberg, 1992]. L'avantage de ce type d'apprentissage réside dans sa grande capacité d'adaptation reconnue comme une auto-organisation, « self-organizing » [Kohonen and Somervuo, 2002]. L'apprentissage non supervisé est surtout utilisé pour le traitement du signal et l'analyse factorielle.

Apprentissage renforcé : l'apprentissage renforcé est une technique similaire à l'apprentissage supervisé. Cependant, au lieu de fournir des résultats désirés au réseau, on lui accorde plutôt un grade (ou score) qui est une mesure du degré de performance du réseau après quelques itérations. Les algorithmes utilisant la procédure d'apprentissage renforcé sont surtout utilisés dans le domaine des systèmes de contrôle [White and Sofge, 1992, Sutton, 1992].

2.3.5 Prédiction

2.3.5.1 Introduction

La prédiction numérique consiste à prédire des valeurs qui caractérisent les données d'entrée. La méthode la plus largement utilisée pour la prévision numérique (ci-après dénommée prédiction) est la régression. C'est une méthode statistique qui a été développée par [Galton, 1886]. En fait, de nombreuses études ont utilisé les termes « régression » et « prédiction numérique » comme synonymes. Cependant, comme nous l'avons vu, certaines techniques de classification (telles que les réseaux de neurones artificiels, les SVM, etc.) peuvent être adaptées pour la prédiction. Dans cette section, nous présentons les techniques de régression et la méthodologie qui leur est associée pour la prédiction.

L'analyse par régression peut être utilisée pour modéliser la relation entre une ou plusieurs variables indépendantes. Dans le cadre de l'exploration de données, les variables explicatives sont les attributs intéressants décrivant l'ensemble de données (qui constituent le vecteur d'attributs). En général, les valeurs des variables prédictives sont connues. Étant donné un ensemble de données décrit par des variables prédictives, on veut prédire la valeur associée à la variable « réponse » à partir d'un ensemble de données décrit par des variables prédictives. Une introduction intuitive à la régression est fournie dans cette section. Dans la sous-section 2.3.5.2, nous discutons de l'analyse de régression linéaire (ce qui implique une variable explicative unique) et analyse de régression linéaire multiple (qui comprend deux ou plusieurs variables prédictives).

2.3.5.2 Régression linéaire

La régression linéaire comprend une variable de réponse, y , qui est fonction d'une variable prédictive unique, x . Il s'agit de la forme la plus simple de la régression. La variable y est modélisée comme une fonction linéaire de x :

$$y = b + w x. \quad (2.11)$$

La variance de y est supposée être constante et w et b sont des coefficients de régression spécifiant l'ordonnée à l'origine et la pente de la droite, respectivement (figure 2.15). Les coefficients de régression, w et b , peuvent également être considérés comme des poids. Nous pouvons alors écrire de façon équivalente :

$$y = w_0 + w_1 x. \quad (2.12)$$

Ces coefficients peuvent être calculés par la méthode des moindres carrés qui estime les coefficients w_1 et w_2 comme ceux qui minimisent l'erreur entre les données réelles et la droite modèle.

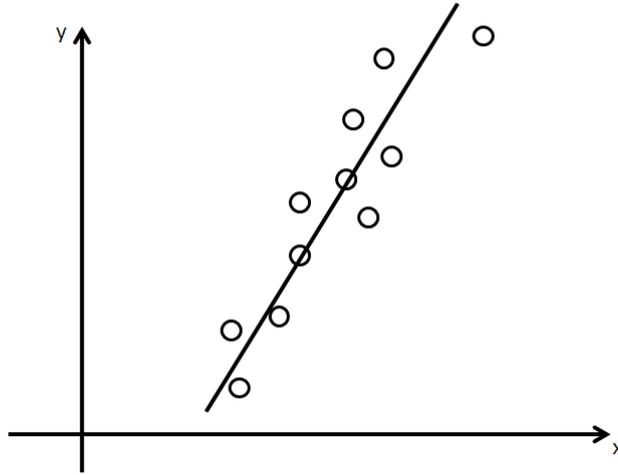


FIGURE 2.15 – Régression par une ligne droite.

Soit D un ensemble d'apprentissage ayant les valeurs de la variable prédictive x d'une population et leurs valeurs associées pour la variable réponse y . L'ensemble d'apprentissage contient D points de données de la forme $(x_1, y_1), (x_2, y_2), \dots, (x_D, y_D)$. Les coefficients de régression peuvent être estimés à l'aide des équations :

$$w_1 = \frac{\sum_{i=1}^D (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^D (x_i - \bar{x})^2} \quad (2.13)$$

et

$$w_0 = \bar{y} - w_1 \bar{x}, \quad (2.14)$$

où \bar{x} est la valeur moyenne de (x_1, x_2, \dots, x_D) , et \bar{y} est la valeur moyenne de (y_1, y_2, \dots, y_D) . Les coefficients w_0 et w_1 fournissent souvent de bonnes approximations pour les équations de régression non complexes.

La régression linéaire multiple est une extension de la régression linéaire afin d'impliquer plus d'une variable prédictive. Elle permet de modéliser la variable réponse y comme une fonction linéaire de n variables prédictives où des attributs, A_1, A_2, \dots, A_n , décrivent un ensemble de données, $X = (x_1, x_2, \dots, x_n)$. L'ensemble d'apprentissage D contient les données de la forme $(X_1, y_1), (X_2, y_2), \dots, (X_D, y_D)$, où X sont les ensembles d'apprentissage à n dimensions avec des étiquettes de classe associées y_i . Un exemple d'un modèle de régression linéaire multiple fondé sur deux attributs A_1 et A_2 est :

$$y = w_0 + w_1 x_1 + w_2 x_2, \quad (2.15)$$

où x_1 et x_2 sont les valeurs d'attributs A_1 et A_2 , respectivement. La méthode des moindres carrés peut être étendue pour calculer w_0, w_1 et w_2 . Cependant, les équations deviennent longues et fastidieuses à résoudre analytiquement.

2.3.6 Mesures des performances d'un test

Dans cette section, la présentation des mesures de performance est orientée dans le cadre de travaux de l'estimation de la durée de vie des matériaux composites. Ainsi, la notion de modèle employée jusqu'à présent sera associée aux tests d'EA sur les matériaux composites.

2.3.6.1 Indices synthétiques de la performance d'un test

Généralement, pour obtenir les performances des modèles de classification, on cherche principalement leur précision de classification sur le sous-ensemble de test : plus précisément, la probabilité d'erreur de classification donnant la proportion totale des observations mal classées. Avoir la probabilité d'erreur comme unique information peut être insuffisante. En effet dans un problème binaire, un problème à deux classes, où le résultat du test est soit positif soit négatif, les erreurs de chacune des classes, les faux positifs et les faux négatifs, ne sont pas distinguées. Les éléments de ces deux groupes sont alors considérés par cette mesure de performance comme des erreurs de même nature. Une fausse idée de la qualité du modèle de classification est alors donnée par le taux d'erreur lorsque les classes sont déséquilibrées.

D'autre part, la distinction entre ces deux erreurs de prédiction peut être nécessaire dans certaines applications, notamment dans la prédiction de la rupture des éprouvettes, où l'on cherche à déterminer les capacités d'un test à prédire la rupture. Cette remarque montre que l'utilisation du taux d'erreur de prédiction comme seul indicateur n'est pas suffisant pour évaluer l'erreur de la prédiction. La performance d'un test de rupture peut alors être décrite en termes de fiabilité distinguant les éprouvettes qui sont dans la phase de rupture de celles qui ne le sont pas. Ainsi, les résultats de tests sont utilisés afin de déterminer la probabilité qu'une éprouvette se situe dans la phase de rupture ou non : on parle généralement de prédiction positive quand le résultat du test sur une éprouvette indique une présence de signes « rupture » et une prédiction négative en absence de signes. Dans un test, la distinction entre une classe positive et une classe négative n'est pas toujours clairement définie (représentée par le chevauchement des deux densités de probabilité à la figure 2.16). La détermination d'un seuil devient donc nécessaire afin de lever l'incertitude lors de la prédiction du test. La figure 2.16 illustre un exemple simple, où l'on cherche à définir la validité d'un test pouvant prédire l'existence de l'éprouvette dans la phase de rupture. Le seuil permet alors de diviser l'échantillon de patients en quatre groupes :

- le vrai positif (VP) représente le résultat positif du test dont l'état de l'éprouvette est dans la phase de **rupture** ;

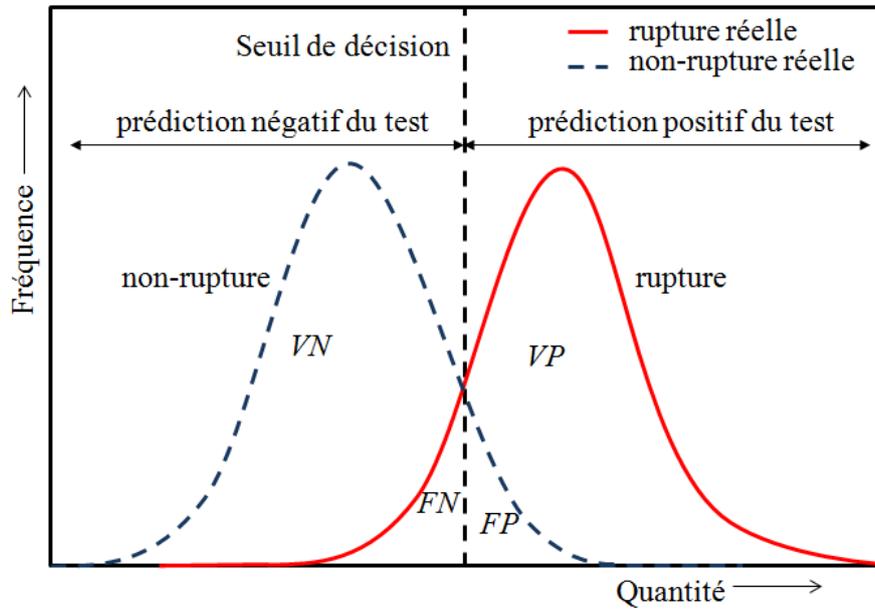


FIGURE 2.16 – Illustration des quatre états possibles lors de la prédiction d'un modèle de classification binaire : vrai/faux positif et vrai/faux négatif.

- le vrai négatif (VN) représente le résultat négatif du test quand l'état de l'éprouvette est dans la phase de **non-rupture** ;
- le faux positif (FP) représente le résultat positif du test quand l'état de l'éprouvette est dans la phase de **non-rupture** ;
- le faux négatif (FN) représente le résultat négatif du test quand l'état de l'éprouvette est dans la phase de **rupture**.

Les quatre variables (VP, VN, FP et FN) sont représentées dans le tableau 2.3, où les éléments de la diagonale donnent les observations bien classées pour chacune des classes. Ainsi, plusieurs indices sont récapitulés dans le tableau 2.4. Ces indices vont permettre de rendre l'interprétation des résultats du test plus pertinente.

TABLE 2.3 – Description des quatre variables issues de la prédiction d'un test de classification binaire : vrai/faux positif et vrai/faux négatif [Feuilloy, 2009].

		observation réelle de l'état du l'éprouvette	
		positive (rupture)	négative (non-rupture)
prédiction du test	positif > seuil	VP	FP
	négative < seuil	VN	FN

Les indices les plus connus, disponibles à partir des quatre variables, sont la sensibilité et la spécificité. La sensibilité S_e (aussi appelée Fraction de Vrais Positifs)

est la proportion d'éprouvettes, situées dans la phase de rupture, et effectivement bien détectées comme telles par le test. Autrement dit, la sensibilité permet de mesurer à quel point le test est performant lorsqu'il est utilisé sur des éprouvettes qui sont dans la phase de rupture. Le test est parfait lorsque la sensibilité vaut 1, alors qu'il est équivalent à un tirage au hasard lorsque la sensibilité vaut 0,5. Mais s'il est inférieur à 0,5, le test est contre-performant, on peut inverser la règle pour qu'il soit supérieur à 0,5 (à condition que cela n'affecte pas la spécificité). La définition mathématique est : $S_e = VP/(VP + FN)$. La spécificité S_p (aussi appelée Fraction de Vrais Négatifs) est la proportion d'éprouvettes, situées dans la phase de non-rupture, et effectivement bien détectées comme telles par le test. Autrement dit, la spécificité permet de mesurer à quel point le test est performant lorsqu'il est utilisé sur des éprouvettes qui sont dans la phase de non-rupture. Le test est parfait lorsque la spécificité vaut 1, alors qu'il est équivalent à un tirage au hasard lorsque la spécificité vaut 0,5. Mais si elle est inférieure à 0,5, alors le test est contre-performant, on peut inverser la règle pour qu'il soit supérieur à 0,5 (à condition que cela n'affecte pas la sensibilité). La définition mathématique est : $S_p = VN/(VN + FP)$. L'indice de ROC (Receiver Operating Characteristic) dépend du meilleur compromis entre ces deux critères. Pour évaluer la qualité du test, il faut minimiser l'indice de ROC afin d'obtenir conjointement les meilleures sensibilité et spécificité, réduisant par conséquent, les faux négatifs et les faux positifs. Cet indice est donné par la formule suivante :

$$ROC = \sqrt{(1 - \text{spécificité})^2 + (1 - \text{sensibilité})^2} \quad (2.16)$$

L'augmentation d'un des deux paramètres occasionne une réduction de l'autre. C'est pourquoi dans l'évaluation d'un test, il est nécessaire de ne jamais considérer la sensibilité sans la spécificité et réciproquement.

D'autres indices sont utilisés pour l'évaluation d'un test ; on peut citer :

- la fraction de faux positifs ($FFP = 1 - S_p$) : proportion des éprouvettes négatives (non-rupture) détectées comme positives (rupture) par le test,
- la fraction de faux négatifs ($FFN = 1 - S_e$) : proportion des éprouvettes positives détectées comme négatives par le test,
- prévalence de l'événement ($P_e = (VP + FN)/N$) : fréquence de apparition de l'événement dans l'échantillon total.

2.3.6.2 Courbes de ROC

Ainsi qu'évoqué précédemment, il est nécessaire de recourir à d'autres indices que le sensibilité et la spécificité afin d'évaluer de manière fine nos modèles prédictifs. Les courbes de ROC [Metz, 1978, Fawcett, 2005] ont démontré de tels capacités

TABLE 2.4 – Descriptions des indices d'évaluation obtenus à partir des quatre variables (voir tableau 2.3).

Indice	Relation
Sensibilité (S_e)	$S_e = \frac{VP}{VP+FN}$
Spécificité (S_p)	$S_p = \frac{VN}{VN+FP}$
Fraction de faux positifs (FFP)	$FFP = 1 - S_p$
Fraction de faux négatifs (FFN)	$FFN = 1 - S_e$
Prévalence de l'événement (P_e)	$P_e = (VP + FN)/N$
Valeur prédictive positive (VPP)	$VPP = \frac{VP}{VP+FP}$
Valeur prédictive négative (VPN)	$VPN = \frac{VN}{VN+FN}$
Rapport de vraisemblance positif ($LR+$)	$LR+ = \frac{\text{Sensibilité}}{(1-\text{Spécificité})}$
Rapport de vraisemblance négatif ($LR-$)	$LR- = \frac{(1-\text{Sensibilité})}{\text{Spécificité}}$
Risque relatif (R_r)	$R_r = VPP/VPN$

d'évaluation. Elles sont fondées sur la théorie statistique de la décision. Elles ont été développées initialement pour la détection de signaux associés aux radars durant la seconde guerre mondiale, où les opérateurs radars devaient distinguer les vols d'avions parmi d'autres artefacts. Dans les années 1970, les courbes de ROC sont apparues afin d'améliorer la prise de décision en imagerie médicale [Hanley and McNeil, 1982]. Depuis quelques années, ces courbes sont présentes dans de nombreux domaines. Nous allons les utiliser pour caractériser les capacités (et les limitations) d'un test pouvant prédire si l'état d'une éprouvette sous charge est dans la phase de rupture ou de non-rupture.

Ces courbes sont utilisées afin de visualiser la performance globale du test en analysant les variations de la sensibilité et de la spécificité. Elles sont construites en traçant l'évolution de la sensibilité en fonction du paramètre $1 - \text{spécificité}$, en faisant varier le seuil de décision du modèle (voir figure 2.16). Elles présentent l'avantage d'être moins sensibles au déséquilibre entre les classes.

Pour évaluer numériquement la courbe de ROC, nous utilisons la surface sous la courbe de ROC (AUC, Area Under the Curve) comme indice d'évaluation. Cet indice peut être considéré comme la probabilité d'un modèle à prédire correctement l'état d'une éprouvette en test (rupture ou non-rupture). Nous pouvons observer deux cas particuliers sur la figure 2.17 :

- une aire AUC de 0,5 indique que le modèle est équivalent au hasard et il n'apporte rien à la prédiction. Nous ne pouvons pas utiliser ce modèle pour différencier les deux classes, c'est équivalent à un recouvrement total des deux densités de probabilité, avec $VP = FP$ (voir figure 2.16) ;
- une aire égale à 1 correspond à un résultat parfait, avec une sensibilité et une spécificité de 100%, dans ce cas les deux classes sont parfaitement séparées.

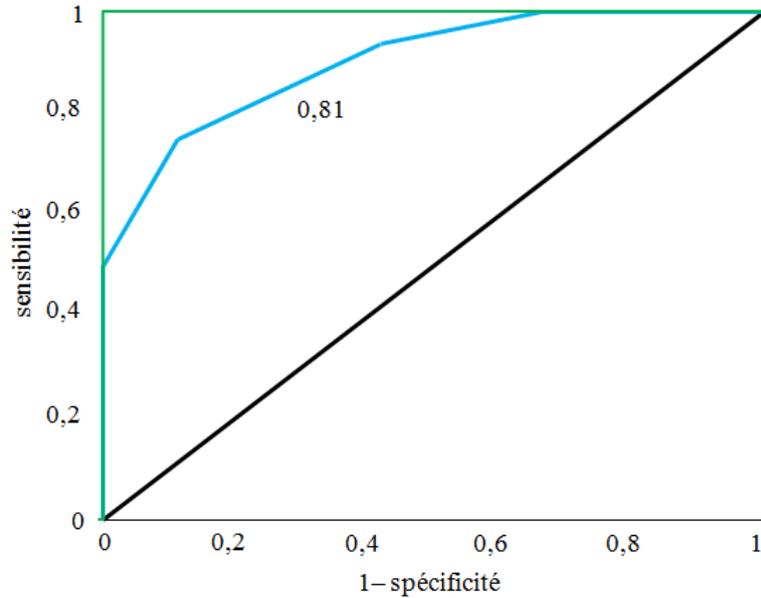


FIGURE 2.17 – Exemple de courbes de ROC.

L'analyse des courbes de ROC était initialement utilisée pour traiter des problèmes binaires. D'autres travaux [Srinivasan, 1999, Landgrebe and Duin, 2007, 2008] ont été proposés pour étendre l'utilisation des courbes de ROC aux problèmes multi-classes. Néanmoins, leur utilisation dans les problèmes de multi-classes présente une complexité calculatoire importante.

2.3.6.3 Comparaison de modèles par analyse des courbes de ROC

Nous avons vu plusieurs types d'approches pour la classification et la discrimination, ce qui génère de multiples modèles. Ainsi, il faut donc comparer les performances de chaque modèle pour sélectionner le meilleur.

Dans ce qui précède, nous avons mentionné des méthodes et des indices pour mesurer la performance d'un modèle, on peut citer par exemple la sensibilité, la spécificité et l'aire sous la courbe de ROC. Néanmoins, l'utilisation simultanément de plusieurs indices peut rendre l'interprétation de la performance difficile. C'est pourquoi, dans notre étude, nous nous limiterons à l'aire sous la courbe, à la sensibilité et à la spécificité comme indices pour interpréter la performance de nos modèles.

2.4 Application

Nous rappelons que la problématique (définie à la section 2.2) est de prédire si un signal d'EA, sélectionné aléatoirement à l'instant t , appartient à l'intervalle de temps de pré-rupture du matériau ou pas. Pour résoudre cette problématique, nous avons appliqué des méthodes d'apprentissage artificiel pour classer et localiser les signaux d'EA sur deux intervalles de temps que nous avons intitulés intervalle de rupture et intervalle de non-rupture. La procédure adoptée débute par la sélection aléatoire des signaux d'EA à partir des différents tests, afin de les répartir entre les deux intervalles (sous-section 2.4.1). Ces signaux formeront la base de données qui sera utilisée pour l'apprentissage puis pour la validation des résultats de l'outil appliqué (réseau de neurones, SVM et classifieurs bayésiens, détaillés auparavant dans ce chapitre).

Dans la deuxième étape, nous procédons à l'extraction des paramètres qui vont être utilisés par les méthodes d'apprentissage artificiel (sous-section 2.4.2). La normalisation des données (sous-section 2.4.3) est nécessaire avant tout apprentissage. L'étape suivante consiste à supprimer les données aberrantes (détaillé dans la partie 2.4.4) ; ces données affectent l'apprentissage et entraînent des mauvais résultats de décision. Par ailleurs, le grand nombre et l'utilisation simultanée de certains paramètres nuisent aux capacités de la méthode pour discriminer les signaux. Pour optimiser l'efficacité de la méthode nous avons mis en œuvre une technique de sélection des paramètres pertinents (sous-section 2.4.5).

Afin de valider les résultats, la technique puissante de validation croisée a été appliquée sur les différentes méthodes d'apprentissage artificiel (détaillée au paragraphe 2.4.6). Enfin, une présentation des résultats est donnée dans la sous-section 2.4.7. Le schéma de la figure 2.18 synthétise les différentes étapes que nous allons décrire dans la suite.

2.4.1 Sélection des signaux d'EA

Afin de remplir la base de données des machines d'apprentissage artificiel pour classer les signaux, nous avons sélectionné plusieurs signaux en respectant la « prévalence » des classes, de manière à avoir autant de signaux des deux classes.

Les signaux sont sélectionnés aléatoirement et sont répartis sur l'intervalle complet d'un test. Nous avons effectué 7 tests de fluage jusqu'à la rupture complète de chacune des éprouvettes. Par ailleurs, pour chaque éprouvette, 12 signaux différents ont été sélectionnés par intervalle de rupture, et 12 signaux par intervalle de non-rupture. Finalement, nous obtenons 168 signaux dont 84 signaux pour l'intervalle

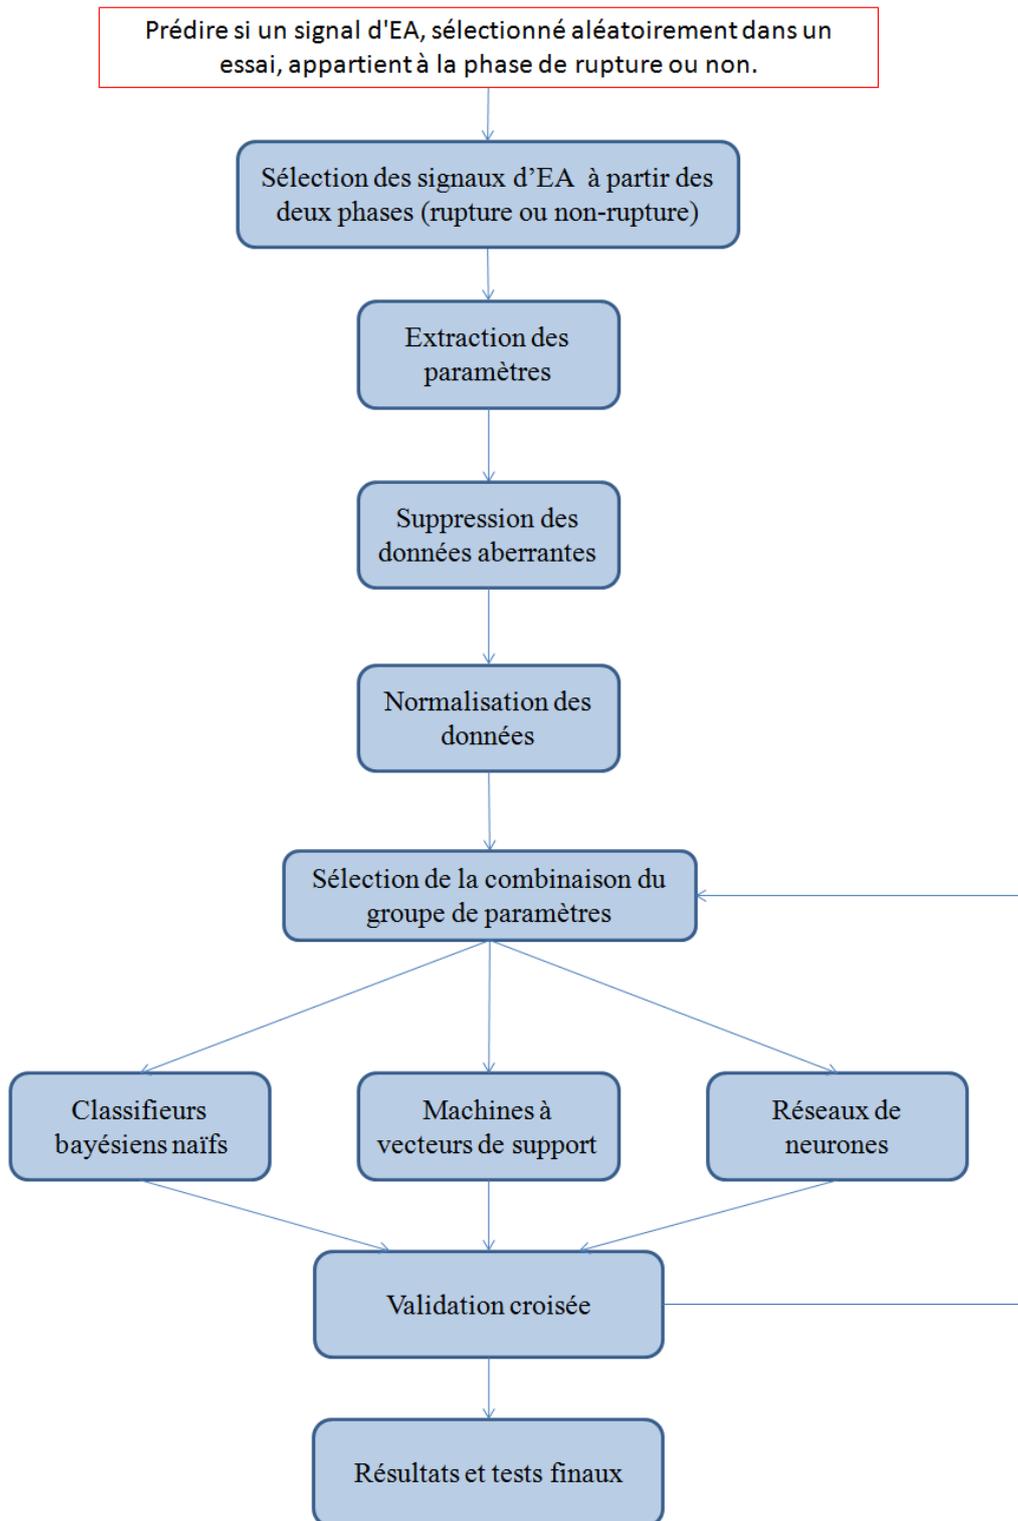


FIGURE 2.18 – Schéma représentatif de l'application des différentes étapes pour la discrimination des classes (rupture ou non-rupture).

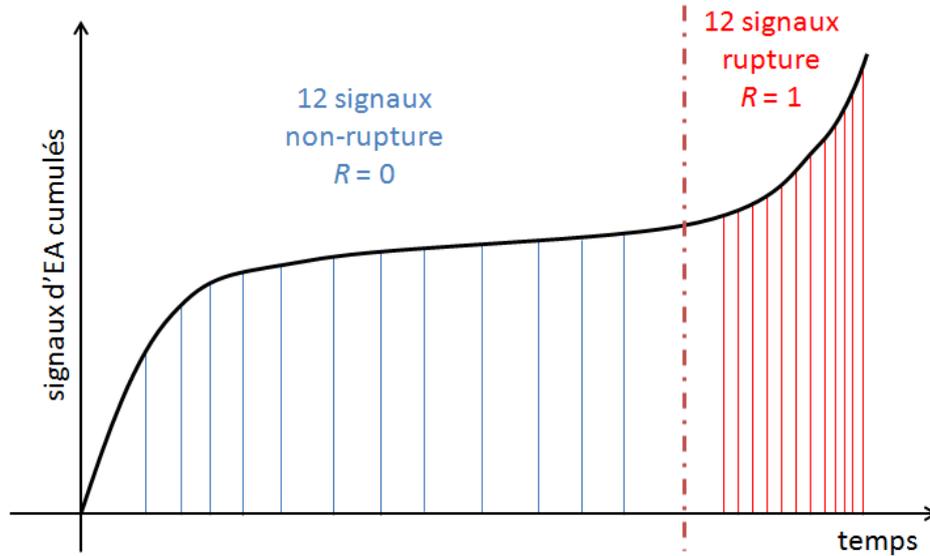


FIGURE 2.19 – Processus de sélection des signaux à partir des tests et selon les phases.

de rupture et 84 signaux pour l'intervalle de non-rupture. Le processus de sélection est représenté par la figure 2.19.

2.4.2 Extraction des paramètres

L'étude présentée dans la section 2.1 porte sur l'utilisation des paramètres extraits des signaux d'EA pour pouvoir faire la discrimination. Les paramètres utilisés dans cette étude peuvent être extraits par analyse temporelle ou fréquentielle ou temps-échelle. Dans notre travail, nous utilisons l'analyse temporelle des signaux d'EA enregistrés durant les tests pour extraire les paramètres qui serviront à différencier l'appartenance à tel ou tel intervalle.

Les paramètres que nous avons sélectionnés sont, l'amplitude, l'énergie, la durée, le temps de montée, le nombre de coups, le nombre de coups au pic et la fréquence (*nombre de coups / durée*) [Marec et al., 2008]. Après l'analyse des paramètres enregistrés par les appareils présentés dans la sous-section 1.5.3.4, nous avons effectué une mise en forme et un calcul pour optimiser la précision des valeurs des paramètres extraits.

Les paramètres que nous venons de citer sont les paramètres d'entrée du système d'apprentissage. La fonction de sortie pour chaque vecteur de paramètres c'est-à-dire la réponse, sera « rupture » ($R = 1$) ou « non-rupture » ($R = 0$). Dans notre travail, le type d'apprentissage que nous utilisons est un apprentissage supervisé. Les signaux sélectionnés dans la phase de rupture ont une valeur de $R = 1$ et ceux

qui étaient sélectionnés dans la phase de non-rupture ont une valeur $R = 0$ (figure 2.19).

2.4.3 Normalisation des données

La normalisation des données consiste à doter les paramètres réduits de distributions normales au moyen de changements de variables. Elle permet de s'affranchir des différences de « normes » entre les variables. Sans normalisation préalable, les paramètres pourraient altérer significativement les performances des machines d'apprentissage. Une des techniques utilisées consiste à aborder chaque variable indépendamment et de calculer pour chaque variable x_j la valeur moyenne \bar{x}_j et l'écart type σ_j . Ainsi, la normalisation de l'élément x_{ij} de la variable x_j se fait à l'aide de l'expression :

$$\tilde{x}_{ij} = \frac{x_{ij} - \bar{x}_j}{\sigma_j}. \quad (2.17)$$

En appliquant indépendamment cette règle à toutes les données de chacune des variables nous obtenons pour chaque paramètre réduit une valeur moyenne nulle et une variance égale à un. D'autres types de normalisations sont possibles, fondées sur des fonctions non linéaires, comme les fonctions de type sigmoïde ou logarithmiques [Pyle, 1999, Theodoridis and Koutroumbas, 2006] par exemple.

2.4.4 Données aberrantes

Une donnée aberrante « outlier » est une observation qui se trouve « éloignée » des autres observations ; elle diffère de manière importante des autres données. D'un point de vue de la distance, c'est une donnée éloignée de la valeur moyenne de la distribution de la variable correspondante (figure 2.2) [Theodoridis and Koutroumbas, 2006].

Un inconvénient apparaît en présence de ce type de données lors du calcul de la moyenne. Ces données influencent la valeur moyenne et la ramènent dans leur direction. Ce type de données a un effet sur la détermination par la méthode des moindres carrés de l'hyperplan discriminant (figure 2.20). L'effet des données aberrantes apparaît directement sur la normalisation : les données aberrantes se retrouvent éloignées de la moyenne. Elles affectent directement les performances des outils de classification durant l'apprentissage. La détermination de la frontière de décision rencontre alors une forte sensibilité aux valeurs aberrantes [Bishop, 2006, Theodoridis and Koutroumbas, 2006].

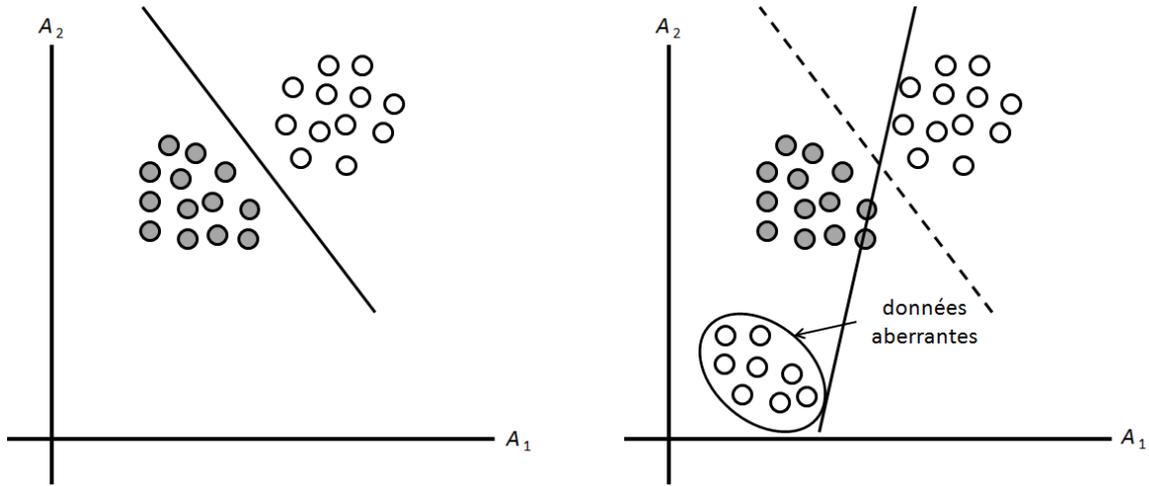


FIGURE 2.20 – Influence de la présence de données aberrantes sur la frontière de décision obtenue par les moindres carrés.

Pour détecter les données aberrantes, il faut déterminer un seuil permettant d'isoler les valeurs aberrantes. Une technique consiste à calculer le seuil en fonction de l'écart type. Si on calcule la moyenne μ et l'écart type σ , on trouve que l'intervalle $[\mu - 2\sigma, \mu + 2\sigma]$ couvre 95 % des données et l'intervalle $[\mu - 3\sigma, \mu + 3\sigma]$ en couvre 99 %. Ainsi, toute variable de valeur supérieure à $\mu + 2\sigma$ ou inférieure à $\mu - 2\sigma$ est susceptible d'être une valeur aberrante, comme l'illustre la figure 2.21. Un exemple concret des valeurs aberrantes des données que nous utilisons est représenté par le tableau 2.5. Il s'agit d'une étude statistique sur le paramètre « nombre de coups au pic ». Ces valeurs ont une moyenne de 5332 et un écart-type de 31990, donc l'intervalle de décision sera $[-58649, 69313]$, il n'existe pas de valeurs négatives donc l'intervalle devient $[0, 69313]$. Nous avons trouvé trois données aberrantes ($N=3$) parmi les 128 données enregistrées. Il pourrait être surprenant d'avoir une telle valeur importante de l'écart-type (écart-type= 31990), mais les trois données aberrantes trouvées avaient des valeurs très importantes (valeur maximale trouvée = 277000, cf. tableau 2.5).

TABLE 2.5 – Exemple de variables aberrantes trouvées dans nos données enregistrées.

nombre de coups au pic	minimum	maximum	moyenne	écart-type	seuil
valeur	19	277000	5332	31990	69313

Une autre méthode qui peut être utilisée pour détecter les données aberrantes est d'utiliser le premier quartile (Q_1) et le troisième quartile (Q_3) pour évaluer la dispersion des données et définir les seuils : les valeurs aberrantes seront celles qui se trouvent à l'extérieur de l'intervalle $[Q_1 - 1,5(Q_3 - Q_1); Q_3 + 1,5(Q_3 - Q_1)]$. Ces seuils ont été mis en évidence par [Pyle, 1999, Tufféry, 2007].

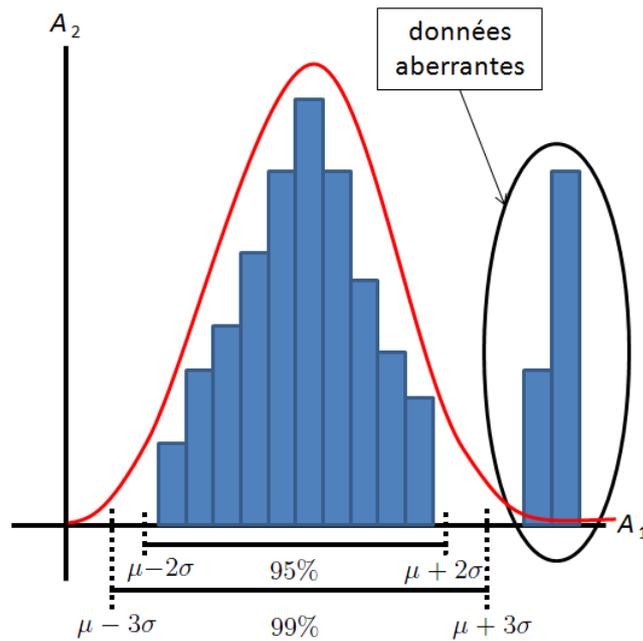


FIGURE 2.21 – Détection d’observations aberrantes pour une variable aléatoire de distribution normale.

Cependant, une fois que les valeurs aberrantes sont détectées, on peut tout simplement les considérer comme des valeurs erronées et donc les supprimer.

2.4.5 Réduction du nombre des paramètres

L’utilisation d’un grand nombre de paramètres peut nuire à la discrimination des échantillons. En effet, l’information utile peut être cachée ou noyée dans les données. Les algorithmes et les techniques statistiques sont pénalisés par trop de paramètres ou des paramètres redondants [Langley, 1996, Gutierrez-Osuna, 2002]. Chaque signal d’EA est représenté par un vecteur de dimension égal au nombre des paramètres retenus.

La réduction de la dimension est évidemment une des solutions du problème évoqué de la malédiction de la dimension. Les paramètres qu’il faut éliminer sont ceux qui s’avèrent inutiles et non pertinents (figure 2.22) pour la classification. Des études récentes, à titre d’exemple [Marec, 2008] dans le domaine de l’acoustique et [Feuilloy, 2009] dans le domaine de la santé et de la médecine, ont proposé des méthodes de réduction du nombre de paramètres extraits à partir des données utilisées. Pour ce faire, ils ont utilisé, entre autres, la méthode de l’ACP (Analyse en Composantes Principales) [Oja, 1991].

Dans notre travail, nous avons utilisé une méthode simple pour la sélection des paramètres pertinents. Cette méthode consiste à tester toutes les combinai-

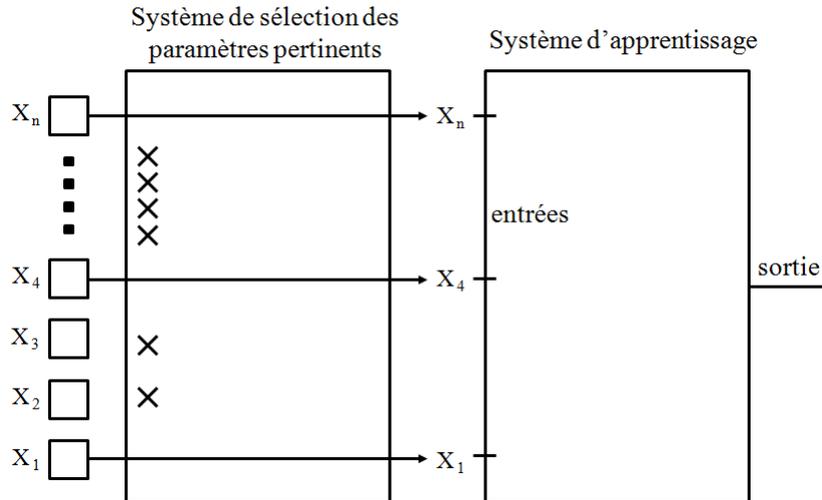


FIGURE 2.22 – Sélection des paramètres pertinents.

sons possibles des paramètres présélectionnés et à retenir le groupe minimal ayant les meilleurs résultats de classification². Nous avons 7 paramètres temporels sélectionnables ce qui conduit à $2^7 - 1$ combinaisons possibles.

L'avantage de cette méthode est de donner la combinaison des paramètres qui conduit aux meilleurs résultats de classification. Malgré le nombre important de combinaisons, dû au grand nombre de paramètres, cette méthode reste efficace grâce à la rapidité des méthodes d'apprentissage utilisées, comme les SVM ou les classifieurs bayésiens.

Dans le processus de réduction du nombre de paramètres, nous avons procédé à la technique de validation croisée (sous-section 2.4.6) pour évaluer le résultat de la classification. Les paramètres sélectionnés par le processus de réduction sont ensuite présentés dans la sous-section 2.4.7.

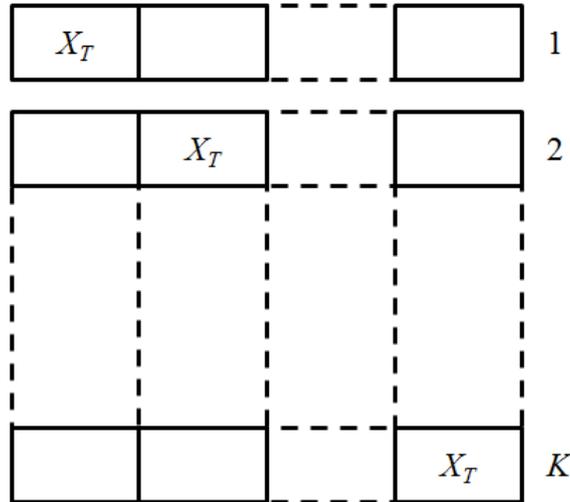
2.4.6 Validation croisée

Pour estimer la fiabilité de nos méthodes d'apprentissage statistique, nous utilisons une technique puissante dénommée validation croisée (*K-validation croisée*) [Stone, 1974]. Elle consiste à diviser les données aléatoirement en K sous-ensembles ($K > 1$) de taille approximativement égale. L'apprentissage du modèle s'effectue sur $K - 1$ sous-ensembles, l'erreur est évaluée sur le sous-ensemble n'ayant pas participé à l'apprentissage (sous-ensembles X_T sur la figure 2.6). Ce processus est répété K

2. Dans le monde de l'apprentissage artificiel, on ne prend pas en compte l'ordre des combinaisons. Par exemple si on a trois paramètres (p1, p2 et p3) à l'entrée de l'algorithme d'apprentissage, le changement de l'ordre d'entrée des paramètres (p2, p1 et p3) n'affecte pas les résultats de l'apprentissage.

fois. L'erreur générale est calculée en effectuant la moyenne des K erreurs mesurées. Cette erreur offre une estimation de ce que serait l'erreur sur un nouvel ensemble, qui n'aurait donc pas servi à réaliser les apprentissages.

TABLE 2.6 – Illustration du partitionnement d'un ensemble d'observations pour une validation croisée.



2.4.7 Résultats et discussions

Notre base de données est constituée de 8 paramètres extraits à partir des 165 signaux d'EA que nous avons sélectionnés (au départ, il y avait 168 signaux puis nous avons supprimé 3 signaux aberrants, voir le détail dans les sous-sections 2.4.1 et 2.4.4). Parmi ces paramètres, il y a les 7 paramètres d'entrée et un paramètre de sortie R ($R = 0$ ou $R = 1$). Nous avons divisé notre base de données en deux groupes : Le premier groupe est constitué de 125 éléments pour la phase d'apprentissage et la validation croisée ; les deuxième est constitué de 40 éléments qui vont être utilisés pour la phase du test final. La figure 2.23 récapitule cette procédure.

2.4.7.1 Résultats de la validation croisée

Pour appliquer la validation croisée, les 125 éléments de la base de données ont été divisés en 5 sous-ensembles ($K = 5$) de 25 éléments chacun. Les outils d'apprentissage (SVM, Classifieurs bayésiens, réseaux de neurones) sont entraînés sur 4 sous-ensembles puis testés sur le 5^{ème} sous-ensemble.

Il est à noter qu'avant de partager la base de données en sous-ensembles, nous avons mélangé ces éléments de façon à garder la prévalence de 50 % ($R = 0$ et $R = 1$) dans chacun des sous-ensembles.

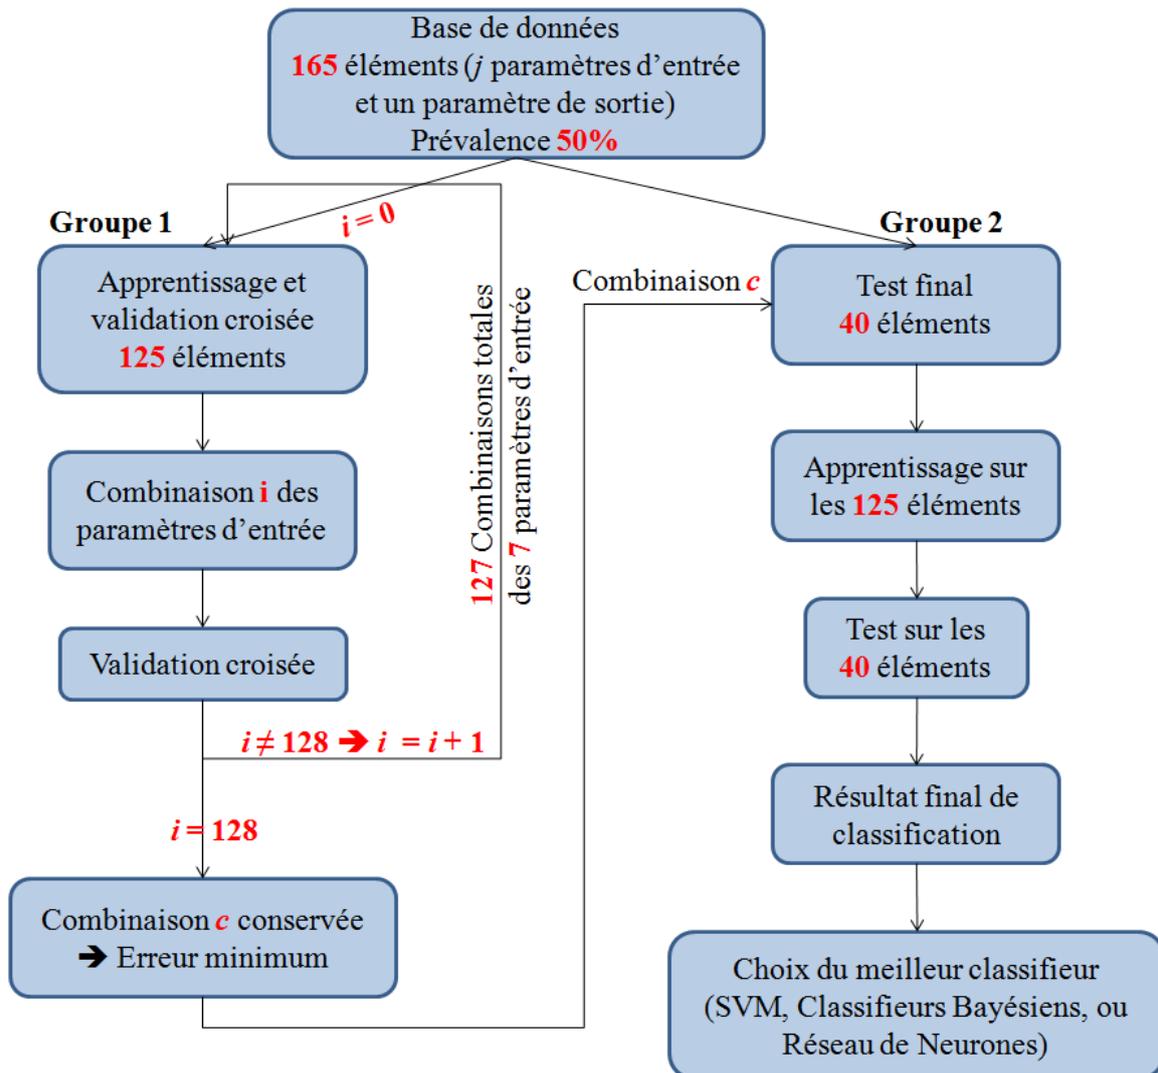


FIGURE 2.23 – Sélection de la combinaison du groupe de paramètres ayant les meilleurs résultats.

Les meilleurs résultats obtenus à partir des différentes combinaisons, sont ceux résultant de l'utilisation de la combinaison des trois paramètres suivants : la durée du signal (1), le nombre de coups au pic (2) et l'amplitude (3), et ceci sur les trois machines d'apprentissage mises en œuvre. Dans le tableau 2.7, nous présentons les différents résultats inhérents à la combinaison retenue et la performance de la classification pour les trois machines d'apprentissage.

Nous précisons que l'algorithme du réseau de neurones a nécessité 24 heures de calcul avec un ordinateur de type i7 quatre double-core. Les deux autres algorithmes ont pris respectivement 4 heures 35 minutes pour les classifieurs bayésiens et 2 heures 17 minutes pour les SVM.

TABLE 2.7 – Résultats de la technique de K -validation croisée de la phase d'apprentissage

Combinaison de variables	Sensibilité (%)	Spécificité (%)	AUC
Machines à vecteurs de support			
1, 2, 3	$82 \pm 1,23$	$84 \pm 2,44$	$0,88 \pm 0,093$
1, 2, Δ	$80 \pm 3,32$	$79 \pm 2,24$	$0,82 \pm 0,073$
1, Δ , 3	$78 \pm 2,13$	$80 \pm 2,42$	$0,85 \pm 0,064$
Δ , 2, 3	$74 \pm 1,92$	$80 \pm 3,56$	$0,81 \pm 0,087$
Classifieurs bayésiens			
1, 2, 3	$83 \pm 2,19$	$82 \pm 3,36$	$0,86 \pm 0,079$
1, 2, Δ	$78 \pm 3,25$	$77 \pm 2,18$	$0,82 \pm 0,054$
1, Δ , 3	$76 \pm 1,35$	$79 \pm 3,51$	$0,82 \pm 0,092$
Δ , 2, 3	$75 \pm 1,86$	$78 \pm 3,33$	$0,80 \pm 0,076$
Réseaux de neurones			
1, 2, 3	$69 \pm 3,24$	$71 \pm 3,53$	$0,75 \pm 0,096$
1, 2, Δ	$63 \pm 3,76$	$69 \pm 2,98$	$0,71 \pm 0,085$
1, Δ , 3	$65 \pm 3,67$	$70 \pm 3,83$	$0,73 \pm 0,102$
Δ , 2, 3	$62 \pm 4,14$	$68 \pm 3,82$	$0,70 \pm 0,123$

En examinant minutieusement les résultats affichés dans le tableau 2.7, nous remarquons que les résultats obtenus par les réseaux de neurones sont les moins performants (sensibilité, spécificité et surface sous la courbe « AUC »). En plus, il ressort que les réseaux de neurones sont les moins rapides, parmi les méthodes utilisées, pour effectuer la classification.

Comme mentionné précédemment, la qualité des apprentissages sera évaluée par le critère de la surface sous la courbe (AUC). Nous remarquons que cette surface, dans le cas des SVM, a une valeur supérieure à celle obtenue par les classifieurs bayésiens, les SVM sont donc plus performants que les classifieurs bayésiens pour ce type d'application et ce type de données (tableau 2.7). Nous remarquons aussi que les SVM sont plus performants que les classifieurs bayésiens dans les autres combinaisons de paramètres.

La figure 2.24 présente les courbes de ROC des meilleurs résultats obtenus en validation croisée des trois machines d'apprentissage. Ces courbes montrent clairement les différences de performance entre les machines et justifient la décision de retenir les SVM pour la classification des données.

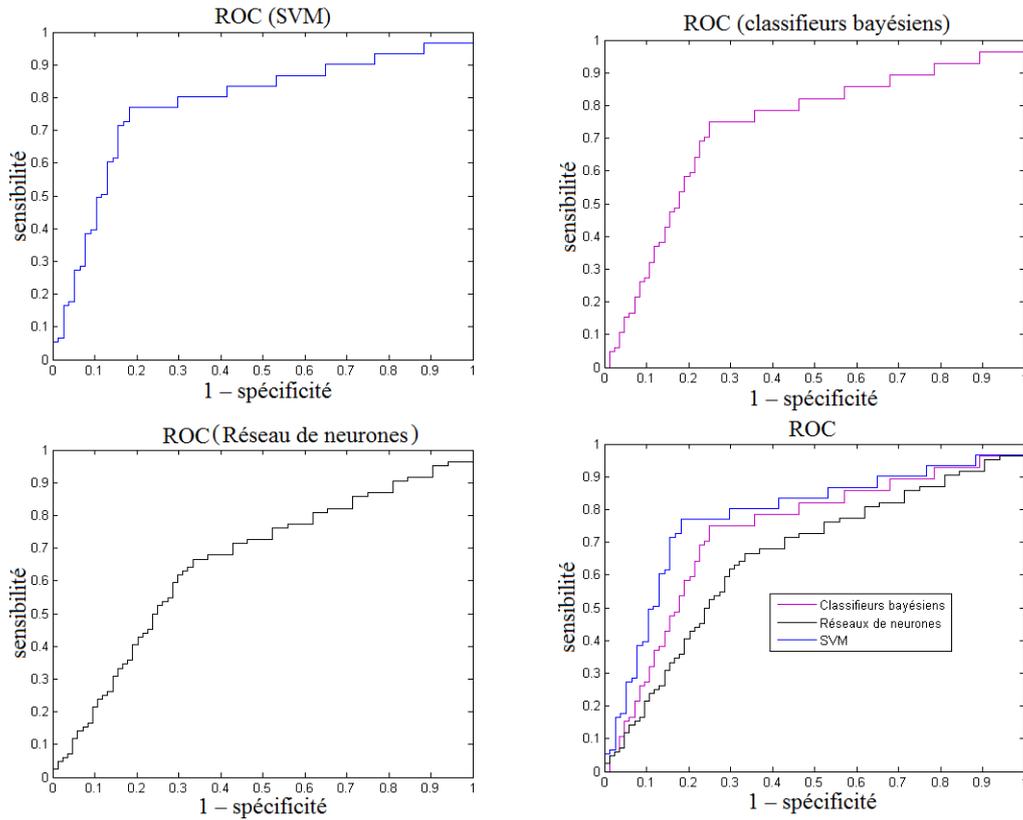


FIGURE 2.24 – Les courbes de ROC des meilleurs résultats obtenus de la validation croisée des trois machines d'apprentissage.

2.4.7.2 Résultats du test final

Dans la phase du test final, seuls les trois paramètres (durée du signal, nombre de coups aux pics et amplitude), avec lesquels nous avons obtenu les meilleures performances dans la phase de validation, ont été retenus. Lors du test final, les modèles d'apprentissage des trois machines sont évalués sur l'ensemble des 40 éléments qui ne sont pas encore été utilisés jusqu'à présent. Les résultats obtenus sont indiqués dans le tableau 2.8. Nous remarquons que les performances des trois machines sont proches des performances en validations croisées mais légèrement meilleures. À nouveau, nous avons remarqué que les SVM donnent les meilleurs résultats.

2.5 Conclusion

Dans ce chapitre, nous avons étudié la possibilité de prédire si un matériau en cours d'utilisation est dans la phase de rupture ou de non-rupture. Il s'agissait d'une problématique de classification, ce qui nous a poussé à utiliser des méthodes de classification basées sur l'apprentissage statistique (les réseaux de neurones, les

TABLE 2.8 – Résultats des machines d'apprentissage sur l'ensemble du test.

Combinaison de variables	Sensibilité (%)	Spécificité (%)	AUC
Machine à vecteurs de support			
1, 2, 3	90	94	0,92
1, 2, Δ	88	92	0,89
1, Δ , 3	89	93	0,90
Δ , 2, 3	86	90	0,88
Réseaux de neurones			
1, 2, 3	88	90	0,90
1, 2, Δ	86	90	0,87
1, Δ , 3	88	92	0,89
Δ , 2, 3	87	83	0,86
Classifieurs bayésiens			
1, 2, 3	83	86	0,87
1, 2, Δ	80	84	0,85
1, Δ , 3	78	84	0,84
Δ , 2, 3	75	82	0,81

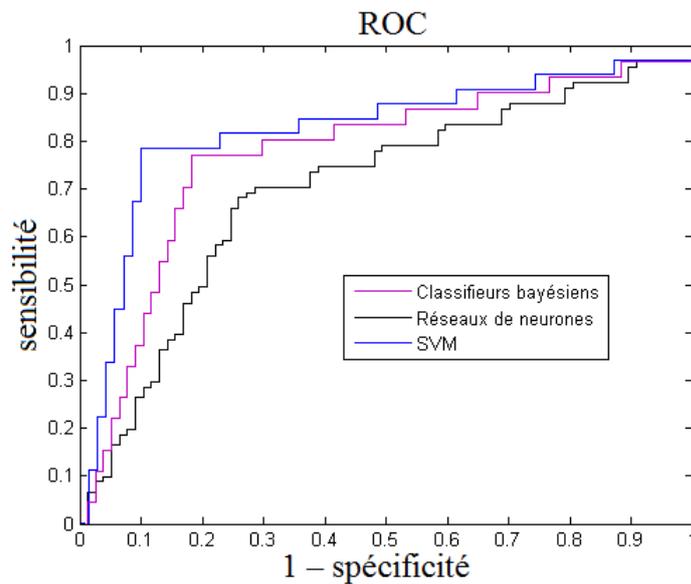


FIGURE 2.25 – Les courbes de ROC des meilleurs résultats obtenus de la validation croisée des trois machines d'apprentissage.

classifieurs bayésiens et les SVM). L'idée principale était de sélectionner un signal d'EA d'un matériau en cours d'utilisation et de l'affecter à une phase (rupture ou non-rupture). Dans la section 2.1, nous avons cité des études réalisées sur des signaux d'EA afin de les affecter à des classes ou types d'endommagements. Ces études montrent que les signaux d'EA qui apparaissent dans la phase de rupture (figure 2.1) sont différents des signaux d'EA des deux premières phases. Finalement, en discriminant ces signaux entre deux grandes familles, « rupture » ou « non-rupture », nous pouvons juger de l'état du matériau.

Dans la section 2.3, nous avons expliqué les principaux fonctionnements des différentes méthodes d'apprentissage que nous avons utilisées pour la prédiction des phases. Les mesures de performance de ces méthodes ont été détaillées dans la sous-section 2.3.6. Dans la section 2.4, nous avons détaillé les différentes étapes de la procédure pour atteindre les meilleures discriminations :

- la sélection des signaux d'EA, étape nécessaire pour la base de données des machines d'apprentissage statistique ;
- l'extraction des paramètres nécessaires pour l'apprentissage en se fondant sur les méthodes de discrimination des mécanismes d'endommagements (section 2.1). La base de données est composée de 7 paramètres d'entrée et 1 paramètre de sortie ;
- la normalisation des données nécessaire à l'apprentissage ;
- l'identification et la suppression des données aberrantes qui faussent l'apprentissage ;
- l'utilisation d'une technique simple pour sélectionner les paramètres qui nuisent aux résultats de l'apprentissage. Parmi les 7 paramètres d'entrée que nous avons utilisés au départ, seuls les 3 trois paramètres (durée du signal, nombre de coups aux pics et amplitude) donnent les meilleurs résultats ;
- la validation croisée. Les résultats obtenus avec cette technique montrent que les SVM donnent les meilleurs résultats parmi les machines d'apprentissage utilisées. La sensibilité moyenne est de 82 %, la spécificité moyenne est de 84 % et la surface sous la courbe (AUC) moyenne est de 0,84 ;
- les tests des performances de la discrimination sur des nouvelles données et nous avons obtenu d'excellents résultats avec une sensibilité de 90 %, une spécificité de 94 % et une surface sous la courbe (AUC) de 0,92.

Les résultats obtenus, par les techniques de validation et de test, montrent des performances significatives pour la discrimination. On notera que ce sont les résultats des validations croisées qui servent de référence dans la littérature (les résultats en test ne constituent qu'un indicateur) [Dreyfus et al., 2002]. Nous pouvons évaluer les résultats obtenus par la validation croisée comme suit : si un signal est sélectionné dans la phase de rupture, la probabilité de bien le classer est proche de 82 % ; s'il est sélectionné dans la phase de non-rupture, la probabilité de bien le classer est proche de 84 %, avec les SVM ». Le travail effectué dans ce chapitre a fait l'objet de plusieurs publications [Darwiche et al., 2011, 2012c,b].

L'utilisation des méthodes d'apprentissage artificiel pour l'estimation de la durée de vie restante nécessite une centaine de tests sur des éprouvettes et cela induit un coût. Pour cette raison, dans le chapitre 3 nous étudierons l'estimation de la durée de vie restante en modélisant la vitesse d'apparition des signaux d'EA.

Chapitre 3

Estimation par émission acoustique de la durée de vie des matériaux sous fluage

3.1 Introduction

L'étude de la durée de vie des matériaux est l'un des sujets essentiels pour garantir un bon fonctionnement des systèmes mécaniques. Notre étude apporte une contribution dans le domaine de la maintenance prédictive, elle consiste à estimer la durée de vie restante des matériaux composites. Les recherches dans ce domaine débutent dans les années 1970 [Nauenberg, 1975]. Un état de l'art est présenté dans la section 3.2. Il est établi que la rupture des matériaux soumis à des contraintes, se produit par l'accumulation de défauts localisés au niveau de la structure du matériau. Ces défauts sont accompagnés par des EA. Les signaux d'EA sont recueillis sur des échantillons soumis à un test de fluage. Le taux d'apparition des signaux d'EA représente la vitesse d'apparition des défauts. Nous exploitons ces deux données pour proposer de nouvelles méthodes d'estimation du temps de la rupture. Ces nouvelles méthodes sont essentiellement basées sur l'établissement d'un modèle mathématique de la caractéristique d'EA et par la suite d'un modèle de la vitesse d'apparition de signaux d'EA qui en découle.

Dans ce chapitre, nous détaillons les différentes étapes nécessaires pour établir la modélisation de la caractéristique d'EA, puis nous expliquons comment déduire la vitesse d'apparition des signaux EA. Enfin nous détaillons les méthodes proposées pour l'estimation de la durée de vie. Le schéma de la figure 3.1 synthétise les différentes étapes que nous allons décrire dans la suite.

Afin d'obtenir un modèle mathématique de la caractéristique d'EA nous débutons notre étude par une analyse de l'évolution du nombre des signaux d'EA en fonction du temps lors du test de chaque échantillon. Des mises en forme nommées « traitements préliminaires » sont nécessaires. Nous détaillons tout particulièrement, la méthode de normalisation qui consiste à faire un changement de variable pour passer à des variables réduites. Cette opération mathématique s'est avérée très fructueuse quant à l'objectif final visé qui est l'estimation de la durée de vie restante des échantillons en test. Ensuite, nous établissons un modèle mathématique sous forme de fonctions analogiques polynomiales qui caractérisent le phénomène d'EA et la vitesse d'apparition des signaux pour chaque échantillon sous test. Dans l'étape de l'estimation de la durée de vie, nous détaillons les différentes méthodes et techniques qui utilisent les modèles mathématiques d'EA des échantillons puis nous exposons les résultats obtenus et la validation de ces résultats par la méthode des validations croisées. La dernière étape représente une innovation par rapport à ce qui a été fait dans le passé : nous avons montré l'existence d'un modèle commun entre tous les échantillons testés spécifique à ce matériau. Ensuite, nous avons utilisé ce modèle pour estimer la durée de vie des échantillons et enfin nous exposons les résultats obtenus qui présentent une erreur relative très faible.

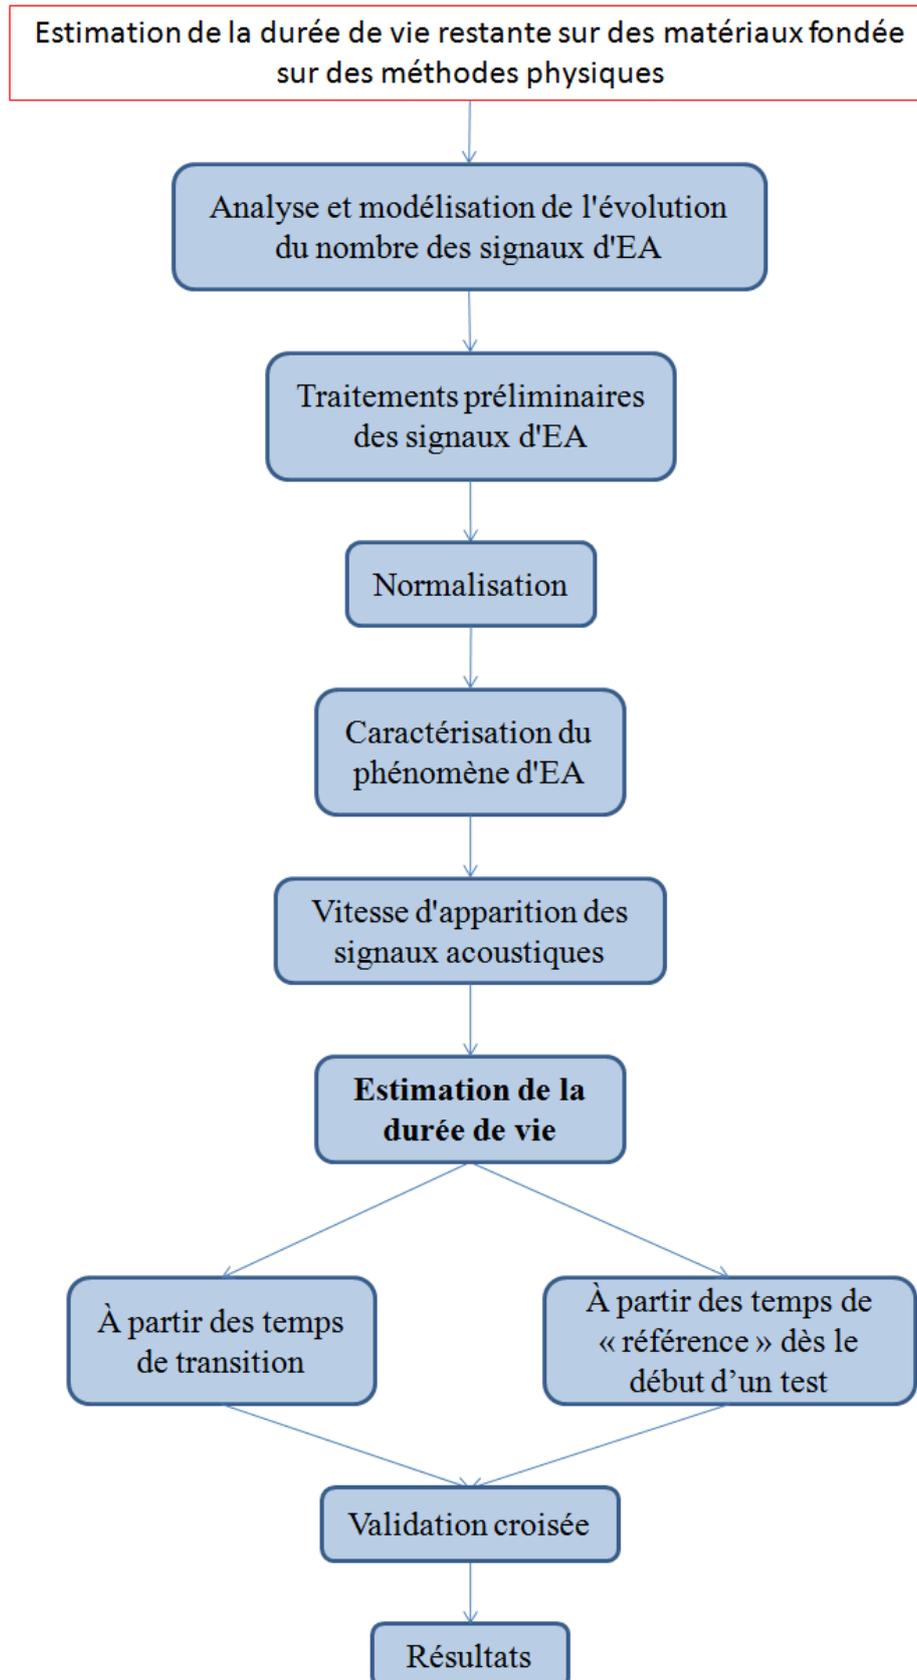


FIGURE 3.1 – Schéma représentatif des différentes étapes de modélisation pour estimer la durée de vie restante de matériaux.

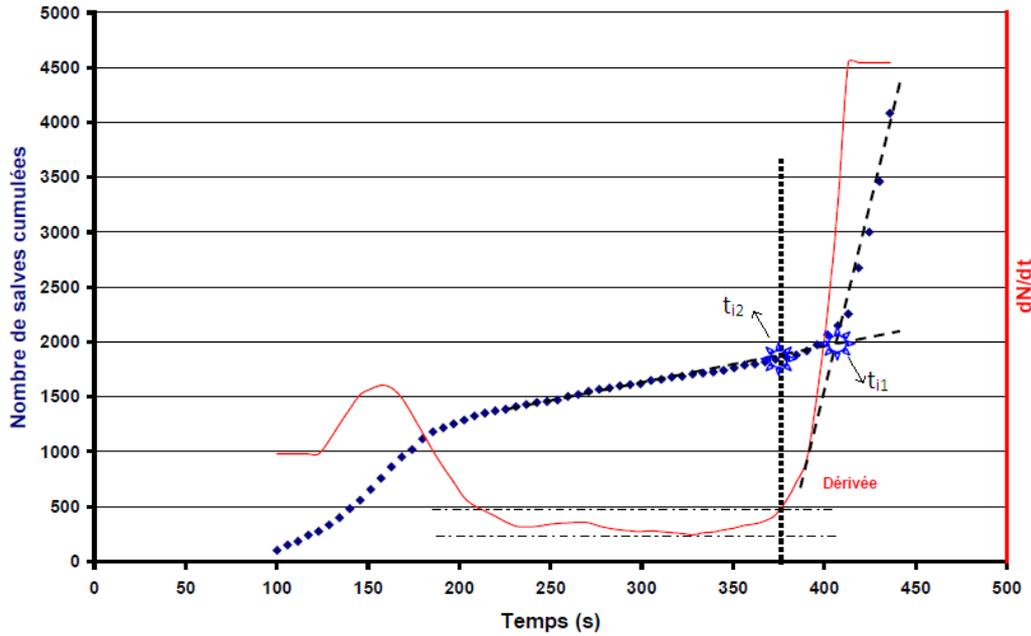


FIGURE 3.2 – Courbe cumulée d’EA et sa dérivée lors d’un essai sous sollicitation statique sur le béton [Thummen, 2004].

3.2 État de l’art de l’estimation de la rupture

Les premières études réalisées dans le domaine de l’estimation de la durée de vie restante sur les matériaux sont situées dans les années 1970 [Nauenberg, 1975]. La rupture de ces matériaux, soumis à des contraintes, se produit par l’accumulation progressive de défauts locaux [Herrmann and Roux, 1990]. L’instant de la rupture est semblable à un point critique [Anifrani et al., 1995]. Dans le voisinage du point critique de rupture, il existe une zone critique [Lamagnère et al., 1996, Sornette and Andersen, 1998], où le dégagement d’énergie peut être caractérisé par une loi de puissance avec des oscillations log-périodiques [Sornette, 1998].

Les essais sous sollicitations statiques des matériaux composites, révèlent une forte dispersion de la durée de vie qui peut s’étaler pour les bétons réfractaires de 400s à plusieurs semaines [Thummen, 2004]. Durant ces essais, on observe un comportement partagé en trois zones temporelles d’activité acoustique (similaire à la figure 1.5, section 1.4, page 11). La première zone correspond à la montée de charge. La deuxième zone est relativement calme, le nombre des signaux est faible. L’évolution de l’EA dans cette zone est faiblement croissante, la courbe cumulée d’EA peut être ajustée par une droite de faible pente positive. Cette phase se termine par une augmentation soudaine de l’activité acoustique qui finit par la rupture du matériau ; les événements acoustiques dans cette phase sont de plus forte amplitude. Pour déterminer la durée de vie restante, [Thummen, 2004] a utilisé le point d’in-

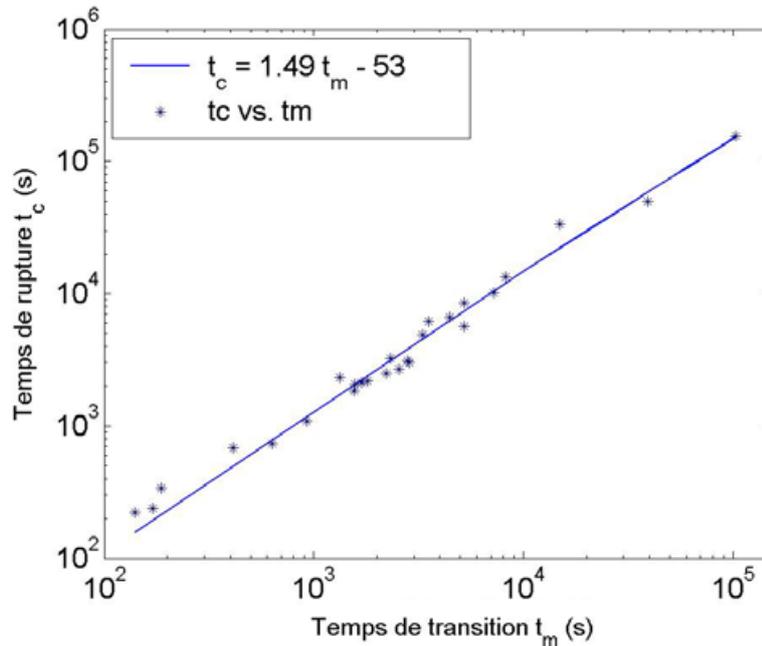


FIGURE 3.3 – Corrélation globale entre le temps de transition t_m et le temps de rupture t_c pour tous les matériaux [Nechad, 2004].

flexion (t_i) qui correspond à celui où l'activité acoustique reprend. Pour déterminer t_i , [Thummen, 2004] a utilisé deux méthodes mathématiques : la première consiste à approcher par des droites la courbe cumulée d'EA dans la zone 2 et la zone 3, le point de transition est l'intersection « t_{i1} » de ces droites (figure 3.2). La deuxième méthode consiste à calculer le taux d'apparition de la courbe cumulée d'EA. Ce taux est quasi constant et faible dans la zone 2. Le début de la zone 3 est déterminé par un changement brusque de pente de la courbe. La courbe dans la zone 2 n'étant pas parfaitement linéaire, alors sa dérivée n'est pas parfaitement constante, donc il faut définir un seuil au delà duquel on considère qu'il y a reprise de l'EA « t_{i2} ». Le temps correspondant au point d'inflexion t_i résultant de la première méthode est plus éloigné que celui de la deuxième. Étant donné que le but est de déterminer le point d'inflexion le plus tôt possible, [Thummen, 2004] a conseillé d'utiliser la deuxième méthode pour déterminer le temps de transition t_i . Néanmoins, les essais sur des éprouvettes à faible durée de vie ne présentent pas de point d'inflexion et ont une évolution rapide de l'EA correspondant à la zone 3 avec une zone 2 inexistante. Une autre difficulté réside dans la faible précision de l'estimation de la durée de vie restante, les pourcentages de durée de vie restante s'étalent de 3 à 19% de la durée déjà écoulée, l'estimation elle-même est très tardive.

Les tests sur des matériaux de type hétérogène, comme les SPC [± 62] (Systèmes Polymères Complexes), SPC [90/35], SMC (Sheet Moulding Compound) et les composites unidirectionnels (UD45 et UD27), révèlent des temps de rupture, relatifs à chaque série d'éprouvettes du même matériau, très différents alors que la

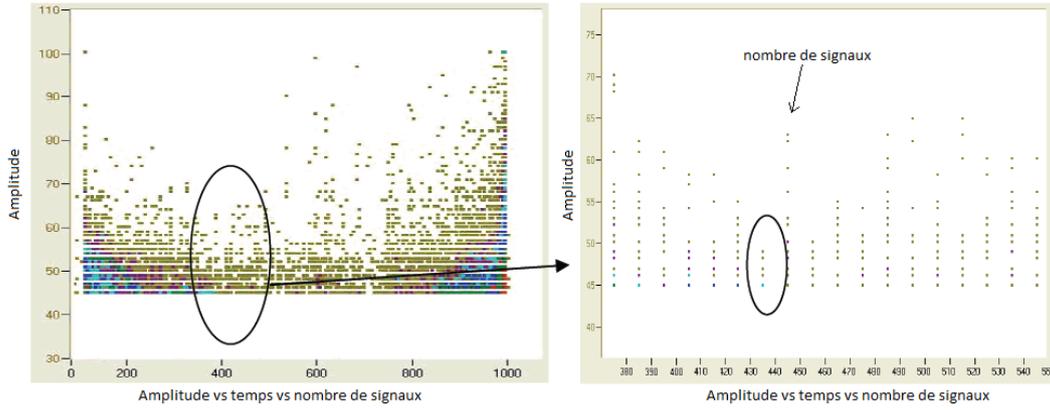


FIGURE 3.4 – Détection des temps d’inflexion t_i par [Berbaoui et al., 2009].

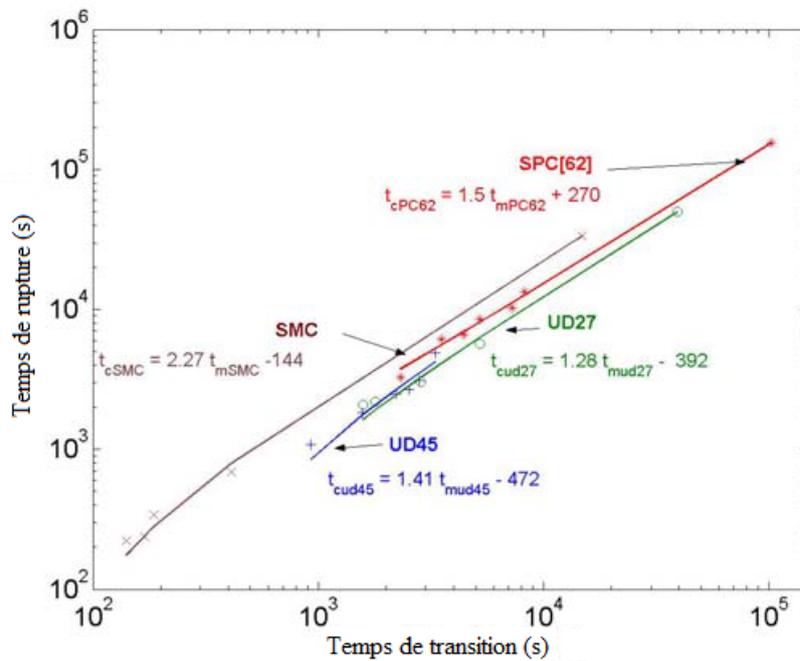


FIGURE 3.5 – Corrélations entre le temps de transition t_m et le temps de rupture t_r , pour les différents types de matériaux pris séparément [Nechad, 2004].

contrainte appliquée reste la même [Nechad, 2004] et le matériau est le même. En outre, l’endommagement qui se produit dans le fluage primaire influe certainement sur son évolution dans le fluage secondaire et tertiaire et par la suite sur le temps de rupture t_r . Le temps de transition entre la phase primaire et la phase secondaire t_m correspond au minimum du taux de déformation (fluage primaire/secondaire). Une corrélation entre t_m et t_r a été proposée (figure 3.3). Finalement, t_m représente environ $2/3$ du t_r .

L’étude de la corrélation entre t_m et t_r pour chaque type de matériau est représentée séparément sur la figure 3.5. La meilleure corrélation est celle obtenue pour les composites SMC caractérisés par un degré d’hétérogénéité et de désordre

important. Le temps t_m pour les SMC représente plus de la moitié du temps t_r , et de même les SPC sont mieux corrélés que les UD45 et les UD27.

De même, l'application de cette technique sur des bétons polymères (étudiés par [Berbaoui et al., 2009]), montre une bonne corrélation entre t_m et t_r . La technique de détection de t_m correspondant au minimum des salves acoustiques est représentée à la figure 3.4. La relation qui traduit cette corrélation s'exprime par :

$$t_r = 1,68 t_m + 29,35.$$

3.3 Analyse et modélisation de l'évolution du nombre de signaux d'EA

La compréhension du comportement des matériaux composites sous charge passe par l'analyse de l'évolution du nombre cumulé des signaux d'EA. Nous présentons deux approches qui visent à répondre à la problématique soulevée. Des étapes de mise en forme des données sont communes aux deux approches. Ces étapes sont groupées dans la partie traitements préliminaires.

La mise en œuvre des méthodes proposées d'estimation de la durée de vie restante sur les matériaux composites nécessite un traitement des données. Nous expliquons dans ce qui suit la technique de normalisation des courbes d'EA relevées dans différents tests, puis nous présentons la technique de reconstruction des courbes cumulées des signaux d'EA. Ensuite, nous proposons un modèle analogique de la courbe d'EA normalisée, et enfin nous exploitons ce modèle pour estimer la durée de vie de chaque échantillon.

3.3.1 Traitements préliminaires des signaux d'EA

Dans notre étude, les données des signaux d'EA sont enregistrées lors des tests de fluage par traction effectués sur plusieurs éprouvettes de fibre de verre unidirectionnelle renforcées avec de la résine époxyde. La synchronisation de l'enregistrement avec l'application de la charge n'est pas automatisée. Donc il y a un décalage entre le lancement de la machine de traction et l'acquisition effectuée par le logiciel de lecture et de sauvegarde des signaux. En raison de cette manière de procéder lors des tests, il faut rectifier l'écart présent au début et à la fin des enregistrements (figure 3.6).

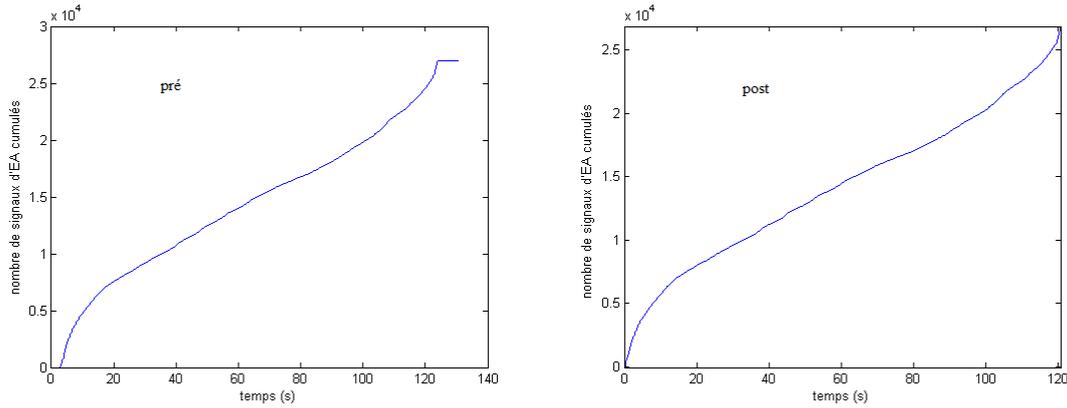


FIGURE 3.6 – Pré et post correction des signaux d’EA.

3.3.2 Normalisation

Nous avons soumis plusieurs éprouvettes au test de fluage par traction. Les temps de rupture constatés sont très différents (134 s, 155 s, 525 s, 845 s, 992 s, 1832 s, 3362 s). A chaque test, des dizaines de milliers de signaux acoustiques sont enregistrés. Nous constatons l’existence des 3 phases d’EA (détaillées dans la section 1.4.1) lors d’un test de fluage par traction.

La réponse en fluage des matériaux composites peut être présentée par la courbe du nombre des signaux cumulés d’EA en fonction du temps. Afin d’approcher par un modèle la réponse en fluage de ce matériau composite, nous avons appliqué une technique de normalisation des données. Normaliser, c’est réduire les grandeurs des axes du temps et du nombre des signaux d’EA de façon que le temps réduit correspondant à la rupture soit équivalent à 1 et le nombre total cumulé des signaux d’EA réduit soit équivalent à 1 au moment de la rupture [Al Shalabi et al., 2006]. Pour réaliser cette normalisation, nous divisons les données de l’axe du temps (axe des abscisses) par le temps correspondant à la rupture et l’axe de nombre des signaux d’EA (axe des ordonnées) par le nombre total des signaux d’EA. Le résultat donne naissance à des nouvelles variables t' (axe des abscisses normalisé) et cs' (axe des ordonnées normalisé) qui appartiennent à l’intervalle $[0; 1]$ (figure 3.7). Cette normalisation a été effectuée par l’application des expressions suivantes :

$$cs' = cs/SN \text{ et } t' = t/t_r.$$

tel que, SN : nombre total des signaux et t_r : temps de rupture.

Le résultat de cette normalisation est représenté sur la figure 3.7. La superposition des différentes courbes normalisées des tests sur des éprouvettes ayant des temps de rupture différents montre, comme illustré dans la figure 3.8, que les réponses en fluage de ces éprouvettes sont très ressemblantes. Nous constatons aussi

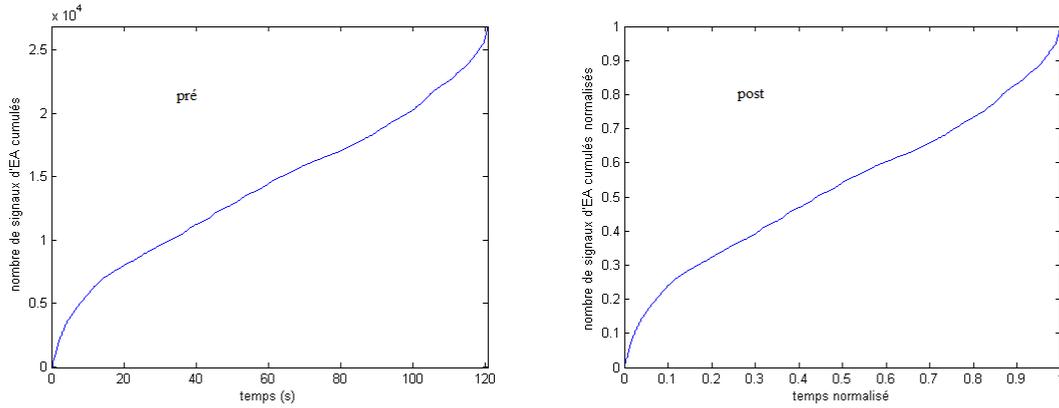


FIGURE 3.7 – Pré et post normalisation.

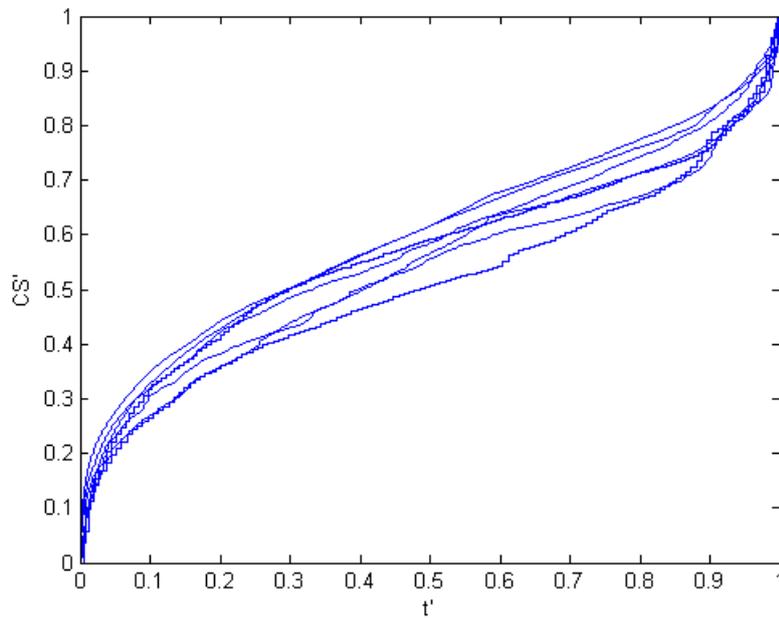


FIGURE 3.8 – Normalisation des 7 courbes.

que les courbes des signaux d'EA ont la même forme ; ces courbes normalisées caractérisent ce type de matériau lors d'un test de fluage. Nous remarquons également que les différentes phases de fluage sont potentiellement proportionnelles, ce qui nous permet d'estimer la durée de vie restante à partir du modèle commun.

3.3.3 Caractérisation du phénomène d'EA

La forme de la caractéristique d'EA est semblable pour toutes les éprouvettes en test, mais ce qui change, c'est la durée du test avant la rupture et le nombre total de signaux cumulés jusqu'au moment de la rupture (conclusion tirée de la

normalisation). Nous avons trouvé que les durées des 3 phases sont corrélées entre elles, donc il est possible d'estimer la durée de vie restante à partir des temps de transition. Il nous reste donc à déterminer de la manière la plus précise possible les temps de transition.

Dans la section 3.2, nous citons plusieurs méthodes dans la littérature pour déterminer les temps de transition. La technique la plus adéquate est celle de [Thummen, 2004], elle est basée sur l'utilisation du taux d'apparition. Notre approche consiste à utiliser la dérivée de la caractéristique d'EA. Il suffit donc de modéliser analytiquement cette caractéristique et de la dériver pour obtenir l'expression du taux d'apparition instantané.

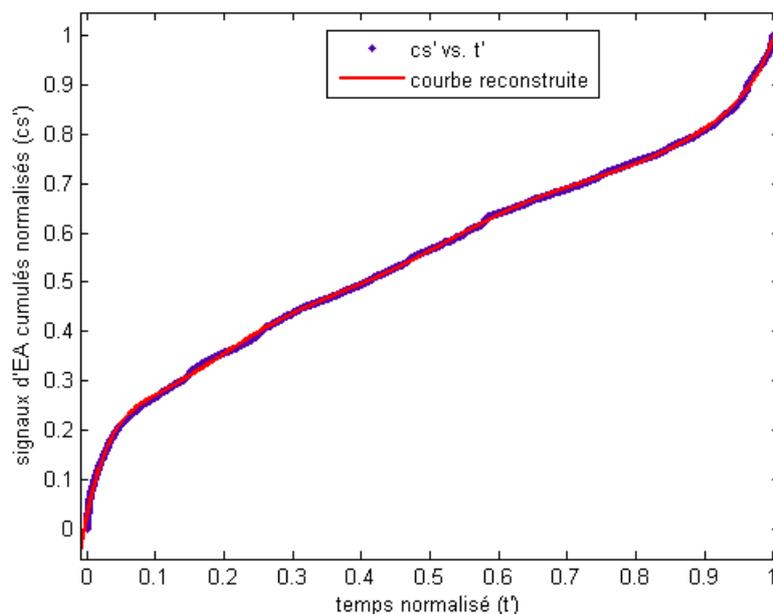


FIGURE 3.9 – Reconstruction du phénomène acoustique.

Réaliser la régression ou l'ajustement d'une fonction discrète (un ensemble de points (x,y)) consiste à déterminer une fonction continue qui en donne une représentation la plus fidèle possible [Petit et al., 2001]. Elle consiste alors à approcher un ensemble de points par une courbe. La qualité de la régression dépend des méthodes et des contraintes utilisées pour choisir et paramétrer cette fonction. Il existe plusieurs méthodes analytiques [Chapra and Canale, 2002] d'ajustement de données : exponentielle, de Fourier, polynomiale, rationnelle... Nous avons choisi la fonction polynomiale qui s'est avérée la plus satisfaisante pour ajuster au mieux nos données.

La fonction polynomiale choisie est de degré 9 (équation 3.1), elle s'est révélée la plus adaptée à modéliser la caractéristique d'EA avec des erreurs relativement faibles (figure 3.9). La figure 3.10 montre les courbes reconstruites pour chaque échantillon.

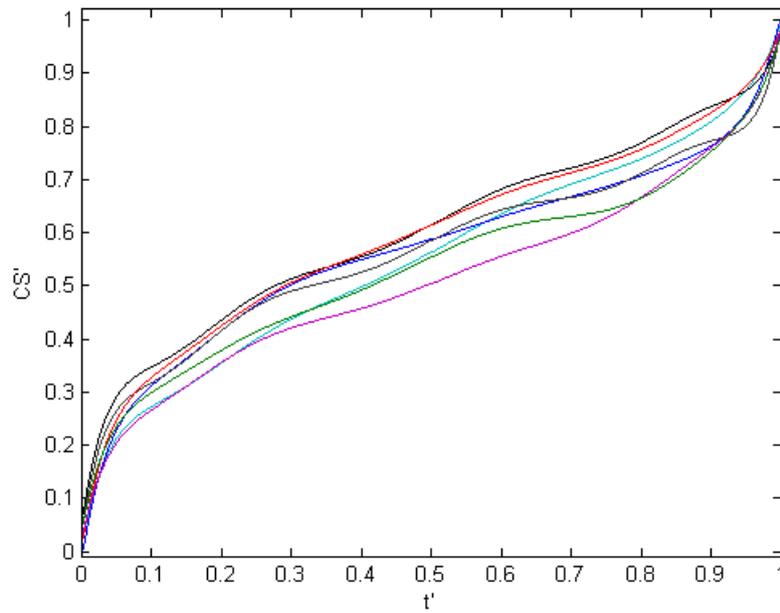


FIGURE 3.10 – Toutes les courbes reconstruites.

L'expression de la fonction polynomiale est de la forme :

$$f(t) = a_0 + a_1 t + a_2 t^2 + a_3 t^3 + a_4 t^4 + a_5 t^5 + a_6 t^6 + a_7 t^7 + a_8 t^8 + a_9 t^9 \quad (3.1)$$

La reconstruction des courbes d'EA par une fonction est un outil puissant et maniable qui nous permettra de situer toute évolution du phénomène d'EA à l'aide de l'analyse de la dérivée. Ces courbes modélisées par ce type de fonction caractérisent l'EA de ce matériau lors du test de fluage (équation 3.1). L'ajustement des données a été réalisé sous Matlab®, l'erreur relative calculée entre la fonction polynomiale de degré 9 et le tableau de données est de 0.0053 %.

Pour détecter les temps de transition, comme déjà mentionné au début de cette section, il faut effectuer la dérivée de la fonction analytique d'EA (équation 3.1) que nous avons déterminée précédemment. Dans la section suivante, nous analysons cette dérivée qui représente la vitesse instantanée d'apparition des signaux d'EA. Elle explique le phénomène physique du comportement des éprouvettes lors du test de fluage.

3.3.4 Vitesse d'apparition des signaux acoustiques

Au début de la première phase d'un test de fluage, la vitesse d'apparition des signaux acoustiques est très importante. Cette vitesse commence par la suite à décroître en fonction du temps. Ensuite, il y a la deuxième phase qui est caractérisée par une vitesse d'apparition quasi constante de ces signaux. Enfin, la troisième

phase s'annonce avec une accélération rapide à nouveau de la vitesse d'apparition des signaux acoustiques. Cette phase se termine par la rupture du matériau. Mathématiquement parlant, la vitesse est calculée par la détermination de la dérivée de l'équation de la courbe [Thummen, 2004], représentée ici par l'équation 3.1 de la caractéristique acoustique.

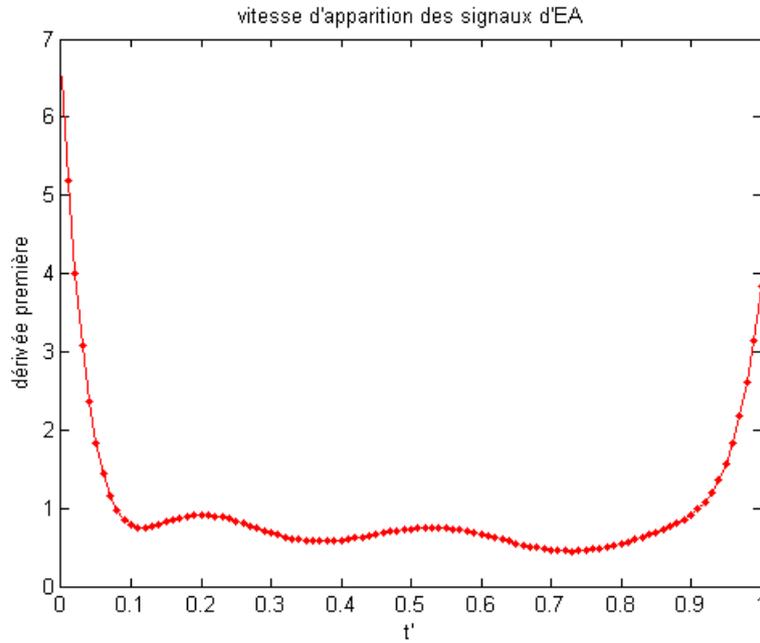


FIGURE 3.11 – La vitesse d'apparition des EA.

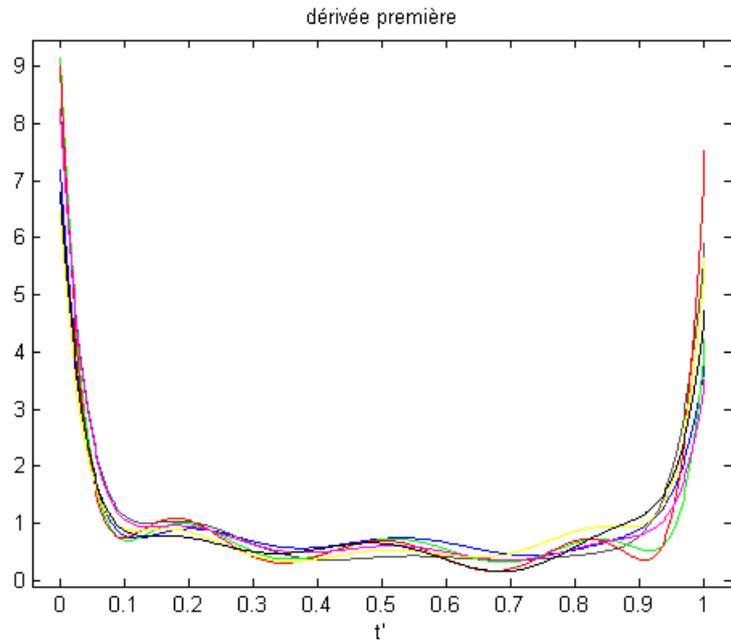


FIGURE 3.12 – La vitesse d'apparition des EA des différents tests effectués.

L'expression de la vitesse d'apparition des signaux acoustiques (équation 3.2) est de la forme :

$$f'(t) = a_1 + 2 a_2 t + 3 a_3 t^2 + 4 a_4 t^3 + 5 a_5 t^4 + 6 a_6 t^5 + 7 a_7 t^6 + 8 a_8 t^7 + 9 a_9 t^8 \quad (3.2)$$

Elle est représentée à la figure 3.11. À la figure 3.12, nous représentons respectivement toutes les dérivées de toutes les courbes reconstruites de la figure 3.10.

3.4 Estimation de la durée de vie

Dans cette section, nous expliquons comment exploiter le modèle établi pour estimer la durée de vie restante des matériaux composites. Nous allons présenter deux méthodes complémentaires pour atteindre cet objectif avec des résultats qui se sont avérés d'une très bonne précision. La première consiste à estimer le temps restant à partir des deux temps de transition. La deuxième est une nouvelle méthode qui estime le temps restant dès le début de la phase primaire en se basant sur la variation de la vitesse d'apparition des signaux d'EA.

Les deux méthodes utilisées sont fondées sur deux approches différentes. La première consiste à trouver la moyenne des temps de transition ou de référence et de la corrélérer avec le temps de rupture. En revanche, la deuxième méthode consiste à calculer la courbe moyenne des différents tests et ensuite corrélérer ces temps de transition ou de référence avec le temps de rupture. Un schéma explicatif est donné à la figure 3.13.

3.4.1 Estimation à partir du temps de transition

Le comportement des matériaux composites sous test de fluage est composé de trois phases. Entre ces phases on distingue deux temps de transition. La détection des temps de transition ainsi que leur corrélation avec le temps de rupture ont fait l'objet de plusieurs travaux de recherche comme nous l'avons présenté dans la partie 3.2 au début de ce chapitre [Anastassopoulos and Philippidis, 1995, Nechad, 2004].

Dans cette section, nous détaillons une nouvelle méthode de détection des temps de transition en nous fondant sur les outils établis dans la partie 3.2. Deux techniques peuvent être utilisées pour détecter les temps de transition et estimer le temps de rupture ; la première s'effectue à travers une corrélation entre le temps de transition moyen des temps de transition trouvés dans toutes les courbes et le temps de rupture, et la deuxième est réalisée en corrélant le temps de transition obtenu à partir de la courbe moyenne de toutes les courbes et le temps de rupture.

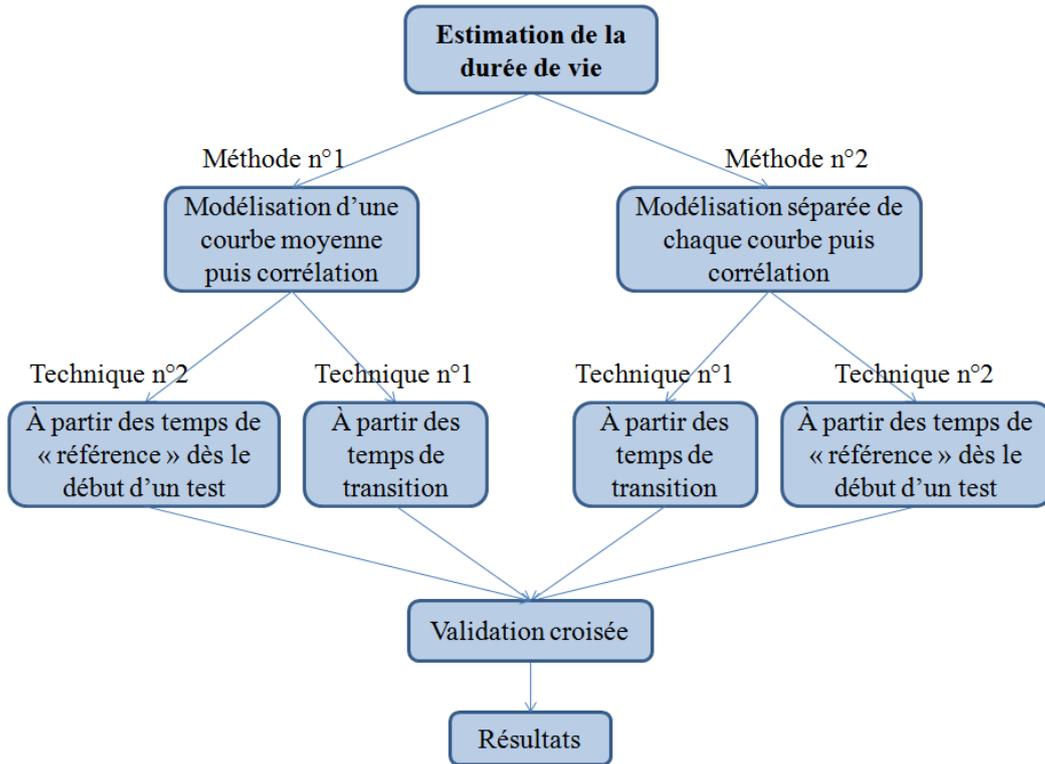


FIGURE 3.13 – Schéma représentatif des méthodes et techniques utilisées pour l'estimation de la rupture.

3.4.1.1 Détection des temps de transition

Le temps de transition est le temps de passage d'une phase à une autre. Nous définissons le temps de transition t_{m12} (entre les phases 1 et 2) par le moment où la vitesse d'apparition des signaux acoustiques atteint le premier minimum après sa décroissance et avant de devenir quasi constante. Le temps de transition t_{m23} (entre les phases 2 et 3) est défini par le moment où la vitesse d'apparition des signaux acoustiques commence à nouveau à augmenter fortement.

La détection du temps de transition t_{m23} est réalisé de la même façon que la méthode utilisée dans le travail de [Thummen, 2004]. La courbe dans la zone 2 n'étant pas parfaitement linéaire, la dérivée n'est pas constante dans cette zone, il faut donc définir un seuil au delà duquel on considère qu'il y a reprise de l'EA. Ce seuil est une référence définie par $y = 2 * moy$, c.à.d. qu'il représente le double de la valeur moyenne de la dérivée dans la 2^{ème} phase. Le point d'intersection avec ce seuil définit le temps de transition t_{m23} .

Le temps de transition t_{m12} est caractérisé par le passage de la vitesse d'apparition des signaux d'EA par le premier minimum. Les courbes de la dérivée de la figure 3.12 possèdent plusieurs minimums locaux dans la deuxième phase (figure 3.14). Ces minimums correspondent aux redondances dues au degré élevé de la fonction poly-

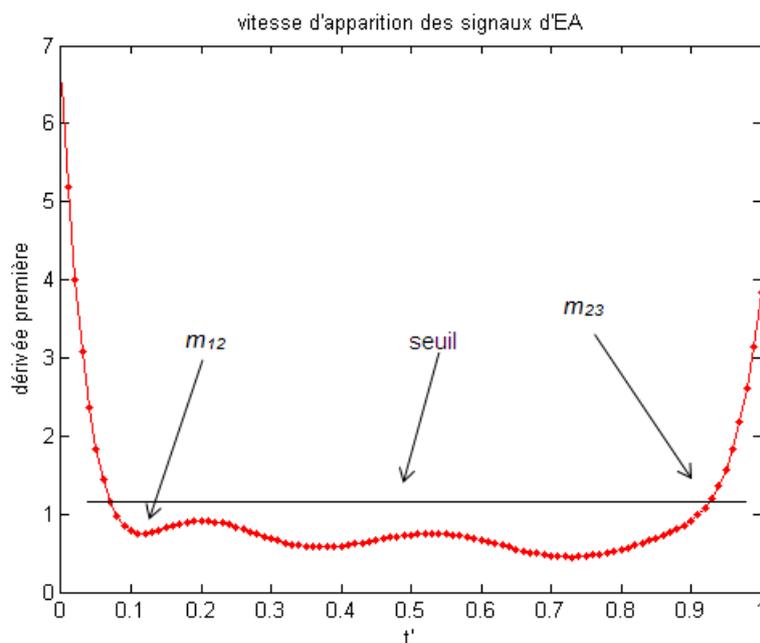


FIGURE 3.14 – Détection des temps de transition.

nomiale de la courbe reconstruite. Pour détecter le temps de transition t_{m12} , nous avons besoin de tous les signaux qui apparaissent jusqu'au début de la deuxième phase. Dans la suite, nous présentons les deux techniques qui peuvent être utilisées pour estimer la durée de vie restante sur les matériaux.

3.4.1.2 Estimation à partir des moyennes des temps de transition

Après la détection des temps de transition de toutes les courbes, nous établissons des corrélations constantes entre les deux temps de transition, t_{m12} et t_{m23} , et le temps de rupture t_r . Dans un premier temps nous calculons les rapports :

$$m_{12} = \frac{t_{m12}}{t_r} \quad \text{et} \quad m_{23} = \frac{t_{m23}}{t_r}. \quad (3.3)$$

Ensuite, les moyennes de ces rapports ($\overline{m_{12}}$ et $\overline{m_{23}}$) calculées sur tous les tests seront utilisées comme coefficients de corrélation pour estimer le temps restant sur de nouvelles éprouvettes.

Pour tester la validité de cette approche, nous avons appliqué la méthode de la validation croisée (cf. section 2.4.6 dans le chapitre 2) avec $K = 7$. Nous avons calculé tout d'abord le coefficient sur 6 éprouvettes. Le coefficient choisi représente la moyenne des 6 rapports relevés sur les 6 courbes. Ce coefficient est ensuite utilisé pour calculer le temps de rupture estimé de la 7^{ème} éprouvette. L'équation générale de l'estimation du temps de rupture calculée respectivement à partir du t_{m12} ou t_{m23} est :

TABLE 3.1 – Résultats de la validation croisée (t_{m12}).

éprouvettes utilisées	\overline{m}_{12}	t_{r*}	t_{re*}	er
*, 2, 3, 4, 5, 6, 7	0,12	525	480	8,5 %
1, *, 3, 4, 5, 6, 7	0,12	155	168	8,3 %
1, 2, *, 4, 5, 6, 7	0,125	3362	3060	9 %
1, 2, 3, *, 5, 6, 7	0,123	1832	1790	2 %
1, 2, 3, 4, *, 6, 7	0,122	845	900	6,5 %
1, 2, 3, 4, 5, *, 7	0,123	134	131	2,2 %
1, 2, 3, 4, 5, 6, *	0,12	992	1132	14 %

TABLE 3.2 – Description statistique des résultats (t_{m12}).

	minimum	maximum	moyenne	écart type
\overline{m}_{12}	0,12	0,125	0,1218	$2,3 * 10^{-5}$
er	2 %	15 %	8,58 %	4,65

$$t_{re} = \frac{t_{m12}}{\overline{m}_{12}} \quad (3.4)$$

ou

$$t_{re} = \frac{t_{m23}}{\overline{m}_{23}} \quad (3.5)$$

L'erreur de l'estimation est calculée à l'aide de l'expression suivante :

$$er = \left| \frac{(t_r - t_{re})}{t_r} \right|. \quad (3.6)$$

Dans le tableau 3.1, nous montrons les résultats de l'estimation du temps de rupture par la validation croisée. Dans ce tableau, \overline{m}_{12} , qui représente le coefficient de corrélation, est calculé en effectuant la moyenne des rapports m_{12} des éprouvettes non mentionnées par une étoile. On remarque que \overline{m}_{12} varie entre 0.12 et 0.125 avec une erreur qui oscille entre 2 % et 14 %.

Dans le tableau 3.2, la moyenne des moyennes \overline{m}_{12} des 7 validations croisées, représentée par $\overline{\overline{m}_{12}}$, a une valeur de 0,1218. L'erreur moyenne atteint une valeur de 8,58 %. Cette erreur aurait pu être plus faible (moyenne = 6,1 % \pm 2,9) si la prédiction sur la dernière éprouvette avait été plus précise. Une augmentation significative du nombre des éprouvettes à l'avenir pourrait amener à minimiser cette erreur.

Dans le tableau 3.3, nous montrons les résultats de l'estimation du temps de rupture par la validation croisée. \overline{m}_{23} représente la moyenne des rapports m_{23} d'éprouvettes non mentionnées par une étoile. On remarque que \overline{m}_{23} varie entre 92,1 % et 94 % avec une erreur qui varie entre 0,95 % et 5,9 %.

TABLE 3.3 – Résultats de la validation croisée (t_{m23}).

éprouvettes utilisées	\overline{m}_{23}	t_{r*}	t_{re*}	er
*, 2, 3, 4, 5, 6, 7	0,923	525	530	0,95 %
1, *, 3, 4, 5, 6, 7	0,93	155	151	2,5 %
1, 2, *, 4, 5, 6, 7	0,935	3362	3210	4,5 %
1, 2, 3, *, 5, 6, 7	0,921	1832	1890	3,16 %
1, 2, 3, 4, *, 6, 7	0,939	845	873	3,3 %
1, 2, 3, 4, 5, *, 7	0,94	134	142	5,9 %
1, 2, 3, 4, 5, 6, *	0,927	992	981	1,15 %

TABLE 3.4 – Description statistique des résultats (t_{m23}).

	minimum	maximum	moyenne	écart type
\overline{m}_{23}	0,921	0,94	0,93	0,0075
er	0,95 %	5,9 %	3,06 %	1,76

La description statistique (tableau 3.4) montre que la moyenne \overline{m}_{23} des 7 validations croisées a une valeur de 0,93. L'erreur moyenne atteint une valeur de 8,58 %. Une augmentation significative du nombre des éprouvettes à l'avenir pourrait amener à minimiser cette erreur.

3.4.1.3 Estimation à partir des temps de transition de la courbe moyenne

Le principe de cette technique consiste à construire et modéliser une courbe moyenne résultante de toutes les courbes normalisées obtenues par les tests. Puis nous détectons t_{m12} et t_{m23} , ensuite nous calculons leurs relations avec t_r . La figure 3.15 montre la courbe moyenne que nous avons obtenue à partir des courbes de tous les tests que nous avons effectués.

À partir de l'expression analytique de cette courbe modèle, nous établissons celle de la dérivée (figure 3.14), et nous détectons t_{m12} et t_{m23} (voir sous-section 3.4.1.1). Ces temps sans unités seront utilisés comme coefficients de corrélation pour estimer le temps restant sur de nouvelles éprouvettes.

Pour valider cette technique, nous avons appliqué aussi la méthode de validation croisée ($K = 7$). Nous avons construit la courbe moyenne tout d'abord à partir des 6 courbes de tests. Puis, nous avons trouvé les coefficients de corrélation. Ensuite ces coefficients sont utilisés pour estimer le temps de rupture de la 7^{ème} éprouvette. L'estimation du temps de rupture est calculée à partir de l'équation 3.4 et l'erreur de l'estimation est déduite à l'aide de l'équation 3.6.

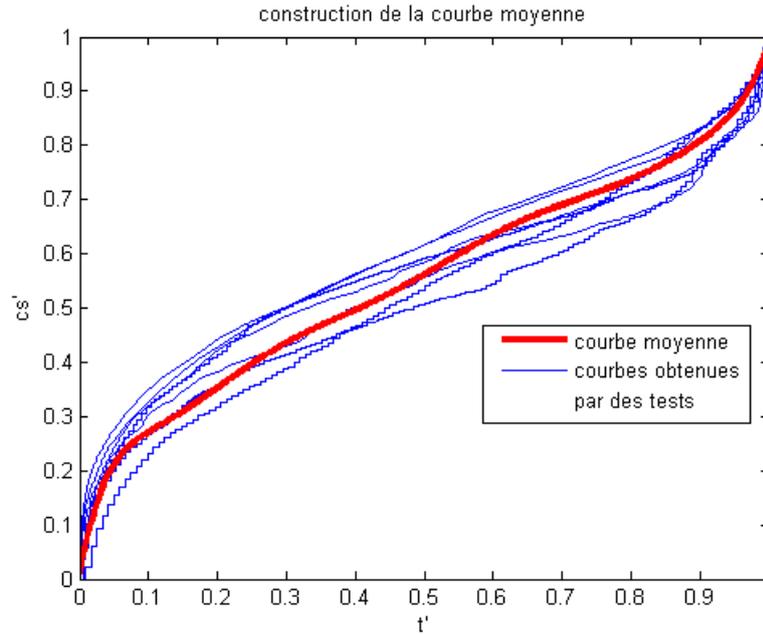


FIGURE 3.15 – Reconstruction de la courbe moyenne à partir des courbes des tests effectués.

Dans le tableau 3.5, nous montrons les résultats de l'estimation du temps de rupture par la validation croisée. Dans ce tableau, m_{12} représente le coefficient de corrélation trouvé en utilisant les éprouvettes non mentionnées par une étoile. On remarque que m_{12} varie de 0.117 à 0.125 avec une erreur qui oscille entre 3,7 % et 8,87 %. Dans le tableau 3.6, la description statistique montre que la moyenne du coefficient de corrélation $\overline{m_{12}}$, des 7 validations croisées, a une valeur de 0,1209. L'erreur moyenne atteint une valeur de 5,43 %. Dans le tableau 3.7, nous présentons les résultats de l'estimation du temps de rupture par la validation croisée. Dans ce tableau, m_{23} représente le coefficient de corrélation trouvé en utilisant les éprouvettes non mentionnées par une étoile. On remarque que m_{23} varie entre 0.921 et 0.94 avec une erreur qui varie entre 0,95 % et 5,9 %.

La description statistique (tableau 3.8) montre que la moyenne du coefficient de corrélation $\overline{m_{12}}$, des 7 validations croisées, a une valeur de 0,93. L'erreur moyenne atteint une valeur de 8,58 %. Une augmentation significative du nombre des éprouvettes à l'avenir pourrait amener à minimiser cette erreur.

Dans le cadre de l'estimation de la durée de vie restante sur les matériaux composites, la première méthode que nous avons proposée est d'estimer le temps de

TABLE 3.5 – Résultats de la validation croisée (t_{m12}).

éprouvettes utilisées	m_{12}	t_{r*}	t_{re*}	er
*, 2, 3, 4, 5, 6, 7	0,119	525	502	4,35 %
1, *, 3, 4, 5, 6, 7	0,12	155	148	4,51 %
1, 2, *, 4, 5, 6, 7	0,123	3362	3123	7,1 %
1, 2, 3, *, 5, 6, 7	0,125	1832	1753	4,31 %
1, 2, 3, 4, *, 6, 7	0,12	845	889	5,2 %
1, 2, 3, 4, 5, *, 7	0,122	134	139	3,7 %
1, 2, 3, 4, 5, 6, *	0,117	992	1080	8,87 %

TABLE 3.6 – Description statistique des résultats (t_{m12}).

	minimum	maximum	moyenne	écart type
$\overline{m_{12}}$	0,117	0,125	0,1209	$2,7 * 10^{-3}$
er	3,7 %	8,87 %	5,43 %	1,87

TABLE 3.7 – Résultats de la validation croisée (t_{m23}).

éprouvettes utilisées	$\overline{m_{23}}$	t_{r*}	t_{re*}	er
*, 2, 3, 4, 5, 6, 7	0,933	525	540	2,85 %
1, *, 3, 4, 5, 6, 7	0,941	155	147	5,16 %
1, 2, *, 4, 5, 6, 7	0,932	3362	3153	6,2 %
1, 2, 3, *, 5, 6, 7	0,931	1832	1989	3,16 %
1, 2, 3, 4, *, 6, 7	0,941	845	873	8,57 %
1, 2, 3, 4, 5, *, 7	0,943	134	149	11,19 %
1, 2, 3, 4, 5, 6, *	0,926	992	969	2,31 %

	minimum	maximum	moyenne	écart type
$\overline{m_{23}}$	0,926	0,943	0,935	$6,4 * 10^{-3}$
er	2,31 %	11,19 %	5,63 %	3,29

TABLE 3.8 – Description statistique des résultats (t_{m23}).

rupture à partir des deux temps de transition d'un test de fluage. Deux techniques ont été utilisées pour mettre en œuvre cette méthode, la première est basée sur la détermination de la moyenne des temps de transitions des différents tests pour l'utiliser ensuite afin d'estimer le temps de rupture. La deuxième technique est basée sur la reconstruction d'une courbe modèle (moyenne des courbes des différents tests), puis nous déterminons les deux temps de transition afin de les utiliser ensuite pour estimer le temps de rupture d'une éprouvette quelconque.

Dans cette section, nous avons détaillé les différentes étapes de cette méthode et les deux techniques que nous avons utilisées. En déterminant le temps de rupture à partir de t_{m12} , nous avons obtenu avec la première technique une erreur moyenne de 8,58 % et un écart-type de 4,65 (tableau 3.2). Avec la deuxième technique nous avons obtenu une erreur moyenne de 5,43 % avec un écart-type de 1,87 (tableau 3.6). Nous remarquons alors que les résultats de l'estimation du temps de rupture à partir de t_{m12} de la deuxième technique sont meilleurs que ceux de la première technique.

L'erreur moyenne obtenue en déterminant le temps de rupture à partir de t_{m23} au moyen de la première technique est de 3,06 % avec un écart-type de 1,76. Avec la deuxième technique nous avons obtenu une erreur moyenne de 5,63 % et un écart-type de 3,29. Les résultats de l'estimation du temps de rupture à partir de t_{m23} obtenus par la première technique sont meilleurs que ceux de la deuxième technique.

3.4.2 Estimation en étudiant la vitesse d'apparition des signaux d'EA

Dans cette section, nous proposons une nouvelle méthode d'estimation de la durée de vie basée sur la vitesse d'apparition des signaux d'EA dans la première phase. Cette méthode comporte plusieurs étapes. Nous étudions au début la diminution de la vitesse d'apparition des signaux d'EA, puis nous identifions des moments de référence (ou temps de référence) communs pour tous les tests et semblables à ceux que nous avons appelés temps de transition. Ensuite, nous corrélons ces temps de référence avec le temps de rupture pour en sortir des lois d'estimation de la durée de vie restante pour la rupture. Enfin, nous validons ces lois par des validations croisées.

Dans la section 3.3.4, nous avons étudié et caractérisé la vitesse d'apparition des signaux d'EA. Cette vitesse est liée au phénomène d'EA qui présente 3 phases. Nous avons remarqué qu'au début de la première phase la vitesse d'apparition d'EA est grande, puis elle commence à diminuer et passe par un minimum, ensuite elle devient constante dans la deuxième phase et vers la fin du test elle accélère à nouveau au début de la troisième phase et jusqu'à la rupture de l'éprouvette.

TABLE 3.9 – Temps de référence à 50% de la diminution de la dérivée.

éprouvette	1	2	3	4	5	6	7	$\overline{m}_{ref\ 50\%}$
$m_{ref\ 50\%}$	0,0269	0,0284	0,0246	0,0245	0,0281	0,0269	0,028	0,0268

Dans cette méthode, nous cherchons à trouver des temps de référence pour estimer la durée de vie restante. La normalisation des caractéristiques a révélé un modèle et un gabarit commun, cela rend possible une estimation du temps final de rupture à partir de n'importe quel moment. Ceci est le point fort de cette étude. Dans cette section, nous recherchons les points qui permettent la meilleure précision de prédiction. Nous allons prouver l'existence d'une relation entre le temps où la vitesse diminue d'un certain pourcentage de sa valeur initiale (temps de référence) et le temps de rupture.

Nous allons utiliser dans les sections suivantes, les deux d'estimations décrites précédemment (partie 3.4.1). Ces deux techniques sont utilisées pour détecter les temps de référence et pour estimer le temps de rupture. La première s'effectue à travers une corrélation entre la moyenne des temps de référence de toutes les courbes et le temps de rupture. La deuxième est réalisée en corrélant le temps de référence à partir de la courbe moyenne de toutes les courbes et le temps de rupture.

3.4.2.1 Estimation à partir des moyennes des temps de référence

Les essais ont été réalisés en calculant le temps qui correspond à la diminution de la vitesse d'apparition des signaux d'EA de 50% dans la première phase (temps de référence $t_{ref\ 50\%}$). Les figures 3.16 et 3.17 présentent la technique utilisée. Elles nous montrent que les rapports $m_{ref\ 50\%}$ (équation 3.7) sont proportionnels et ont une relation directe avec le temps de rupture. Le tableau 3.9 montre les $m_{ref\ 50\%}$ calculés sur les données normalisées des 7 essais ainsi que leur moyenne $\overline{m}_{ref\ 50\%}$.

$$m_{ref\ 50\%} = \frac{t_{ref\ 50\%}}{t_r}. \quad (3.7)$$

Le temps de rupture estimé sur de nouvelles éprouvettes sera calculé suivant l'équation suivante :

$$t_{re} = \frac{t_{ref\ 50\%}}{\overline{m}_{ref\ 50\%}}. \quad (3.8)$$

Dans le tableau 3.10 , nous montrons les résultats de l'estimation du temps de rupture par la validation croisée. $\overline{m}_{ref\ 50\%}$ représente la moyenne des coefficients de corrélation $m_{ref\ 50\%}$ des éprouvettes non mentionnées par une étoile. On remarque

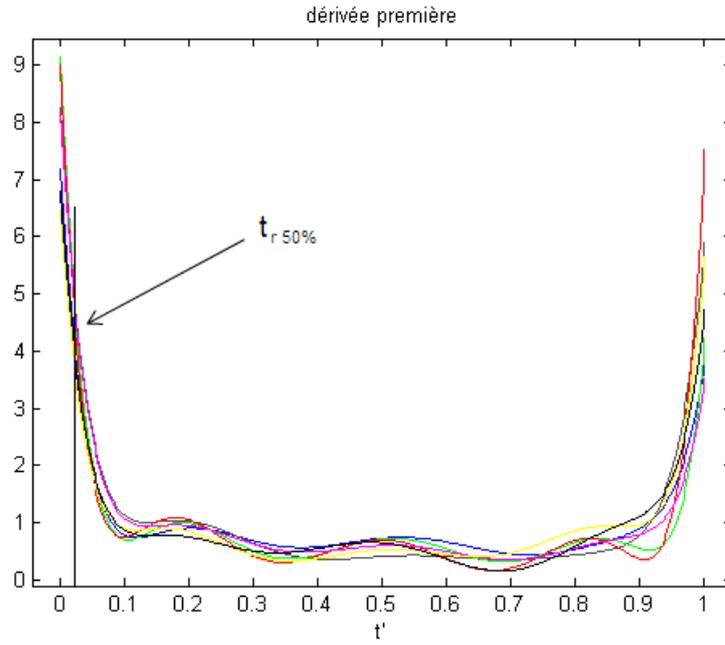


FIGURE 3.16 – Estimation du t_r dès le début du test.

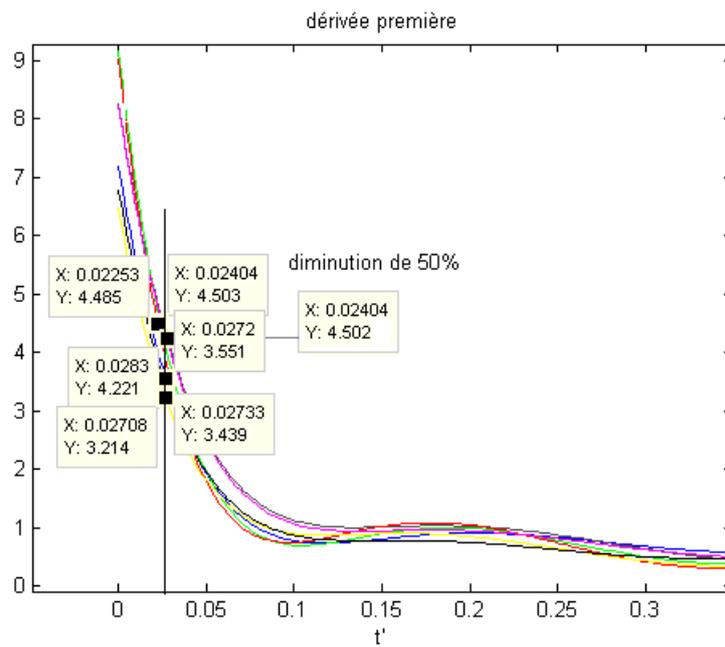


FIGURE 3.17 – Temps de référence $t_{ref\ 50\%}$: diminution de la dérivée de 50%.

TABLE 3.10 – Résultats de la validation croisée ($t_{ref\ 50\%}$).

éprouvette utilisée (*)	$m_{ref\ 50\%}$	$m_{ref*50\%}$	t_{r*}	t_{re*}	er
*, 2, 3, 4, 5, 6, 7	0,0267	0,0269	534	530	0,75 %
1, *, 3, 4, 5, 6, 7	0,0265	0,0284	166	168	7,17 %
1, 2, *, 4, 5, 6, 7	0,0271	0,0246	3362	3051	9,23 %
1, 2, 3, *, 5, 6, 7	0,0271	0,0245	1832	1656	9,59 %
1, 2, 3, 4, *, 6, 7	0,0266	0,0281	845	892	5,64 %
1, 2, 3, 4, 5, *, 7	0,0267	0,0269	134	135	0,75 %
1, 2, 3, 4, 5, 6, *	0,0266	0,028	992	1044	5,26 %

TABLE 3.11 – Description statistique des résultats ($t_{ref\ 50\%}$).

	minimum	maximum	moyenne	écart type
$\bar{m}_{ref\ 50\%}$	0,0265	0,0271	0,0268	$2,4398.10^{-4}$
er	0,75 %	9,59 %	5,48 %	3,62

que $\bar{m}_{ref\ 50\%}$ varie entre 2,65 % et 2,71 % avec une erreur qui varie entre 0,75 % et 9,59 %.

Dans le tableau 3.11, la description statistique montre que la moyenne du coefficient de corrélation $\bar{m}_{ref\ 50\%}$, des 7 validations croisées, a une valeur de 0.0548. L'erreur moyenne atteint une valeur de 8,58 %.

De la même façon que pour la diminution de la dérivée de 50%, nous avons recherché les temps qui correspondent à la diminution de la dérivée de 10%, 20%, 30%, 40%, 60%, 70% et 80% de tous les tests. Nous avons ensuite établi les corrélations entre les temps de référence $t_{ref\ 10\%}$, $t_{ref\ 20\%}$, $t_{ref\ 30\%}$, $t_{ref\ 40\%}$, $t_{ref\ 60\%}$, $t_{ref\ 70\%}$ et $t_{ref\ 80\%}$ respectivement avec le temps de rupture. Les résultats des moyennes $\bar{m}_{ref\ X\%}$

TABLE 3.12 – Moyennes des t_{ref} de la validation croisée.

Ép	$\bar{m}_{ref\ 10\%}$	$\bar{m}_{ref\ 20\%}$	$\bar{m}_{ref\ 30\%}$	$\bar{m}_{ref\ 40\%}$	$\bar{m}_{ref\ 50\%}$	$\bar{m}_{ref\ 60\%}$	$\bar{m}_{ref\ 70\%}$	$\bar{m}_{ref\ 80\%}$
1	0,0042	0,0088	0,0139	0,0197	0,0267	0,0349	0,0459	0,0629
2	0,0042	0,0087	0,0137	0,0194	0,0265	0,0343	0,0451	0,0614
3	0,0043	0,0089	0,0142	0,0201	0,0271	0,0357	0,047	0,0646
4	0,0043	0,009	0,0143	0,0202	0,0271	0,0359	0,0473	0,0649
5	0,0042	0,0087	0,0137	0,0195	0,0266	0,0344	0,0452	0,0617
6	0,0042	0,0088	0,0139	0,0197	0,0267	0,0348	0,0457	0,0622
7	0,0042	0,0087	0,0138	0,0196	0,0266	0,0346	0,0455	0,062

TABLE 3.13 – Description statistique des résultats des moyennes des t_{ref} .

	minimum	maximum	moyenne	écart type
$m_{t_{ref} 10\%}$	0,0042	0,0043	0,0042	$5 * 10^{-5}$
$m_{t_{ref} 20\%}$	0,0087	0,009	0,0088	$12 * 10^{-5}$
$m_{t_{ref} 30\%}$	0,0137	0,0143	0,0139	$24 * 10^{-5}$
$m_{t_{ref} 40\%}$	0,0194	0,0202	0,0197	$30 * 10^{-5}$
$m_{t_{ref} 50\%}$	0,0265	0,0271	0,0268	$24 * 10^{-5}$
$m_{t_{ref} 60\%}$	0,0343	0,0359	0,0349	$62 * 10^{-5}$
$m_{t_{ref} 70\%}$	0,0451	0,0473	0,046	$86 * 10^{-5}$
$m_{t_{ref} 80\%}$	0,0614	0,0649	0,0628	$140 * 10^{-5}$

TABLE 3.14 – Erreurs obtenues par la validation croisée.

Ép	$er_{ref} 10\%$	$er_{ref} 20\%$	$er_{ref} 30\%$	$er_{ref} 40\%$	$er_{ref} 50\%$	$er_{ref} 60\%$	$er_{ref} 70\%$	$er_{ref} 80\%$
1	1,4 %	1,8 %	1,9 %	1,5 %	0,75 %	1,1 %	0,3 %	1,1 %
2	5,1 %	5,4 %	5,7 %	6,4 %	7,17 %	7,8 %	8,4 %	9,8 %
3	7,2 %	8,3 %	8,7 %	9,2 %	9,23 %	10,51 %	11,3 %	12,8 %
4	7,4 %	7,9 %	8,9 %	9,1 %	9,59 %	10,4 %	11,9 %	12,8 %
5	3,4 %	3,5 %	4,8 %	5,1 %	5,64 %	6,8 %	7,4 %	8,5 %
6	0,6 %	0,69 %	0,7 %	0,68 %	0,75 %	1,3 %	2,8 %	6,7 %
7	5,4 %	5,6 %	5,5 %	5,8 %	5,26 %	6,6 %	7,5 %	8,9 %

TABLE 3.15 – Description statistique des résultats des erreurs obtenues.

	minimum	maximum	moyenne	écart type
$er_{ref} 10\%$	0,6 %	7,4 %	4,35 %	2,47
$er_{ref} 20\%$	0,69 %	8,3 %	4,74 %	2,89
$er_{ref} 30\%$	0,7 %	8,9 %	5,2 %	3,1
$er_{ref} 40\%$	0,68 %	9,2 %	5,39 %	3,33
$er_{ref} 50\%$	0,75 %	9,59 %	5,48 %	3,62
$er_{ref} 60\%$	1,1 %	10,51 %	6,35 %	3,85
$er_{ref} 70\%$	0,3 %	11,9 %	7,08 %	4,23
$er_{ref} 80\%$	1,1 %	12,8 %	8,65 %	4,01

des coefficients de corrélation $t_{ref X\%}/t_r$ obtenus par la validation croisée sont donnés dans le tableau 3.12, et les erreurs obtenues sont mentionnées dans le tableau 3.14.

TABLE 3.16 – Erreurs obtenues par la validation croisée.

Ép	$er_{ref\ 10\%}$	$er_{ref\ 20\%}$	$er_{ref\ 30\%}$	$er_{ref\ 40\%}$	$er_{ref\ 50\%}$	$er_{ref\ 60\%}$	$er_{ref\ 70\%}$	$er_{ref\ 80\%}$
1	3,7 %	2,1 %	4,9 %	3,2 %	2,2 %	2,3 %	1,9 %	3,9 %
2	6,7 %	7,5 %	7,8 %	8,1 %	8,4 %	9,1 %	9,8 %	11,3 %
3	9,1 %	9,8 %	10,7 %	11,2 %	11,7 %	11,9 %	12,3 %	14,2 %
4	9,5 %	9,9 %	11,2 %	11,9 %	12,4 %	13,7 %	13,9 %	14,9 %
5	6,7 %	6,9 %	7,8 %	8,3 %	8,9 %	9,5 %	9,95 %	10,7 %
6	2,7 %	3,9 %	4,1 %	4,3 %	4,4 %	4,9 %	5,6 %	8,4 %
7	6,1 %	6,3 %	6,7 %	7,23 %	7,5 %	7,8 %	8,4 %	9,5 %

3.4.2.2 Estimation à partir des temps de référence de la courbe moyenne

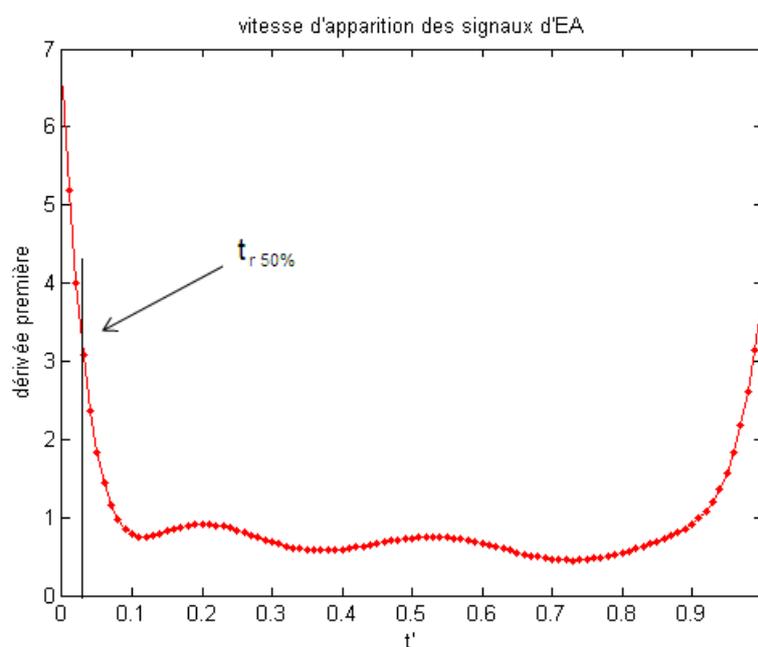


FIGURE 3.18 – Reconstruction de la courbe moyenne à partir des courbes des tests effectués.

Le principe de cette technique (figure 3.18) est de trouver, à partir de la dérivée de la courbe moyenne de toutes les courbes, les temps correspondant à la diminution de la dérivée (vitesse) de 10%, 20%, 30%, 40%, 50%, 60%, 70% et 80% ($t_{ref\ 10\%}$, $t_{ref\ 20\%}$, $t_{ref\ 30\%}$, $t_{ref\ 40\%}$, $t_{ref\ 50\%}$, $t_{ref\ 60\%}$, $t_{ref\ 70\%}$ et $t_{ref\ 80\%}$), et ensuite de trouver la relation avec le temps de rupture (equation 3.7). Les résultats obtenus par la validation croisée sont donnés dans le tableau 3.16, et une description statistique est fournie dans le tableau 3.17.

TABLE 3.17 – Description statistique des résultats des erreurs obtenues.

	minimum	maximum	moyenne	écart type
$er_{ref\ 10\%}$	2,7 %	9,5 %	6,36 %	2,33
$er_{ref\ 20\%}$	2,1 %	9,9 %	6,63 %	2,66
$er_{ref\ 30\%}$	4,1 %	11,2 %	7,6 %	2,48
$er_{ref\ 40\%}$	3,2 %	11,9 %	7,75 %	2,98
$er_{ref\ 50\%}$	2,2 %	12,4 %	7,93 %	3,39
$er_{ref\ 60\%}$	2,3 %	13,7 %	8,46 %	3,62
$er_{ref\ 70\%}$	1,9 %	13,9 %	8,83 %	3,75
$er_{ref\ 80\%}$	3,9 %	14,9 %	10,41 %	3,44

Dans cette partie, nous avons détaillé une nouvelle méthode d'estimation du temps de rupture en étudiant la vitesse des signaux d'EA dès le début d'un test. Nous avons utilisé deux techniques pour estimer le temps de rupture partant de la même idée, la première était basée sur la détermination de la moyenne des temps de référence correspondant à la diminution d'un certain pourcentage de la vitesse d'apparition des signaux d'EA des différents tests. Ensuite nous avons utilisé cette moyenne pour estimer le temps de rupture. La deuxième méthode était basée sur la reconstruction d'une courbe modèle (moyenne des courbes des différents tests), ensuite nous avons déterminé le temps de référence que nous utiliserons pour estimer le temps de rupture.

Nous remarquons que les valeurs moyennes des erreurs obtenues en déterminant le temps de rupture à partir des temps de référence augmentent en fonction de la diminution de la vitesse d'apparition des signaux d'EA. Les résultats détaillés dans les tableaux 3.15 et tableau 3.17 montrent les erreurs obtenues. Par ailleurs, on notera, en déterminant le temps de rupture à partir du temps de référence qui correspond à la diminution de 10 % de la vitesse, nous obtenons une erreur moyenne de 4,35 % avec un écart-type de 2,47 à partir de la première technique. En revanche, pour la deuxième méthode l'erreur moyenne obtenue est de 6,36 % avec un écart-type de 2,33.

3.5 Conclusion

Dans ce chapitre, le but de notre étude était d'estimer la durée de vie restante sur des matériaux composites à l'aide de méthodes de modélisation de la caractéristique d'EA. Lors d'un test de fluage sur des matériaux composites, les éprouvettes des matériaux composites passent par trois phases d'EA avant la rupture. La première phase est caractérisée par une forte vitesse d'apparition des signaux d'EA au

début du test, cette vitesse devient presque constante dans la deuxième phase avant d'accélérer à nouveau dans la troisième phase avant la rupture de l'éprouvette.

Dans notre travail, nous avons utilisé deux méthodes complémentaires afin d'atteindre notre but. La première méthode est basée sur les études présentées dans la section 3.2 (état de l'art de l'estimation de la rupture), elle consiste à estimer le temps restant à partir des deux temps de transition entre les trois phases. La deuxième méthode est une nouvelle méthode basée sur l'étude de la diminution de la vitesse d'apparition des signaux d'EA. Elle consiste à déterminer le temps de rupture dès le début de la phase primaire en se basant sur la variation de la vitesse d'apparition des signaux d'EA.

Les deux méthodes utilisées sont basées sur l'analyse et la modélisation de l'évolution du nombre cumulé des signaux d'EA. Les étapes communes pour ces deux méthodes sont détaillées dans la section 3.3 :

- un traitement préliminaire sur les signaux enregistrés lors d'un test est nécessaire pour rectifier l'écart présent au début et à la fin des enregistrements.
- Nous avons ensuite effectué une normalisation des courbes des signaux d'EA ; cela nous a permis de superposer les différentes courbes normalisées des tests sur des éprouvettes ayant des temps de rupture différents et de montrer que les réponses en fluage de ces éprouvettes sont parfaitement ressemblantes dans le plan des variables réduites.
- Pour pouvoir étudier et analyser l'évolution du nombre de signaux d'EA, nous avons procédé à la reconstruction analytique de la courbe cumulée normalisée des signaux d'EA en fonction du temps avec une régression. Cela nous a permis d'obtenir une fonction analytique polynomiale générale qui représente le processus du fluage.
- Nous avons ensuite étudié la vitesse d'apparition des signaux d'EA en effectuant la dérivée de la fonction analytique établie pour la courbe de chaque éprouvette.

Après l'étude de l'allure de la dérivée qui représente la vitesse des signaux d'EA, nous avons mis en œuvre les deux méthodes proposées pour estimer le temps restant avant la rupture. L'idée principale de la première méthode est de détecter les deux temps de transition à partir de la courbe de la dérivée et ensuite les corrélérer avec le temps de rupture. La deuxième méthode est basée sur la détermination des temps de référence correspondant à la diminution de la vitesse d'un certain pourcentage et ensuite de les corrélérer avec le temps de rupture.

Nous avons utilisé des techniques communes pour les deux méthodes. La première porte sur la détection des temps de transition ou de référence à partir de la dérivée de chaque courbe puis nous effectuons leur moyenne et ensuite nous trouvons leurs relations avec le temps de rupture. La deuxième méthode est fondée sur la construction d'une courbe moyenne de toutes les courbes (normalisées) ; ensuite à partir de sa dérivée nous détectons les temps de transition ou de référence et finalement nous faisons la corrélation avec le temps de rupture.

Les résultats de la première méthode montrent qu'il faut utiliser la deuxième technique pour calculer le temps de rupture à partir de t_{m12} . L'erreur moyenne obtenue avec cette technique est de 5,43 %. Pour déterminer le temps de rupture à partir de t_{m23} , les résultats montrent qu'il faut utiliser la première technique en ayant une erreur moyenne de 3,06 %. Ces résultats montrent des améliorations significatives par rapport aux méthodes présentées dans l'état de l'art de ce chapitre (section 3.2). Ainsi, nous avons amélioré la détection du temps de transition t_{m12} par rapport à la méthode utilisée par [Nechad, 2004] et [Berbaoui et al., 2009]. Nous avons également amélioré la précision de l'estimation de la durée de vie restante, à partir du deuxième temps de transition t_{m23} , qui s'étale entre 6 % et 7,9 % de la durée déjà écoulée au lieu de 3 à 19 % par rapport à la méthode utilisée par [Thummen, 2004]. Le travail effectué dans ce chapitre a fait l'objet de plusieurs publications [Darwiche et al., 2012a, 2013].

En estimant le temps restant à partir de la deuxième méthode, nous recommandons d'utiliser la première technique qui donne des résultats très intéressants. En effet, l'estimation du temps restant dès le début du test donne une erreur moyenne de 4,35 %. Les résultats obtenus par cette deuxième méthode sont très importants pour l'estimation de la durée de vie restante sur des matériaux composites. Ainsi, pour une éprouvette ayant une durée de vie de 1 heure, nous pouvons prédire sa rupture dès les 90 premières secondes.

Conclusion générale et perspectives

Il est indispensable de connaître la durabilité des matériaux composites pour généraliser leur utilisation surtout dans des secteurs sensibles comme l'aéronautique, l'aérospatiale et l'automobile. La fatigue de ces matériaux constitue un défi particulier pour les chercheurs.

L'étude abordée dans la première partie de notre travail propose de prédire la limite de la résistance des matériaux composites avant leur rupture. La méthodologie utilisée consiste à analyser les signaux d'EA reçus lors d'essais de traction sur des matériaux composites modèles afin d'extraire les informations qui conduisent à la rupture. Un effort particulier portant sur l'étude des signaux d'EA qui précèdent la rupture, montre que les valeurs des paramètres de ces signaux sont plus élevés, en regard de ceux qui apparaissent, loin de la rupture. La problématique étudiée consistait à prédire si un signal d'EA, sélectionné aléatoirement dans un essai, appartient à la phase qui précède la rupture ou non. Pour pouvoir séparer les signaux d'EA provenant de la phase qui précède la rupture parmi les signaux collectés loin de cette phase, une méthode de classification en utilisant des machines d'apprentissage statistiques (réseaux de neurones, machines à vecteurs de support (SVM), ou classifieurs Bayésiens) a été développée.

La classification des signaux d'EA a d'abord été menée en utilisant les descripteurs temporels usuels utilisés en émission acoustique comme paramètres d'entrée des machines d'apprentissage. Afin d'obtenir les meilleurs résultats en classification, une sélection des paramètres pertinents a été effectuée. Le potentiel de ces méthodes en termes de classification des signaux d'EA a d'abord été validé à l'aide de la technique de validation croisée, puis testé sur des signaux sélectionnés au hasard. Parmi les machines d'apprentissage statistique utilisées, les SVM fournissent les meilleurs résultats de classification avec une sensibilité moyenne de 82 %, une spécificité moyenne de 84 % et une surface moyenne sous la courbe de ROC de 0,84. Etant donné que les résultats obtenus semblent prometteurs, un processus de surveillance des matériaux en service pourrait être mis œuvre. Ainsi, une collecte continue des signaux d'EA, couplée à une classification instantanée de ces signaux

pourrait permettre de remonter une alerte afin de suggérer un changement rapide des matériaux incriminés.

L'estimation de la durée de vie restante des matériaux composites a fait l'objet de l'étude présentée dans le chapitre 3. L'analyse du comportement en fluage des matériaux montre une similitude de ce phénomène dans les différents essais, ce qui a poussé les chercheurs à s'inspirer de ce formalisme pour étudier la rupture. Ainsi nous avons suivi par émission acoustique l'endommagement des matériaux composites dans le but d'obtenir une description la plus fine possible du fluage. La normalisation des courbes des signaux d'EA cumulés a confirmé la similitude du comportement en fluage de ces matériaux. Un modèle mathématique de ces courbes normalisées a été établi. Le traitement du taux d'apparition des signaux d'EA, en se basant sur le modèle établi, nous a permis de mieux comprendre les processus d'endommagement qui mènent à la rupture globale et d'établir des lois pour estimer le temps restant de ces matériaux. Pour éviter les erreurs de classification possibles, la présence de plusieurs alertes successives peut confirmer la limite de la résistance et du coup l'imminence de la rupture.

Dans un premier temps, nous avons établi des corrélations entre les temps correspondant aux transitions des phases de la réponse en fluage et le temps de rupture. De nouvelles techniques ont été utilisées pour déterminer ces temps de transition. Les résultats obtenus ont montré des améliorations importantes par rapport aux travaux existants. Les techniques que nous avons utilisées pour la détection des temps de transition se sont avérées très performantes : nous avons pu localiser le temps de transition primaire/secondaire à 12 % de la durée de vie globale du matériau étudié en obtenant une précision très intéressante de l'estimation de la rupture.

Ensuite, nous nous sommes intéressés à l'estimation de la rupture dès le début du test. Nous avons remarqué que la diminution du taux d'apparition des signaux d'EA était similaire dans tous les tests. Ceci nous a poussé à rechercher la possibilité d'obtenir une relation entre la diminution du taux d'apparition des signaux et le temps de rupture. Une corrélation a été observée entre le temps qui correspond à la diminution de 10 % du taux d'apparition des signaux d'EA et le temps de rupture. Les résultats obtenus sont très significatifs : le temps qui correspond à la diminution de 10 % du taux d'apparition des signaux d'EA a été localisé à 0,4 % de la durée de vie globale du matériau étudié. Ainsi, dans le cas d'un matériau de durée de vie de 1 heure nous pouvons prédire la rupture dès les 90 premières secondes. L'erreur moyenne obtenue était de 4,35 %, ce qui prouve l'efficacité de notre méthode.

Nous avons pu répondre à plusieurs questions qui peuvent être rencontrées lors de l'utilisation de ces matériaux composites dans le domaine industriel. Dans le cas où les matériaux sont déjà en service et qu'aucune connaissance antérieure de leur état n'est présente, nous pouvons surveiller ces matériaux en utilisant la méthode

présentée dans la première étude (prédiction avec les SVM) et signaler l'approche de leur rupture ainsi que le besoin de changer ces matériaux. Dans le cas d'une nouvelle installation, nous pouvons suivre et estimer la durée de vie restante de ces matériaux à plusieurs reprises :

- dès la diminution de 10 % du taux d'EA, de 20 %, de 30 %, . . . , 80 %,
- à partir du temps de transition primaire/secondaire,
- à partir du temps de transition secondaire/tertiaire.

Il existe des cas de figure où on se retrouve face à des matériaux anormaux qui ne suivent pas le comportement connu. Dans ce cas, nous proposons, lors d'une nouvelle installation, d'utiliser en parallèle et de façon complémentaire, les méthodes présentées dans les deux études de cette thèse afin d'assurer la sécurité de la structure où les matériaux sont utilisés.

Cette thèse s'ouvre sur d'autres perspectives. Ainsi, à très court terme, il semble parfaitement envisageable d'implémenter les programmes utilisés, au sein d'un système embarqué afin de surveiller instantanément, les matériaux en service. Sur un plan plus théorique, l'étude des phénomènes qui conduisent à la rupture dans la phase secondaire n'a pas été abordée dans cette thèse. Dans ce but, il semble très intéressant d'étudier l'évolution de chaque type d'endommagement, et de traiter le taux de leur apparition séparément, afin de pouvoir extraire des lois similaires à celles trouvées dans l'étude proposée dans le troisième chapitre. Il est également utile, en termes de prédiction de la rupture, de connaître dans quelle phase l'état du matériau en service se situe. Pour cet objectif, nous proposons de discriminer les signaux d'EA selon leurs phases d'apparition et ce, à l'aide des méthodes utilisées dans l'étude présentée dans le deuxième chapitre.

A moyen terme, la validation de nos études sur d'autres types de matériaux composites que les fibres de verre unidirectionnelles semble très prometteuse.

A plus long terme, de nombreuses pistes s'offrent dans le domaine de l'amélioration des techniques d'apprentissage. Ainsi, il semble prometteur d'utiliser des techniques combinant les SVM, les réseaux de neurones, les classifieurs bayésiens afin de dépasser les performances individuelles de chacun de ces classifieurs [Tulyakov et al., 2008]. Enfin, si les performances obtenues par les SVM sont très intéressantes, le côté "boîte noire" de cette technique d'apprentissage nuit à sa lisibilité. Dès lors, il pourrait sembler judicieux d'extraire des règles à partir des SVM [Barakat and Bradley, 2010] pour essayer ensuite de les recombinaer avec des modèles qui reposeraient sur la physique.

Bibliographie

- H. Abdi. *Les réseaux de neurones*. Presses universitaires de Grenoble, 1994.
- L. Al Shalabi, Z. Shaaban, and B. Kasasbeh. Data mining : A preprocessing engine. *Journal of Computer Science*, pages 735–739, 2006.
- A. Anastassopoulos and T. P. Philippidis. Clustering methodology for the evaluation of acoustic emission from composites. *Journal of Acoustic Emission*, 13 :11–22, 1995.
- J. Anifrani, C. Le Floch, D. Sornette, and B. Souillard. Universal log-periodic correction group scaling for rupture stress prediction from acoustic emission. *Journal of Physics*, 5 :631–638, 1995.
- J. P. Asselin de Beauville and F. Z. Kettaf. *Bases théoriques pour l'apprentissage et la décision en reconnaissance des formes*. Cépaduès, 2005.
- N. Ativitavas, T. Fowler, and T. Pothisiri. Acoustic emission characteristics of pultruded fiber reinforced plastics under uniaxial tensile stress. *Proceeding of European Working Group on Acoustic Emission, Berlin*, 5 :447–454, 2004.
- N. Barakat and A. P. Bradley. Rule extraction from support vector machines : A review. *Neurocomputing*, 74 :178 – 190, 2010.
- R. E. Bellman. *Adaptative control processes*. Princeton University Press, 1961.
- M. Bentahar. *Acoustique non-linéaire : Application à la caractérisation ultra-sonore de l'endommagement des matériaux hétérogènes et à la prédiction de la durée de vie*. PhD thesis, INSA de Lyon, 2005.
- M. L. Benzeggagh and S. Barre. On the use of acoustic emission to investigate damage mechanisms in glass-fiber-reinforced polypropylene. *Composites Science and Technology*, 52 :369–376, 1994.
- R. Berbaoui, A. El Mahi, and R. El Guerjouma. Acoustic emission analysis of polymer concrete damage in creep. *Journées Nationales sur les Composites*, 2009.
- R. Berbaoui, A. El Mahi, and R. El Guerjouma. Contrôle de santé de béton polymère en fluage par Émission acoustique. 10^{ème} *Congrès Français d'Acoustique*, 2010.

- J. M. Berthelot. *Matériaux composites : Comportement mécanique et analyse des structures*. Tec et Doc, 1996. ISBN 2743007710. URL <http://www.worldcat.org/isbn/2743007710>.
- M. Bertin. *Fatigue thermomécanique de multicouches polymère/composite*. Phd thesis, Ecole Nationale Supérieure de Mécanique et d'Aérotechnique, Université de Poitiers, 2011.
- J. C. Bezdek. Pattern recognition with fuzzy objective function algorithms. *Plenum Press, New-York*, 1981.
- C. M. Bishop. *Pattern recognition and machine learning*. Springer, 2006.
- C. M. Bishop, S. M. Svensén, and C. K. I. Williams. GTM : the generative topographic mapping. *Neural Computation*, 10 :215–234, 1998.
- J. Bohse. Damage analysis of polymer matrix composites by acoustic emission testing, 2004.
- O. Ceysson, M. Salvia, and L. Vincent. Damage mechanisms characterisation of carbon fibre/epoxy composite laminates by both electrical resistance measurements and acoustic emission analysis. *Scripta Materialia*, 34 :1273–1280, 1996.
- S. C. Chapra and R. P. Canale. *Numerical Methods for Engineers*. McGraw-Hill, Fourth Edition, 2002.
- O. Chen, P. Karandikar, N. Takeda, and T. Kishi. Acoustic emission characterization of a glass-matrix composite. *Nondestructive Testing and Evaluation*, 9, 1992.
- Y. Chevalier. Comportements élastique et viscoélastique des composites. *Techniques de l'Ingénieur*, A 7750, 1988.
- A. Cornuéjols. *Apprentissage et circulation d'information*. Habilitation à diriger les recherches, Université Paris-Sud, 2005.
- M. Darwiche, R. Berbaoui, M. Feuilloy, D. Schang, G. Bousaleh, and R. El Guerjouma. 18th international congress on sound and vibration (icsv 18). In *Proceedings of a meeting held 10-14 July 2011, Rio de Janeiro, Brazil*, pages 3114–3122. Curran Associates, 2011.
- M. Darwiche, G. Bousaleh, M. Feuilloy, D. Schang, and R. El Guerjouma. A normalization method for life-time prediction of composite materials. In *Proceedings of the Acoustics 2012 Nantes Conference*, pages 2949–2953, 2012a.
- M. Darwiche, G. Bousaleh, M. Feuilloy, D. Schang, and R. El Guerjouma. Creep-rupture prediction by naive bayes classifiers. In *Proceedings of the Acoustics 2012 Nantes Conference*, pages 2431–2435, 2012b.

- M. Darwiche, M. Feuilloy, D. Schang, G. Bousaleh, and R. El Guerjouma. Creep test material rupture prediction by neural networks. In *Sciences of Electronics, Technologies of Information and Telecommunications (SETIT), 2012 6th International Conference*, pages 902–905, 2012c.
- M. Darwiche, G. Bousaleh, M. Feuilloy, D. Schang, and R. El Guerjouma. Lifetime prediction in heterogenous materials. 2013. Submitted to Mechanical Systems and Signal Processing.
- J. M. Dorlot, J. P. Bâillon, and J. Masounave. *Des matériaux*. Ecole Polytechnique de Montréal, 1986.
- G. Dreyfus, J. M. Martinez, M. Samuelides, M. B. Gordon, F. Badran, S. Thiria, and L. Héroult. *Réseaux de neurones : méthodologie et applications*. Eyrolles, 2002.
- R. Dubes and A. K. Jain. Clustering techniques : the user’s dilemma. *Pattern Recognition*, 8 :247–260, 1976.
- R. O. Duda and P. E. Hart. *Pattern classification and scene analysis*. John Wiley and Sons, 1973.
- R. O. Duda, P. E. Hart, and D. Stork. *Pattern classification*. Wiley, 2001.
- J. P. Favre. Interface dans les composites fibreux. *Techniques de l’Ingénieur Plastiques et composites*, A7765, 1992.
- T. Fawcett. An introduction to ROC analysis. *Pattern Recognition Letters, special issue on ROC analysis*, 27 :861–874, 2005.
- M. Feuilloy. *Étude d’algorithmes d’apprentissage artificiel pour la prédiction de la syncope chez l’homme*. Phd thesis, Université d’Angers, 2009.
- K. Fukushima. A neural network for visual pattern recognition. *Computer*, 15 : 65–74, March 1988.
- F. Galton. Regression towards mediocrity in hereditary stature. *Journal of the Anthropological Institute*, 15 :246–263, 1886.
- D. Gay. *Matériaux composites*. Hermès, 1997.
- N. Godin. *Identification de la signature acoustique des mécanismes d’endommagement se produisant lors de sollicitation mécanique ou thermomécanique. Application à la prévision de la durée de vie*. Habilitation à diriger les recherches, INSA de Lyon, 2009.

- N. Godin, S. Huguet, R. Gaertner, and L. Salmon. Clustering of acoustic emission signals collected during tensile tests on unidirectionnal glass/polyester composites using supervised and unsupervised classifiers. *Nondestructive Testing and Evaluation*, 37 :253–64, 2004.
- N. Godin, S. Huguet, and R. Gaertner. Integration of the kohonen self-organising map and k-means algorithm for the segmentation of the AE data collected during tensile tests on cross-ply composites. *NDT International*, 38 :299–309, 2005.
- S. Grossberg. *Neural Networks and Natural Intelligence*. MIT Press, 1992.
- S. Guérif. *Réduction de dimension en apprentissage numérique non supervisé*. PhD thesis, Université de Paris 13, 2006.
- R. Gutierrez-Osuna. Pattern analysis for machine olfaction : a review. *IEEE Sensors journal*, 2(3) :189–202, 2002.
- R. Gutkin, C. J. Green, S. Vangrattanachai, S. T. Pinho, P. Robinson, and P. T. Curtis. On acoustic emission for failure investigation in CFRP : pattern recognition and peak frequency analysis. *Mechanical Systems and Signal Processing*, 25 : 1393–1407, 2011.
- J. A. Hanley and B. J. McNeil. The meaning and use of the area under a receiver operating characterisitic (R.O.C.) curve. *Radiology*, 143(1) :29–36, 1982.
- M.H. Hassoun. *Fundamentals of Artificial Neural Networks*. MIT Press, 1995.
- K. Hattori and M. Takahashi. A new nearest-neighbor rule in the pattern classification problem. *Pattern Recognition*, 32 :425–432, 1999.
- S. Haykin. *Neural networks : a comprehensive foundation*. Prentice Hall, 1999.
- D. O. Hebb. *The organization of behavior*. New York, Wiley, 1949.
- H. Herrmann and S. Roux. *Statistical Models for the Fracture of Disordered Media*. North-Holland, Amsterdam, 1990.
- G. E. Hinton. *Neural networks and natural intelligence*. MIT press, Cambridge MA, 1988.
- S. Huguet. *Application de classificateurs aux données d'émission acoustique : identification de la signature acoustique des mécanismes d'endommagement dans les composites à matrice polymère*. Phd thesis, Institut National des Sciences Appliquées de Lyon, 2002.

- M. Jacquesson. *Mécanismes d'endommagement sous sollicitations monotone et cyclique de composites quasi-UD à fibres longues et à matrice base Aluminium. Apport de l'émission acoustique*. PhD thesis, Institut des Sciences Appliquées de Lyon, 2000.
- J.F. Jodouin. *Les réseaux de neurones : principes et définitions*. Hermès, 1994.
- I. T. Jolliffe. *Principal Component Analysis*. Springer, second edition, 2002.
- S. Journaux. *Évaluation de l'endommagement de pièces métalliques par analyse d'images : Endommagement par piqûres de corrosion, endommagement par fluage*. PhD thesis, Université de Bourgogne, 1999.
- A. Kaffou. *Étude du comportement des interfaces et des interphases dans les composites à fibres et à matrices céramiques*. PhD thesis, Institut des Sciences Appliquées de Lyon., 2006.
- J. Kaiser. *Untersuchungen über das Auftreten von Geräuschen beim Zugversuch (études sur la présence de bruits dans l'essai de traction)*. PhD thesis, Université technique de Munich, 1950.
- M. Kawai. Damage mechanics model for off-axis fatigue behavior of unidirectional carbon fiber-reinforced composites at room and high temperatures. *MASSARD T. Proc. of the 12th International Conference on Composite Materials, Paris, France*, 1999.
- M. Kharoubi, L. Fatmi, A. El Mahi, R. EL Guerjouma, and R. Berbaoui. Identification du dommage par EA de stratifiés composites chargés en statique et cyclique. *10^{ème} Congrès Français d'Acoustique*, 2010.
- A. Khavandi. *Étude de la déformation non élastique de composites unidirectionnels verre-résine époxyde : Prévission du comportement mécanique*. PhD thesis, Institut des Sciences Appliquées de Lyon, 1997.
- S. T. Kim and Y. T. Lee. Characteristics of damage and fracture process of carbon fiber reinforced plastic under loading-unloading test by using AE method. *Materials Science and Engineering*, 236 :322–326, 1997.
- T. Kohonen and P. Somervuo. How to make large self-organizing maps for nonvectorial data. *Neural Networks*, 15(8-9) :945–952, 2002.
- V. Kostopoulos, T. H. Loutas, A. Kontsos, G. Sotiriadis, and Y. Z. Pappas. On the identification of the failure mechanisms in oxide/oxide composites using acoustic emission. *Nondestructive Testing and Evaluation*, 36 :571–580, 2003.

- G. Kotsikos, J. T. Evans, A. G. Gibson, and J. Hale. Use of acoustic emission to characterize corrosion fatigue damage accumulation in glass fiber reinforced polyester laminates. *Polymer Composites*, 20 :689–696, 1999.
- L. Lamagnère, F. Carmona, and D. Sornette. Experimental realization of critical thermal fuse rupture. *Physical Review Letters*, 77 :2738–2741, 1996.
- T. C. W. Landgrebe and R. P. W. Duin. Approximating the multiclass ROC by pairwise analysis. *Pattern Recognition Letters*, 28(13) :1747–1758, 2007.
- T. C. W. Landgrebe and R. P. W. Duin. Efficient multiclass ROC approximation by decomposition via confusion matrix perturbation analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30(5) :810–822, 2008.
- P. Langley. *Elements of machine learning*. Morgan Kaufmann, 1996.
- A. Likas, N. Vlassis, and J. Verbeek. The global k-means clustering algorithm. *Pattern Recognition*, 366 :451–461, 2003.
- A. Marec. *Contrôle de santé des matériaux hétérogènes par émission acoustique acoustique non linéaire : discrimination des mécanismes d'endommagement et estimation de la durée de vie restante*. PhD thesis, Université du Maine, 2008.
- A. Marec, J. H. Thomas, and R. El Guerjouma. Damage characterization of polymer-based composite materials : Multivariable analysis and wavelet transform for clustering acoustic emission data. *Mechanical Systems and Signal Processing*, 22 : 1441–1464, 2008.
- W. S. McCulloch and W. S. Pitts. A logical calculus of ideas imminent in nervous activity. *Bulletin of Mathematical Biophysics*, 5 :115–133, 1943.
- C. Metz. Basic principles of ROC analysis. *Seminars in Nuclear Medicine*, 3(4), 1978.
- M. Minsky and S. Papert. *Perceptrons*. MIT Press, Cambridge, MA, 1969.
- M. Nauenberg. Scaling representation for critical phenomena. *Journal Physics*, 8 : 925–928, 1975.
- H. Nechad. *Évaluation de l'endommagement et de la rupture de matériaux hétérogènes par ultrasons et émission acoustique : Estimation de la durée de vie restante*. PhD thesis, INSA de Lyon, 2004.
- H. Nechad, A. Helmstetter, R. El Guerjouma, and D. Sornette. Andrade and critical time-to-failure laws in fibre-matrix composites : Experiments and model. *Journal of Mechanics and Physics of solids*, 53 :1099–1127, 2005.

- E. Oja. Neural networks, principal components, and subspaces. *International Journal of Neural Systems*, 1 :61–68, 1991.
- K. Ono. Acoustic emission. *Encyclopedia of acoustics*, Wiley, 1997.
- K. Ono and Q. Huang. Pattern recognition analysis of acoustic emission signals. *Progress in Acoustic Emission VII, The Japanese Society for NDI*, 86 :69–78, 1994.
- T. Ouahbi. Composite materials in aeronautic, page consultée en, 2013. URL <http://www.composite.free.fr/>.
- Y. Z. Pappas, Y. P. Markopoulos, and V. Kostopoulos. Failure mechanisms analysis of 2d carbon/carbon using acoustic emission monitoring. *Nondestructive Testing and Evaluation*, 31 :157–163, 1998.
- E. Petit, J. Lemoine, and S. Djeziri. An adaptative method to smooth discrete curves proposed as a final step for edge detection. *Image Vision Comput.*, 19(3) : 145–152, 2001.
- S. J. T. Pollard, G. D. Fowler, C. J. Sollars, and R. Perry. Low cost adsorbents for waste and wastewater treatment : a review. *The Science Total Environ*, 116 : 31–52, 1992.
- D. Pyle. *Data preparation for data mining*. Morgan Kaufmann Publishers, 1999.
- C. R. Ramirez-Jimenez, N. Papadakis, N. Reynolds, T. H. Gan, P. Purnell, and M. Pharaoh. Identification of failure modes in glass/polypropylene composites by means of the primary frequency content of the acoustic emission event. *Composites Science and Technology*, 64 :1819–1827, 2004.
- J. P. Rennard. *Réseaux neuronaux : une introduction accompagnée d'un modèle Java*. Vuibert, Paris, 2006.
- J. Roget. *Essais non destructifs - L'émission acoustique Mise en œuvre et applications*. AFNOR, 1988.
- F. Rosenblatt. The perceptron : a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65 :386–408, 1958.
- D. E. Rumelhart, G. E. Hinton, and R. J. Williams. Parallel distributed processing : explorations in the microstructure of cognition, vol. 1. chapter Learning internal representations by error propagation, pages 318–362. MIT Press, Cambridge, MA, USA, 1986.
- H. K. Shen and J. L. Rutherford. Flow behavior of nylon epoxyde adhesive. *Mater Science engineering*, 9 :323–331, 1972.

- Société Solana. Epoxy surfboard buyers guide - solana surfboards, page consultée en, 2013. URL <http://www.solanasurfboards.com/epoxy-surfboard-buyers-guide.html>.
- D. Sornette. Discrete scale invariance and complex dimensions. *Phys. Rep.*, 297 : 239–270, 1998.
- D. Sornette and J. Andersen. Scaling with respect to disorder in time-to-failure. *Eur. Phys. J. B*, 1 :353–357, 1998.
- A. Srinivasan. Note on the location of optimal classifiers in n-dimensional roc space. Technical report, Oxford University Computing Laboratory Oxford, England, 1999.
- M. Stone. Cross-validatory choice and assessment of statistical prediction. *Journal of the Royal Statistical Society*, 36(1) :111–147, 1974.
- H. Stoppiglia. *Méthodes statistiques de sélection de modèles neuronaux ; applications financières et bancaires*. PhD thesis, Université Pierre et Marie Curie, 1997.
- R. S. Sutton. Reinforcement learning architectures for animats. *The second International Conference on Simulation of Adaptive Behavior*, MIT Press, 1992.
- S. Theodoridis and K. Koutroumbas. *Pattern Recognition*. Academic Press, 2006.
- F. Thummen. *Propriétés mécaniques et durée de vie de bétons réfractaires*. PhD thesis, INSA de Lyon, 2004.
- M. T. Tran. *Approche des mécanismes d'oxydation thermique par l'émission acoustique*. PhD thesis, Université de Grenoble, 2011.
- S. Tufféry. *Data mining et statistique décisionnelle*. Editions Technip, 2007.
- S. Tulyakov, S. Jaeger, V. Govindaraju, and D. Doermann. Review of classifier combination methods. In Marinai, S. and Fujisawa, H., *Machine Learning in Document Analysis and Recognition*, volume 90 of *Studies in Computational Intelligence*, pages 361–386. Springer Berlin Heidelberg, 2008.
- M. J. Van der Laan and K. S. Pollard. A new algorithm for hybrid hierarchical clustering with visualization and the bootstrap. *Journal of Statistical Planning and Inference*, 117 :275–303, 2003.
- V. Vapnik. Principles of Risk Minimization for Learning Theory. In *Neural Information Processing Systems*, pages 831–838, 1991.
- V. Vapnik and A. Y. Chervonenkis. *Theory of pattern recognition*. Nauka, Moscow, 1974.

-
- D. A. White and D. A. Sofge. *Handbook of intelligent control*. Van Nostrand Reinhold, 1992.
- B. Widrow and M. E. Hoff. Adaptive switching circuits. In *IRE WESCON Convention Record*, volume 4, pages 96–104, 1960.

