



Université du Québec  
à Rimouski

## **Prédiction du comportement en fatigue des composites des pales d'éoliennes à l'aide des méthodes d'intelligence artificielle**

Mémoire présenté  
dans le cadre du programme de maîtrise en ingénierie  
en vue de l'obtention du grade « maître ès sciences appliquées »  
(M. Sc. A.)

PAR

**Khaled Ziane**

**Mai 2020**



**Composition du jury :**

**Mohamad Yasser Hayyani, président du jury, Université du Québec à Rimouski**

**Adrian Ilinca, directeur de recherche, Université du Québec à Rimouski**

**Hussein Ibrahim, examinateur externe, ITMI**

Dépôt initial le 24 Février 2020

Dépôt final le 01 Mai 2020



UNIVERSITÉ DU QUÉBEC À RIMOUSKI  
Service de la bibliothèque

Avertissement

La diffusion de ce mémoire ou de cette thèse se fait dans le respect des droits de son auteur, qui a signé le formulaire « *Autorisation de reproduire et de diffuser un rapport, un mémoire ou une thèse* ». En signant ce formulaire, l'auteur concède à l'Université du Québec à Rimouski une licence non exclusive d'utilisation et de publication de la totalité ou d'une partie importante de son travail de recherche pour des fins pédagogiques et non commerciales. Plus précisément, l'auteur autorise l'Université du Québec à Rimouski à reproduire, diffuser, prêter, distribuer ou vendre des copies de son travail de recherche à des fins non commerciales sur quelque support que ce soit, y compris l'Internet. Cette licence et cette autorisation n'entraînent pas une renonciation de la part de l'auteur à ses droits moraux ni à ses droits de propriété intellectuelle. Sauf entente contraire, l'auteur conserve la liberté de diffuser et de commercialiser ou non ce travail dont il possède un exemplaire.



## **REMERCIEMENTS**

Mes premiers remerciements et les plus vifs, je les adresse à mon directeur de recherche Professeur Adrian Ilinca qui m'a honoré d'avoir dirigé ce travail. Je le remercie pour la rigueur scientifique, l'objectivité et l'orientation. Il a toute ma gratitude pour m'avoir aidé et encouragé dans les moments difficiles et m'avoir consacré son temps malgré ses occupations.

Je tiens à remercier Monsieur Mohamad Yasser Hayyani, Professeur à l'Université du Québec à Rimouski de m'avoir fait l'honneur de participer au jury en tant que président.

Je présente aussi mes remerciements au Docteur Hussein Ibrahim, Directeur de l'Institut Technologique de Maintenance Industrielle ITMI de Sept-Îles, d'avoir accepté d'examiner ce mémoire.

Mes remerciements s'adressent également à tous les membres du Laboratoire de Recherche en Énergie Éolienne et à tous les enseignants et le personnel de l'Université du Québec à Rimouski UQAR.



## RÉSUMÉ

Les pales d'éoliennes sont les éléments les plus endommagés et la principale source de dégradation des performances des éoliennes. Une prédition de défaillance ou de la durée de vie restante des pales permettra aux opérateurs de mieux planifier leurs interventions ainsi que la gestion de leurs éoliennes tout en réduisant leurs coûts d'opération et de maintenance (O&M). C'est dans ce contexte que s'inscrit ce mémoire, qui vise principalement à prédire le comportement en fatigue des composites des pales d'éoliennes à l'aide des méthodes d'intelligence artificielle. Cette technique s'inscrit dans une stratégie de maintenance prédictive appliquée aux pales d'éoliennes. Plus précisément, il s'agit, de prédire bien avant le bris des pales et la rupture des matériaux composites des pales d'éoliennes à l'aide des techniques d'intelligence artificielle en fonction des charges dynamiques, qui ont été développées pour apporter des réponses à des problèmes complexes et qui peuvent avoir un grand nombre de solutions possibles. Les réseaux de neurones utilisés dans le premier article sont employés pour prédire le comportement en fatigue (résistance et durée de vie) des matériaux composites destinés à la conception des pales d'éoliennes. La phase expérimentale sur ces matériaux a été réalisée par les laboratoires nationaux de Sandia, et les données ont été collectées à partir d'une variété de cette base de données. Après plusieurs tests de topologie, algorithme d'apprentissage et d'entraînement, des fonctions d'activations, etc.; le choix s'est arrêté sur le réseau feedforward à une seule couche cachée « *Tow-layer feedforward neural network* » entraîné par un algorithme de recherche coucou « *Cuckoo search algorithm* » pour prédire la durée de vie en fatigue des pales conçues de deux types d'orientation de fibres, unidirectionnelles et multidirectionnelles. L'objectif du deuxième article est d'identifier les résines les plus résistantes à l'humidité/température en termes de durée de vie en fatigue. Quatre types de résines sont comparés dans ce travail, représentant les résines les plus couramment utilisées pour la fabrication des pales d'éoliennes. Les résines polymères thermodurcissables, y compris les polyesters et les esters vinyliques ont été usinées sous forme des coupons et testées dans des températures de 20 °C et 50 °C dans des conditions "sèches" et "humides". Les données expérimentales sur la fatigue, disponibles de « *Sandia National Laboratories (SNL)* », ont été utilisées pour construire, entraîner et valider

notre réseau, ainsi que pour prédire la durée de vie en fatigue dans différentes conditions environnementales. Les performances de trois algorithmes (*Backpropagation BP*, *Particle Swarm Optimization PSO* et *Cuckoo Search CS*) sont comparées pour ajuster les poids synaptiques de ce réseau et pour évaluer leur efficacité de prédire la durée de vie en fatigue des matériaux étudiés, sous les conditions mentionnées ci-dessus. Pour l'évaluation de la précision, l'erreur quadratique moyenne (*Mean Square Error MSE*) est utilisée comme fonction objective à optimiser par les trois algorithmes.

Mots clés : Pales d'éolienne, Matériaux composites, Durée de vie en fatigue, Réseaux de neurones artificiels, Prédiction, Particle swarm optimization, Backpropagation, Cuckoo search.

## ABSTRACT

Wind turbine blades are still the most damaged elements and the main source of degraded wind turbine performance. Predicting failures or the remaining life of the blades will allow operators to better plan their interventions as well as the management of their wind turbines while reducing their operating and maintenance costs (O&M). In this context that this thesis is written, which mainly aims to predict the fatigue behavior of wind turbine blade composites using artificial intelligence methods. This technique is part of a predictive maintenance strategy applied to wind turbine blades. More precisely, it is a question of predicting well before the rupture of the blades and the rupture of the composite materials of the blades of wind turbines using the techniques of artificial intelligence according to the dynamic loads, which have been developed to provide answers to complex problems which can have a large number of possible solutions. The neural networks used in the first article are used to predict the fatigue behavior (strength and lifetime) of composite materials intended for the design of wind turbine blades. Sandia National Laboratories carried out the experimental phase on these materials, and data was collected from a variety of this database. After several tests of topology, learning and training algorithm, activation functions, etc.; the choice stopped on the feedforward neural network with a single hidden layer "Two-layer feedforward neural network" trained by a cuckoo search algorithm to predict the fatigue life of blades designed of two types of fiber orientation, unidirectional and multidirectional. The objective of the second article is to identify which resins are the most robust to moisture/temperature in terms of fatigue life. Four types of resins are compared in this work, representing the most common resins used for wind turbine blades manufacturing. Thermoset polymer resins, including polyesters and vinyl esters, were machined as coupons and tested for the fatigue in air temperatures of 20 °C and 50 °C under "dry" and "wet" conditions. The fatigue experimental data available from Sandia National Laboratories (SNL) for wind turbine-related materials has been used to build, train and validate an Artificial Neural Network (ANN) to predict the fatigue life under different environmental conditions. The performances of three algorithms (Backpropagation BP, Particle Swarm Optimization PSO and Cuckoo Search CS) are compared for adjusting the synaptic weights of the Artificial

Neural Network (ANN) and to evaluate the efficiency in predicting the fatigue life of the materials studied, under the conditions mentioned above. For accuracy evaluation, Mean Square Error (MSE) is used as an objective function to be optimized by the three algorithms.

*Keywords:* Wind turbine blades, Composite materials, Fatigue life, Artificial neural networks, Prediction, Particle swarm optimization, Backpropagation, Cuckoo search.

## TABLE DES MATIÈRES

REMERCIEMENTS .....	vii
RÉSUMÉ .....	ix
ABSTRACT.....	xi
TABLE DES MATIÈRES .....	xiii
LISTE DES FIGURES .....	xv
LISTE DES ABRÉVIATIONS, DES SIGLES ET DES ACRONYMES .....	xvii
LISTE DES SYMBOLES.....	xix
CHAPITRE I.....	1
INTRODUCTION GÉNÉRALE .....	1
I.1. MISE EN CONTEXTE ET PROBLEMATIQUE .....	1
I.1. OBJECTIFS & METHODOLOGIE .....	4
I.3. PALES EN MATERIAUX COMPOSITES.....	4
I.3.1. CLASSIFICATION DES MATERIAUX COMPOSITES .....	4
I.3.2. CONSTITUANTS DES MATERIAUX COMPOSITES .....	5
I.3.2.1. LES FIBRES .....	6
I.3.2.2. LES MATRICES .....	7
I.3.2.2. L'INTERPHASE.....	9
I.4. PROCEDE DE FABRICATION DES PALES D'EOLIENNES .....	9
I.4. FATIGUE DES PALES D'EOLIENNE .....	11
I.4.1. ENDOMMAGEMENT EN FATIGUE .....	11
I.4.2. MECANISMES D'ENDOMMAGEMENT EN FATIGUE .....	12
I.4.3 PREDICTION DE LA DUREE DE VIE EN FATIGUE .....	13
I.5. PREDICTION NUMERIQUE .....	17
I.5.1. REGRESSION LINEAIRE .....	18

CHAPITRE II RESEAU DE NEURONES BASE SUR LA RECHERCHE COUCOU POUR PREDIRE LA DUREE DE VIE EN FATIGUE DES COMPOSITES DES PALES D'EOLIENNES.....	20
II.1 RESUME EN FRANÇAIS DU PREMIER ARTICLE .....	20
II.1 A CUCKOO SEARCH BASED NEURAL NETWORK TO PREDICT FATIGUE LIFE IN ROTOR BLADE COMPOSITES .....	22
CHAPITRE III ALGORITHMES D'OPTIMISATION DU RESEAU NEURONAL POUR PREDIRE LA DUREE DE VIE EN FATIGUE DES PALES D'EOLIENNES SOUS DES CONDITIONS HYGROTHERMIQUES .....	40
III.1 RESUME EN FRANÇAIS DU DEUXIEME ARTICLE .....	40
III.2 NEURAL NETWORK OPTIMIZATION ALGORITHMS TO PREDICT WIND TURBINE BLADE FATIGUE LIFE UNDER VARIABLE HYGROTHERMAL CONDITIONS .....	41
CONCLUSION GÉNÉRALE .....	61
REFERENCES BIBLIOGRAPHIQUES .....	65

## **LISTE DES FIGURES**

Figure I.1 : Classification des matériaux composites .....	5
Figure I.2 : Constituants d'un matériau composite stratifié.....	8
Fig. I.3 : Coupe transversale d'un profil de pale sous moulage par procédé RTM.....	10
Figure I.4 : Procédé d'injection séquentielle de la résine dans la technologie RTM.....	10
Figure I.5 : Différents mécanismes d'endommagement.....	12
Figure I.6 : Exemple de courbe d'endurance (Wöhler).....	13
Figure I.7 : Divers types de sollicitations sinusoïdales.....	14
Figure I.8 : Allure des courbes d'endurance exprimées en fonction de la déformation.....	15
Figure I.9 : Courbe d'endurance S-N pour un composite carbone époxy de séquence [0/90 <sub>3</sub> /0].....	16
Figure I.10 : Régression par une ligne droite.....	18



**LISTE DES ABRÉVIATIONS, DES SIGLES ET DES ACRONYMES**

<b>ANN</b>	Artificial Neural Network
<b>BP</b>	Backpropagation
<b>CS</b>	Cuckoo Search
<b>DOE</b>	Department of Energy
<b>EP</b>	Epoxy
<b>GDM</b>	Gradient Descent avec Momentum
<b>IA</b>	Intelligence Artificielle
<b>LM</b>	Levenberg-Marquardt
<b>MD</b>	Multidirectionnel
<b>MSE</b>	Mean Square Error
<b>MSU</b>	Montana State University
<b>MLP</b>	Multilayer Perceptron
<b>OEP</b>	Optimisation par Essaim de Particules
<b>PSO</b>	Particle Swarm Optimization
<b>RTM</b>	Resin Transfer Molding
<b>RNA</b>	Réseau de Neurones Artificiels
<b>RP</b>	Rétropropagation
<b>UD</b>	Unidirectionnel
<b>UCS</b>	Ultimate Compressive Stress
<b>UTS</b>	Ultimate Tensile Stress
<b>UP</b>	Unsaturated Polyester
<b>VE</b>	Vinyl Ester



## LISTE DES SYMBOLES

<b><math>M_x</math></b>	<i>Moments de flexion par rapport aux axes x et y</i>
<b><math>M_{xy}</math></b>	<i>Moment de torsion</i>
<b><math>N_x</math></b>	<i>Efforts normaux par rapport aux axes x et y</i>
<b><math>N_{xy}</math></b>	<i>Effort de cisaillement</i>
<b><math>Q_x</math></b>	<i>Efforts de cisaillement transverse</i>
<b><math>\varepsilon_0</math></b>	<i>Déformation</i>
<b><math>\kappa</math></b>	<i>Coefficient de rigidité</i>
<b><math>S</math></b>	<i>Stress (Contrainte)</i>
<b><math>N</math></b>	<i>Nombre de cycles</i>
<b><math>N_R</math></b>	<i>Nombre de cycles à la rupture</i>
<b><math>R</math></b>	<i>Rapport de contrainte</i>
<b><math>\sigma_{max}</math></b>	<i>Contrainte maximale</i>
<b><math>\sigma_{min}</math></b>	<i>Contrainte minimale</i>
<b><math>\sigma_D</math></b>	<i>Limite d'endurance ou de fatigue</i>
<b><math>R_m</math></b>	<i>Résistance en traction</i>
<b><math>Log</math></b>	<i>Logarithme décimal</i>
<b><math>Abs</math></b>	<i>Valeur absolue</i>
<b><math>S_a</math></b>	<i>Amplitude de contrainte</i>
<b><math>w</math></b>	<i>Weight (poids)</i>
<b><math>b \ \theta</math></b>	<i>Bias (biais)</i>
<b><math>e \ i</math></b>	<i>Entrée (Input)</i>
<b><math>s \ out</math></b>	<i>Sortie (Output)</i>
<b><math>d</math></b>	<i>Désirée (desired)</i>

<b><math>net</math></b>	<i>Network</i>
<b><math>\alpha \ \eta</math></b>	<i>Taux d'apprentissage</i>
<b><math>W_e \ W_s</math></b>	<i>Matrice de poids synaptiques</i>
<b><math>g_{best}</math></b>	<i>Meilleur particule</i>
<b><math>l_{best}</math></b>	<i>Meilleur voisinage</i>
<b><math>t</math></b>	<i>Nombre d'itérations</i>
<b><math>p_i</math></b>	<i>Meilleur position</i>
<b><math>g_i</math></b>	<i>Meilleur position de voisinage</i>
<b><math>c \ r</math></b>	<i>Coefficients d'accélération</i>
<b><math>x_{ij}</math></b>	<i>Position d'une particule</i>
<b><math>\Delta T</math></b>	<i>Variation de température</i>
<b><math>\Delta m</math></b>	<i>Variation d'humidité</i>
<b><math>E</math></b>	<i>Cost function</i>
<b><math>V_{max}</math></b>	<i>Vélocité maximale</i>
<b><math>V_{min}</math></b>	<i>Vélocité minimale</i>
<b><math>j(W)</math></b>	<i>Fonction objective</i>
<b><math>\hat{y}</math></b>	<i>Sortie obtenue par RNA</i>
<b><math>y</math></b>	<i>Sortie désirée</i>

## CHAPITRE I

### INTRODUCTION GÉNÉRALE

#### I.1. MISE EN CONTEXTE ET PROBLEMATIQUE

La pale d'une éolienne est en réalité le véritable capteur de l'énergie présente dans le vent. De ses performances dépend la production d'énergie de l'installation, puis par conséquent l'intérêt économique de la machine. La conception d'une pale doit faire appel à un compromis délicat entre le rendement aérodynamique, la légèreté, la résistance statique et les conditions de vent (vitesses, taux de turbulence) qui influent sur la conception (charges extrêmes, tenue en fatigue) [1, 2].

On s'aperçoit donc aisément que la conception d'une pale est en fait un procédé itératif avec de nombreux paramètres et de nombreuses contraintes. Les matériaux utilisés actuellement pour la fabrication des pales d'éolienne sont des composites à base de polymères thermodurcissables. Ces derniers présentent une maturité technologique éprouvée et des facilités de mise en œuvre dans les étapes de fabrication (grande fluidité de la résine, bonne adhésion aux fibres de renfort du composite). Néanmoins, leurs performances mécaniques, en particulier la fatigue, sont limitées, et ces matériaux ne sont pas recyclables [3].

Les pales d'un aérogénérateur sont exposées, durant leur fonctionnement, à des chargements cycliques complexes dus à des conditions environnementales sévères et très variables, comme le cas des vents forts et des rafales qui engendrent des efforts extrêmes, favorisant ainsi la fatigue des pales. Cette fatigue est l'un des problèmes sérieux pouvant entraver le bon fonctionnement de l'éolienne [3].

Les réseaux de neurones artificiels (RNA) ont révélé être utile pour diverses applications d'ingénierie. En raison de leur structure massivement parallèle, ils peuvent faire face à de nombreux problèmes non linéaires et multivariables, pour lesquels une solution

analytique précise est difficile à obtenir. Les réseaux de neurones utilisés dans le cadre ce mémoire ont pour but de prédire la durée de vie en fatigue des matériaux composites des pales d'éoliennes sous l'effet de plusieurs facteurs (environnement, orientation de fibres...).

Ce travail de mémoire est réparti en trois chapitres. Dans le premier, un aperçu général sur la conception des pales d'éoliennes en matériaux composites, et de leur classification et leur constitution. Ensuite, une description du procédé de fabrication des pales d'éoliennes par le Moulage par Transfert de Résine « *Resin Transfer Molding (RTM)* ». Après toutes ces définitions, il est donc nécessaire de bien comprendre les mécanismes d'endommagement en fatigue et de savoir comment prendre en compte au mieux les différents facteurs dont dépend la fatigue des matériaux composites (la nature des fibres et des résines, du drapage, de la qualité des interfaces, etc.).

Les réseaux de neurones utilisés dans le deuxième chapitre sont employés pour prédire le comportement en fatigue (résistance et durée de vie) des matériaux composites destinés à la conception des pales d'éoliennes. La phase expérimentale sur ces matériaux a été réalisée par les laboratoires nationaux de SANDIA SNL (USA), et les données ont été collectées à partir d'une variété de leur base de données. Après plusieurs tests de topologie (architecture du réseau), algorithme d'apprentissage et d'entraînement, des fonctions d'activations, etc.; le choix s'arrête sur le réseau *feed-forward* à une seule couche cachée « *Tow-layer feed-forward neural network* » entraîné par la recherche coucou « *Cuckoo Search* »; c'est un algorithme méta-heuristique très récent, qui a été proposée en 2009 par Yang et Deb [4]. La recherche coucou s'inspire du comportement de reproduction d'une espèce spéciale d'oiseaux parasites de nids appelés « Coucous ».

Les travaux présentés dans le troisième chapitre portent sur l'utilisation de trois algorithmes méta-heuristiques en combinaison avec les RNA dans le but de les optimiser et d'avoir une meilleure prédition par rapport à l'effet hygrothermique. Les matériaux étudiés sont des composites thermodurcissables y compris des polyesters et vinylesters. Ce chapitre propose et compare également trois algorithmes, à savoir Back-Propagation (BP) Levenberg Marquardt, Particle Swarm Optimization (PSO) et Cuckoo Search (CS) en combinaison avec

le populaire *Feed-forward Neural Network* (FNN) pour la prédition de la durée de vie en fatigue des pales d'éoliennes. Ces nouvelles combinaisons ont été utilisées dans l'entraînement de la base de données SNL (SNL / MSU, 2016). Tous ces matériaux étudiés sont utilisés pour la fabrication des pales d'éoliennes par la plupart des fabricants, propriétaires et entrepreneurs d'éoliennes.

## I.2. OBJECTIFS & METHODOLOGIE

- Objectif général : Prédire la durée de vie ainsi que la tenue en fatigue des composites des pales d'éolienne par le biais des méthodes d'intelligence artificielle dans le cadre de la mise en œuvre d'une stratégie de maintenance prédictive.
- Objectif spécifique 1 : L'utilisation des réseaux de neurones artificiels dans la prédition de la durée de vie restante ainsi que du comportement en fatigue des matériaux composites utilisés dans la conception des pales d'éoliennes.
- Objectif spécifique 2 : Explorer et traiter les données liées à la fatigue des pales d'éoliennes à l'aide d'un logiciel d'exploration de données « *Data mining* ».
- Objectif spécifique 3 : Entrainer et ajuster les poids synaptiques du réseau de neurones avec des différents algorithmes métaheuristiques afin d'obtenir la meilleur prédition de la durée de vie en fatigue des pales d'éoliennes ; les algorithmes en question sont : La rétropropagation du gradient, l'optimisation par essaims particulaires et la recherche coucou.
- Objectif spécifique 4 : Faire une comparaison entre les stratifiés composites unidirectionnels et multidirectionnels en terme de la résistance à la fatigue.
- Objectif spécifique 5 : Quantifier l'effet hygrothermique (l'influence de la température et de l'humidité) sur le comportement en fatigue des matériaux composites.

### I.3. PALES EN MATERIAUX COMPOSITES

Dans l'industrie moderne de fabrication des pales d'éoliennes, les matériaux composites à base de fibres occupent une place prépondérante, car ils présentent des avantages résidant principalement dans les bonnes caractéristiques mécaniques, thermiques et hygrométriques associées aux exigences de légèreté, de coût et de meilleure durée de vie [5]. En plus de ces critères techniques, s'ajoute l'imposition d'une méthode de fabrication sûre et respectueuse de l'environnement et de la santé.

Un matériau composite peut être défini comme une combinaison d'au moins deux matériaux différents à l'échelle macroscopique. Les composites utilisés pour leurs propriétés structurales se limitent à ceux qui contiennent des renforts réunis en une seule masse par une matrice [6]. Typiquement, un matériau composite contient une phase discontinue de renfort plus rigide et plus résistante que la phase continue de la matrice.

#### I.3.1. CLASSIFICATION DES MATERIAUX COMPOSITES

La classification des composites peut être effectuée selon diverses façons. Une manière simple consiste à les classer par les formes des renforts. Les composites sont donc divisés en quatre catégories (figure I.1) [7] :

- **Composites à renforts de particules :** Le renfort est considéré comme une particule si toutes ses dimensions sont approximativement égales et petites devant les autres dimensions du matériau. Les particules dures sont dispersées aléatoirement dans la matrice moins rigide.

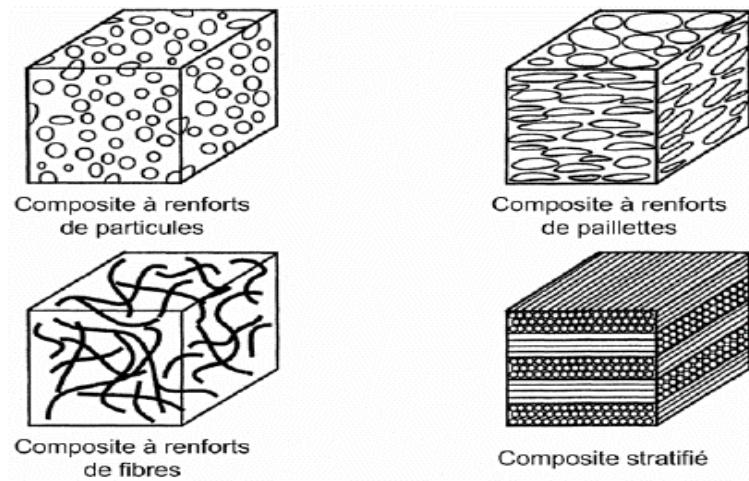


Figure I.1 : Classification des matériaux composites [7]

- **Composites à renforts de paillettes** : Les paillettes ont une dimension très faible par rapport aux autres. La dispersion de ces « particules minces » est généralement aléatoire. Cependant, les paillettes peuvent être rangées parallèlement l'une à l'autre afin d'avoir des propriétés plus uniformes dans le plan.
- **Composites à renforts de fibres** : Une fibre a une longueur bien supérieure aux dimensions de la section transversale. Ce type de composites peut être divisé selon les renforts : en fibres discontinues (courtes) ou fibres continues (longues).
- **Composites stratifiés** : Un stratifié se compose d'au moins deux couches minces de matériau. Les couches peuvent être constituées de différents matériaux monolithiques comme dans les métaux plaqués ou du même matériau composite empilé selon différentes orientations comme pour des stratifiés composites à renforts de fibres longues. Ce dernier devient une classe hybride du composite comportant à la fois le composite à renfort de fibres et la technique de stratification.

### I.3.2. CONSTITUANTS DES MATERIAUX COMPOSITES

Dans la suite de la présentation, nous nous intéresserons uniquement aux composites à renfort de fibres longues et stratifiés utilisés, couramment rencontrés dans l'industrie

éolienne. Ces matériaux seront parfois appelés «composites fibreux» ou même «composites» par simplicité.

Les propriétés mécaniques des composites fibreux sont directement liées aux caractéristiques mécaniques de leurs constituants : la fibre, la matrice, ainsi que l'interphase. La résistance et la rigidité d'un composite sont assurées principalement par les fibres qui possèdent des caractéristiques mécaniques beaucoup plus élevées que la matrice. Cette dernière, quant à elle, réunit les fibres et donne la forme géométrique de la structure. La matrice sert également à transférer les efforts mécaniques entre les fibres et les protéger contre l'environnement. L'interphase est la zone créée par l'adhérence et la réaction entre les fibres et la matrice [7]. Elle possède des caractéristiques chimiques et mécaniques différentes de celles des fibres et de la matrice. La disponibilité d'un grand choix de fibres et de matrices permet de réaliser des composites ayant diverses propriétés. Nous présenterons rapidement quelques-uns des constituants les plus couramment utilisés [8, 9].

### I.3.2.1. LES FIBRES

La rupture des matériaux à hautes résistances ou à hauts modules de Young est généralement provoquée par la propagation des défauts. Les matériaux en forme de fibre sont intrinsèquement plus résistants à la rupture qu'en forme massive, car la taille des défauts est limitée par le diamètre faible. Dans un composite fibreux, la tenue mécanique est assurée principalement par les fibres. Par sa nature filamenteuse, la rupture de quelques fibres a pour résultat la redistribution du chargement sur les autres fibres, ce qui empêche la rupture catastrophique de la structure. Les fibres les plus souvent rencontrées dans les composites sont les suivantes [7] :

- **Fibres de carbone :** Actuellement, les fibres de carbone sont le renfort le plus répandu pour les matériaux composites hautes performances. Deux avantages principaux de ces fibres sont leur fabrication plus adaptée à la production à grande échelle que d'autres fibres hautes performances et leurs excellentes propriétés

mécaniques plus facilement transférables aux matériaux composites. Leur prix reste toutefois prohibitif pour les produits grand public.

- **Fibres de verre :** La connaissance des matériaux composites fibreux à matrice de polymères est initialement basée sur des études des composites à fibres de verre. Ces fibres sont très répandues dans des applications basses performances ainsi que des applications hautes performances telles que les réservoirs de propulseurs de fusée. Leurs avantages incluent le prix compétitif, la disponibilité, et la résistance élevée. Cependant, à cause de leur rigidité relativement faible, les fibres de verre sont progressivement remplacées par les fibres aramides ou les fibres de carbone dans les applications hautes performances.

### I.3.2.2. LES MATRICES

La matrice réunit les fibres par ses propriétés cohésive et adhésive. Elle maintient les fibres dans leur orientation et leur position prévue pour supporter les charges appliquées. Ses autres rôles consistent à distribuer les efforts entre les fibres, fournir une résistance à la propagation de fissure, et fournir la résistance en cisaillement du composite. La matrice détermine en général la limite de la température d'utilisation et l'environnement de service du matériau.

Il existe un grand nombre de polymères pouvant servir de matrice aux matériaux composites. Ceux parmi les plus utilisés sont les suivants [8] :

➤ **Les thermodurcissables :**

- **Les résines polyesters insaturées (UP)** peu onéreuses qui sont généralement utilisées avec les fibres de verre et que l'on retrouve dans de nombreuses applications de la vie courante ;

- **Les résines époxy (EP)** qui possèdent de bonnes caractéristiques mécaniques. Elles sont généralement utilisées avec les fibres de carbone pour la réalisation de pièces de structure et d'aéronautique ;
- **Les résines vinylester (VE)** sont surtout utilisées pour des applications où les résines polyester ne sont pas suffisantes. Elle est issue d'une modification d'une résine époxyde et est excellente pour des applications de résistance chimique ;
- **Les résines phénoliques (PF)** utilisées dans les applications nécessitant des propriétés de tenue aux feux et flammes imposées par les normes dans les transports civils ;
- **Les résines polyimides thermodurcissables (PIRP)** pour des applications à haute température ( $\sim 300$  °C) et polybismaleimides (BMI) pour des applications à température intermédiaire ( $\sim 225$  °C).

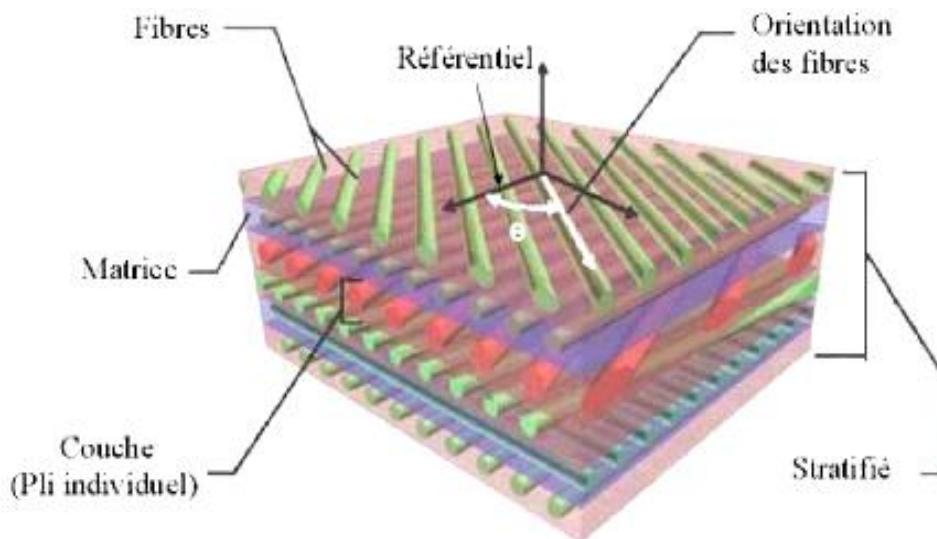


Figure I.2 : Constituants d'un matériau composite stratifié

- **Les thermoplastiques** comme le polypropylène ou le polyamide ou comme le polyéther imide (PEI), le sulfure de polyphénylène (PPS) et la polyétheréthercétone (PEEK) sont pour la réalisation de pièces de structure et d'aéronautique.

### I. 3.2.2. L'INTERPHASE

La nature de l'adhésion fibre/matrice inclut le verrouillage mécanique, l'attraction électrostatique, l'enchevêtrement moléculaire, et la réaction chimique. L'interphase est constituée de la surface de contact (interface) fibre/matrice ainsi que de la région d'un volume fini prolongée dans la matrice. Elle peut être considérée comme un constituant du composite, car elle possède des propriétés chimiques, physiques, et mécaniques différentes de celles de la fibre et de la matrice [7]. L'interphase assure la liaison fibre/matrice et permet le transfert des contraintes de l'une à l'autre sans déplacement relatif. Cependant, l'hypothèse que l'interphase n'a pas d'épaisseur est souvent faite pour faciliter l'analyse micromécanique des composites.

### I.4. PROCEDE DE FABRICATION DES PALES D'EOLIENNES

Le procédé traditionnel exploité actuellement pour la fabrication des pales d'éolienne est caractérisé principalement par une opération d'assemblage de demi-coquilles par un joint de collage. Cette technique de collage est susceptible de poser des problèmes de résistance mécanique au cours du temps. Alternativement, le procédé de moulage par transfert de résine (Resin Transfer Molding RTM) vient positivement pallier cette problématique.

Il présente une solution industrielle à la production des pales d'éoliennes avec une excellente qualité de finition, de meilleures caractéristiques mécaniques, un faible coût et une cadence de production modeste [10].

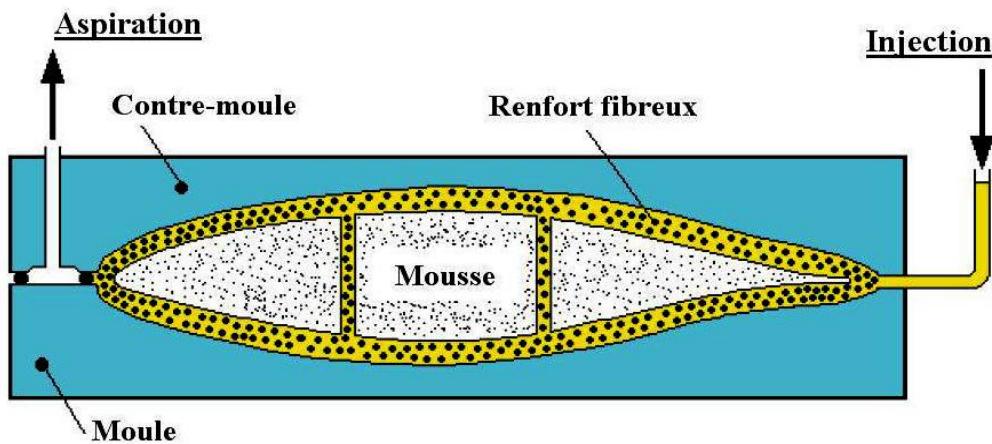


Fig. I.3 : Coupe transversale d'un profil de pale sous moulage par procédé RTM [3].

En outre, il participe à la réduction des quantités d'émission de Composés Organiques Volatils (COV), tels que le styrène. La figure (I.3) illustre la technologie RTM light appliquée au profil d'une pale d'éolienne.

En ce qui concerne les grandes pales d'éoliennes, l'injection se fera d'une manière séquentielle. Les points d'injection sont situés sur le bord de fuite, les points d'aspiration, par contre, sont situés sur le bord d'attaque. La figure (I.4) schématisise la méthode d'injection séquentielle, et ce, en commençant par le pied de pale (partie travaillante et fortement sollicitée).

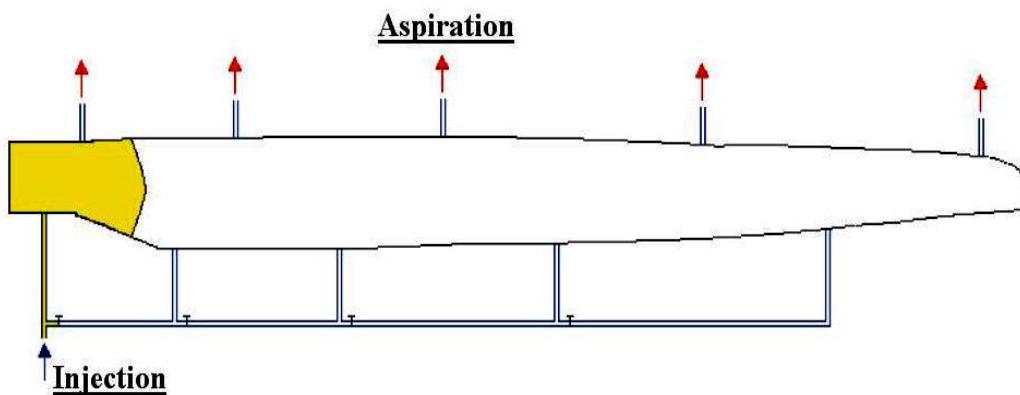


Figure I.4 : Procédé d'injection séquentielle de la résine dans la technologie RTM [3].

## I.4. FATIGUE DES PALES D'EOLIENNE

Lors de son service, la pale est sujette à des problèmes de variation de contraintes d'un cycle à un autre. Cette variation peut avoir pour conséquence une dégradation de la résistance structurale à travers les phénomènes d'accumulation de contraintes et de fatigue.

Cependant, un certain nombre d'échantillons (tronçons) doit être réalisé conformément aux principes de construction de la pale. Ces échantillons seront ensuite testés à un niveau suffisant jusqu'à rupture sous un chargement alterné. Un banc d'essai et des jauge de déformation pour effectuer de tels essais sont nécessaires. Les résultats expérimentaux obtenus permettront de chiffrer la durée de vie de la pale avec un degré de confiance suffisamment admissible. En moyenne, cette durée de vie est estimée à 20 ans [3, 5, 10].

Il est donc nécessaire de bien comprendre les mécanismes d'endommagent en fatigue, et de savoir comment prendre en compte au mieux les différents facteurs dont dépend la fatigue des matériaux composites (la nature des fibres et des résines, du drapage, de la qualité des interfaces...).

### I.4.1. ENDOMMAGEMENT EN FATIGUE

La fatigue est un processus (succession de mécanismes) qui sous l'action de contraintes ou déformations variables dans le temps modifie les propriétés locales d'un matériau. Ces dernières peuvent entraîner la formation de fissures et éventuellement la rupture de la structure. La fatigue est notamment caractérisée par une étendue de variation de contrainte qui peut être bien inférieure à la limite d'élasticité du matériau. Les étapes principales de la ruine par fatigue d'un assemblage sont l'amorçage de fissures (si des défauts ne sont pas déjà présents dans le matériau), la propagation de fissures et la rupture finale [9].

Les paramètres souvent utilisés pour prédire le comportement en fatigue et ainsi le nombre de cycles à la rupture d'une structure sont : l'amplitude de la sollicitation

(chargement ou déformation imposée), sa valeur moyenne, l'état de surface et le milieu dans lequel la structure sera utilisée.

Même si l'étude de la fatigue s'appuie sur des considérations théoriques (en particulier mécanique de la rupture), c'est essentiellement un domaine expérimental. La caractérisation d'un matériau, d'une pièce, d'un ensemble, d'une structure, etc. nécessite de nombreux essais et mesures.

#### I.4.2. MECANISMES D'ENDOMMAGEMENT EN FATIGUE

La ruine des matériaux composites n'est pas initiée par un unique mécanisme d'endommagement, mais elle est la conséquence de l'accumulation de plusieurs modes de dégradations. En effet, par endommagement on entend le développement plus ou moins progressif de micro-défauts (micro-vides, microfissures, etc.) qui conduisent par coalescence à des macro-défauts (fissures, décohésions, etc.) menant ainsi à la ruine de la structure [11].

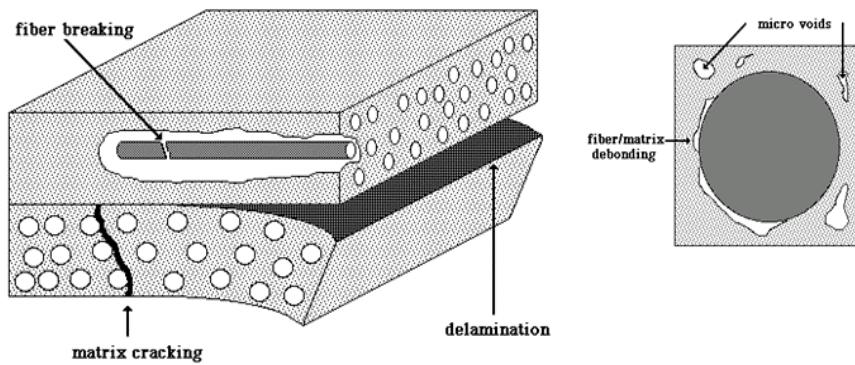


Figure I.5 : Différents mécanismes d'endommagement [7]

Les mécanismes d'endommagement dans les composites stratifiés à fibres longues sont aujourd'hui clairement identifiés. Différents facteurs peuvent influencer l'apparition et le développement de ces dégradations : la séquence d'empilement (ply-orientations) [7], la nature de la matrice, le procédé de fabrication, etc. Ainsi, soumis à des sollicitations externes, les matériaux composites sont le siège de dégradations au niveau des fibres (ruptures de fibres), de la matrice (micro-vides, fissures intra-laminaires) ou encore au niveau des

interfaces fibre/matrice (décohésions fibre/matrice) ou des interfaces inter-plis (délaminage). La figure (I.5) présente de façon schématique les différents mécanismes d'endommagement en fatigue.

#### I.4.3 PREDICTION DE LA DUREE DE VIE EN FATIGUE

L'utilisation croissante des matériaux composites à hautes performances tient sans doute à leur résistance exceptionnelle à la fatigue. Encore plus légers que les alliages d'aluminium, ils sont nettement meilleurs que ces derniers lorsqu'ils sont soumis à des sollicitations cycliques. Comme critère, on a l'habitude d'évaluer le rapport ( $\sigma_D/R_m$ ) de la limite d'endurance (ou limite de fatigue)  $\sigma_D$  à la résistance en traction  $R_m$  [11, 12].

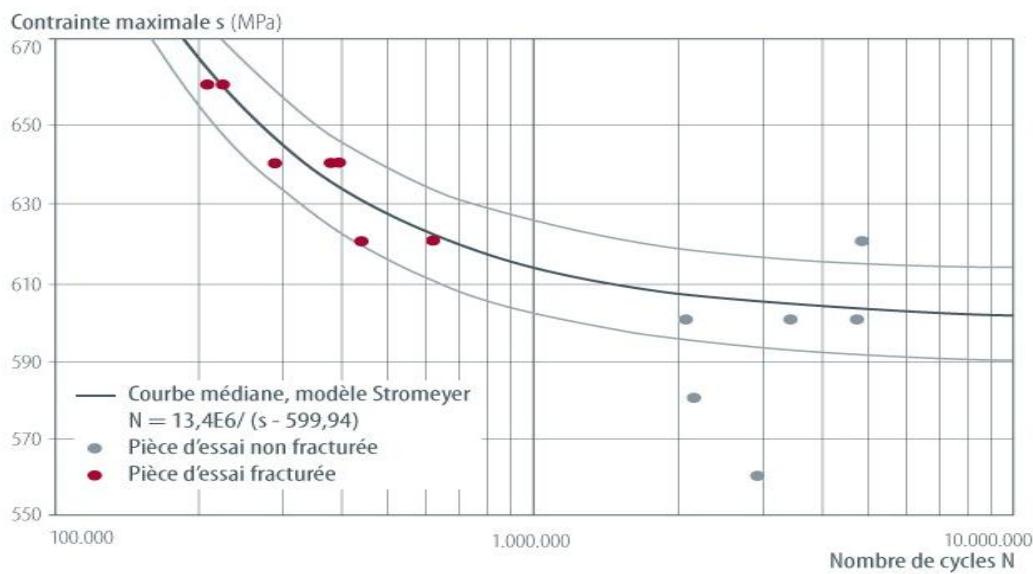


Figure I.6 : Exemple de courbe d'endurance (Wöhler) [11]

Le critère le plus utilisé pour évaluer la durée de vie des matériaux est celui de la courbe d'endurance ou de Wöhler  $S - N$  (Stress-Number of cycles). Le principe en est simple, il s'agit de reporter les sollicitations appliquées (contraintes, déformations, amplitude des contraintes ou des déformations) en fonction du nombre de cycles à la rupture du matériau sollicité. Cette courbe définit une relation entre la contrainte appliquée  $\sigma$  (sigma parfois notée

$S$ ) et le nombre de cycles à la rupture  $N_R$  (en fait nombre de cycles pour lequel on observe  $P\%$  de ruptures) [11].

Pour la tracer, on réalise généralement des essais simples qui consistent à soumettre chaque éprouvette à des cycles d'efforts périodiques, d'amplitude de chargement constante  $S_a$  fluctuant autour d'une valeur moyenne fixée et à noter le nombre de cycles au bout duquel l'amorçage d'une fissure est observé, appelé ici nombre de cycles à rupture  $N_R$  ; ceci est fait pour plusieurs valeurs de l'amplitude alternée  $S_a$  et de  $R$  ; le rapport de charge  $R$  est le rapport de la contrainte minimum à la contrainte maximum du cycle périodique ( $R = \sigma_{min}/\sigma_{max}$ ). Pour plus de commodité, ce nombre  $N_R$  est reporté en abscisse sur une échelle logarithmique, et l'amplitude de contrainte  $S_a$  est reportée en ordonnée sur une échelle linéaire ou logarithmique pour plusieurs valeurs de  $R$ .  $R = -1$  correspond à un cycle symétrique alterné,  $R = 0$  correspond à un cycle répété,  $R > 0$  correspond à des contraintes ondulées [13].

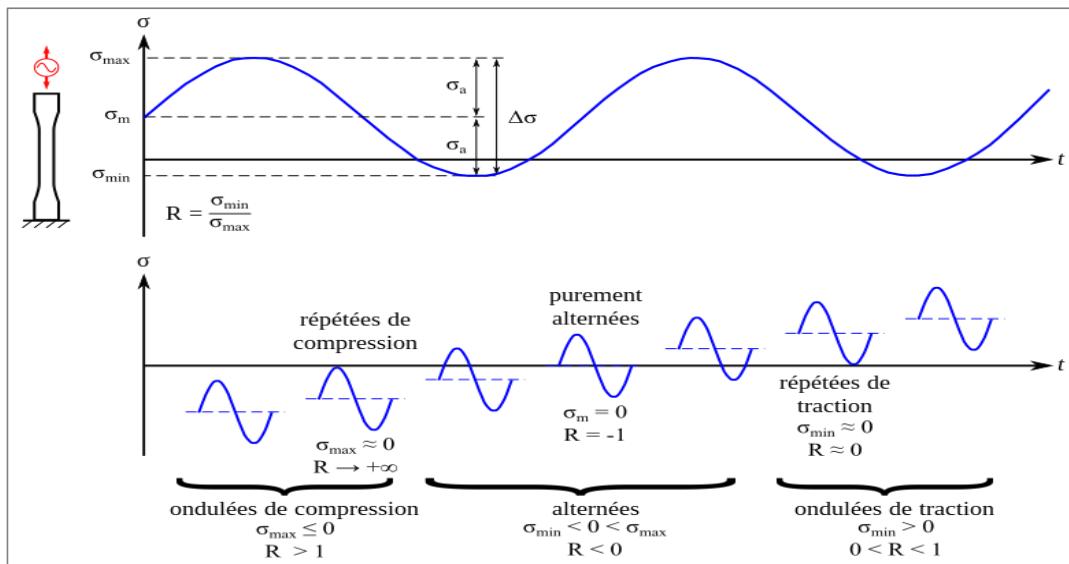


Figure I.7 : Divers types de sollicitations sinusoïdales [13]

Lorsque la plasticité est généralisée, la durée de vie en fatigue caractérisée par le nombre de cycles à la rupture  $N_f$  de l'échantillon est donnée par les relations de Manson-Coffin et Basquin (figure I.8) [11] :

$$\Delta\varepsilon_e/2 + \Delta\varepsilon_p/2 = \alpha(2N_f)^b + \beta(2N_f)^c \quad (1.1)$$

Avec :  $\alpha$ ,  $\beta$ ,  $b$  et  $c$  paramètres déterminés par l'expérience ;

$\varepsilon_e$ ,  $\varepsilon_p$  et  $\varepsilon_t$  déformations élastiques, plastiques et totales.

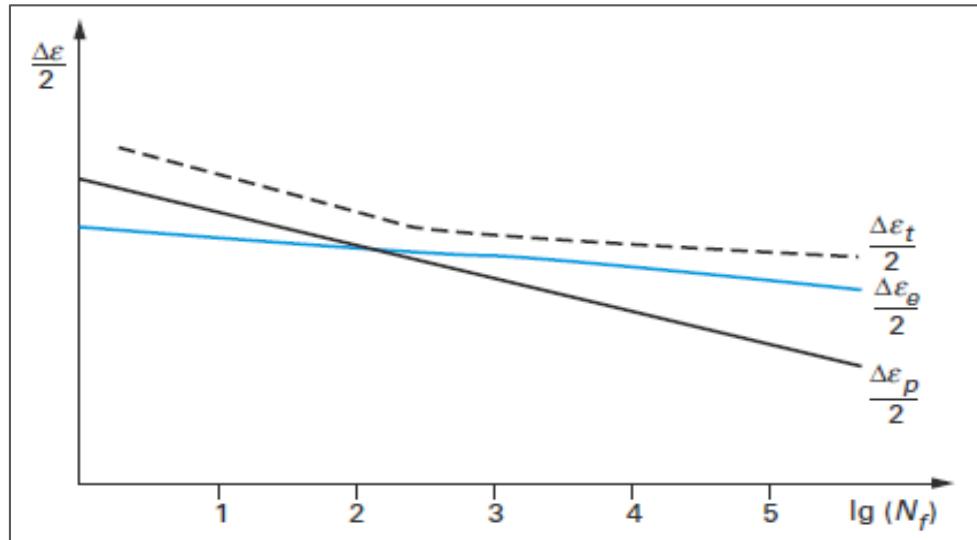


Figure I.8 : Allure des courbes d'endurance exprimées en fonction de la déformation

Pour les métaux, la concavité de la courbe d'endurance est attribuée à la plasticité. Pour les matériaux composites, dont le comportement monotone est quasi linéaire (absence notable de plasticité), en coordonnées logarithmiques l'allure de la courbe est assez plate. Considérant  $\Delta\varepsilon_p$  négligeable, la durée de vie peut alors s'exprimer par la relation simplifiée:

$$\Delta\varepsilon_e/2 = (2N_f)^b \quad (1.2)$$

Ce type de courbe d'endurance est généralement assez bien vérifié pour les matériaux composites unidirectionnels à hautes performances (figure I.9), que la durée de vie soit exprimée en fonction de l'amplitude de la déformation ou de celle de la contrainte appliquée. Pour les composites stratifiés à plis croisés, l'allure de la courbe dépend de l'orientation du drapage. Toutefois, la courbe d'endurance reste encore assez plate comparée à celle obtenue

pour des matériaux métalliques. Il apparaît qu'une fonction logarithmique permet de représenter le phénomène en première approximation [11, 12] :

$$\log \sigma_D = \log F - \frac{1}{m} \log N_f \quad (1.3)$$

Avec :  $\sigma_D$  Limite d'endurance ;

$F$  et  $m$  paramètres dépendant du matériau

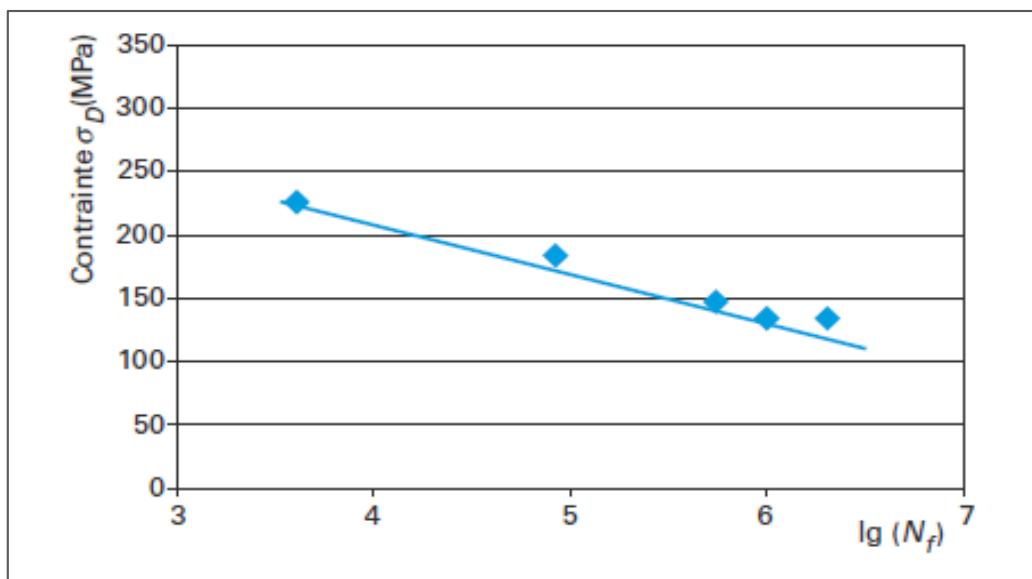


Figure I.9 : Courbe d'endurance S-N pour un composite carbone époxy de séquence  
[0/90<sub>3</sub>/0]

Les résultats précédents amènent cependant quelques réflexions. Si les courbes d'endurance ou le rapport ( $\sigma_D/R_m$ ) font figure de caractéristiques intrinsèques pour les matériaux métalliques homogènes et isotropes, c'est plus difficilement le cas pour les matériaux composites qui par conception ne sont plus vraiment des matériaux, mais déjà des structures. En face du mot rupture, il convient d'associer des modes de dégradations qui comme nous l'avons vu précédemment peuvent intervenir dans les plis et aux interfaces. Les limites de fatigue et d'endurance varient avec les constituantes fibres et matrice, les orientations et les épaisseurs des plis.

De même la viscosité ou la ductilité de la matrice sont des facteurs importants dans les processus de fatigue. Pour les stratifiés croisés, une plus grande ductilité matricielle donne des limites d'endurance supérieures.

Un autre facteur important pour bien comprendre les modes de ruine en fatigue, est l'état local des contraintes, engendré par la sollicitation appliquée.

Si les matériaux composites ont de bonnes performances en traction cyclée comparés aux matériaux métalliques, ils s'endommagent beaucoup plus sévèrement que les métaux sous des sollicitations de compression ou de cisaillement. Il en résulte qu'au cours d'une flexion cyclique un matériau composite peut s'endommager à la fois en traction, en compression et en cisaillement, ce qui rend l'analyse complexe.

## I.5. PREDICTION NUMERIQUE

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 en 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, l'intelligence en essaim, etc.) peuvent être adaptées pour la prédiction [14]. Dans cette section, nous présentons la technique de régression linéaire 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.

### I.5.1. REGRESSION LINEAIRE

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  $x$  :

$$y = b + wx \quad (1.4)$$

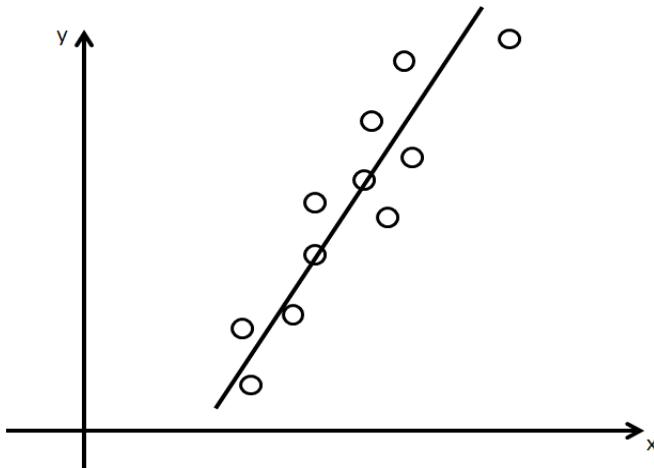


Figure I.10 : Régression par une ligne droite [14]

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 I.10). Les coefficients de régression  $w$  et  $b$  peuvent également être considérés comme des poids et des biais. Nous pouvons alors écrire de façon équivalente :

$$y = w_0 + w_1x \quad (1.5)$$

Ces coefficients peuvent être calculés par la méthode des moindres carrés qui estime les coefficients  $w_0$  et  $w_1$  comme ceux qui minimisent l'erreur entre les données réelles et la droite modèle.

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 :

$$w_1 = \frac{\sum_{i=1}^D (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^D (x_i - \bar{x})^2} \quad (1.6)$$

Et

$$w_0 = \bar{y} - w_1 \bar{x} \quad (1.7)$$

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 :

$$y = w_0 + w_1 x_1 + w_2 x_2 \quad (1.8)$$

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.

## **CHAPITRE II**

### **RESEAU DE NEURONES BASE SUR LA RECHERCHE COUCOU POUR PREDIRE LA DUREE DE VIE EN FATIGUE DES COMPOSITES DES PALES D'EOLIENNES**

#### **II.1 RESUME EN FRANÇAIS DU PREMIER ARTICLE**

Dans l'industrie moderne de fabrication des pales d'éoliennes, les composites à base de fibres sont principalement utilisés et ce, pour leurs bonnes caractéristiques mécaniques : rigidité élevée, faible densité et longue durée de vie en fatigue. Les pales d'éoliennes sont généralement construites d'une variété de composites stratifiés, comprenant souvent des laminés unidirectionnels (UD) dans les espars, et plusieurs formes de renforcement multidirectionnel (MD) telles que des tissus biaxiaux et triaxiaux dans les peaux et les toiles. Chaque type de stratifiés peut avoir une sensibilité significative à la fatigue en fonction de leurs composants : la fibre, la résine, le type et la direction de chargement. Le but de cet article est d'identifier les matériaux qui ont des orientations de fibres appropriées pour améliorer la durée de vie en fatigue des pales. En utilisant un réseau de neurones artificiels basé sur la recherche de coucou (CSNN), nous avons pu développer un modèle capable de prédire la durée de vie en fatigue sous des charges cycliques tension-tension pour cinq matériaux composites, avec différentes séquences d'empilage de fibres immergées dans trois types de matrices de résine (époxy, polyester et vinylester), qui conviennent tous à la conception des pales d'éoliennes. Dans l'approche CSNN utilisée dans ce travail, la fonction objective a été évaluée en utilisant l'erreur quadratique moyenne (MSE) calculée comme la différence au carré entre les valeurs prédictives et les valeurs désirées. Ce travail vise également à utiliser cette nouvelle combinaison (réseau neuronal basé sur la recherche coucou CSNN) dans l'entraînement de la base de données SNL/MSU, qui a été réalisée par les laboratoires nationaux de SANDIA (SNL) en collaboration avec l'université de Montana (MSU). L'ensemble de données que nous avons utilisé est collecté à partir de leur vaste base de données publique, dans le but d'effectuer une analyse comparative entre les matériaux

unidirectionnels et multidirectionnels, en termes de durée de vie en fatigue. Les composites à base de fibres de verre E (Electric Fiber) et de polymères thermodurcissables étaient le choix le plus approprié pour notre étude, en raison de leur utilisation par la plupart des fabricants, propriétaires et entrepreneurs d'éoliennes. Cette base de données est la dernière d'une série de tests que SNL a publiés au fil des ans. La nouveauté de notre travail est qu'il applique CSNN sur ces données récemment publiées et crée un modèle capable de prédire la durée de vie en fatigue de différents matériaux composites MD/UD. Ce modèle pourrait être utilisé à l'avenir comme une alternative aux tests de laboratoire coûteux, ainsi que pour valider de nouveaux résultats expérimentaux. Les résultats obtenus illustrent que le CSNN peut fournir une prévision précise de la durée de vie en fatigue pour différents stratifiés composites MD/UD, sous différents angles d'orientation des fibres.

Mots clés – Pale d'éolienne, Durée de vie en fatigue, Matériaux composites, Réseau de neurones artificiels, Recherche coucou.

Ce premier article, intitulé « *A cuckoo search based neural network to predict fatigue life in rotor blade composites* », fut corédigé par moi-même ainsi que par le Professeur Adrian Ilinca, Dr. Abdullah Khan et le professeure Soraya Zebirate. Il fut accepté pour publication dans sa version finale en Mars 2020 par les éditeurs de la revue *Journal of Mechanical Engineering and Sciences JMES* sous le volume 14 N° 1.

Ziane, K., Ilinca, A., Khan, A., & Zebirate, S. (2020). A cuckoo search based neural network to predict fatigue life in rotor blade composites. *Journal of Mechanical Engineering and Sciences, 14(1)*, 6430 - 6442. <https://doi.org/10.15282/jmes.14.1.2020.18.0503>

## II.2 A CUCKOO SEARCH BASED NEURAL NETWORK TO PREDICT FATIGUE LIFE IN ROTOR BLADE COMPOSITES

### ABSTRACT

In modern wind turbine blades industry, fiber-reinforced composites are mostly used for their good mechanical characteristics: high stiffness, low density and long fatigue life. Wind turbine blades are constructed in different structural elements from a variety of composite laminates, often including unidirectional (UD) material in spars and multiple forms of multidirectional (MD) in skins and webs. The purpose of this paper is to identify materials that have appropriate fiber orientations to improve fatigue life. By using cuckoo search-based neural network (CSNN), we have developed a model to predict fatigue life under tension-tension charges for five composite materials, with different fiber stacking sequences embedded in three types of resin matrices (epoxy, polyester and vinylester), which are all appropriate for the design of wind turbine blades. In the CSNN approach used in this work, the cost function was assessed using the mean square error (MSE) computed as the squared difference between the predicted values and the target values for a number of training set samples, obtained from an experimental fatigue database. The results illustrate that the CSNN can provide accurate fatigue life prediction for different MD/UD composite laminates, under different angles of fiber orientation.

**Keywords:** Wind turbine blades; composite materials; fiber orientation; fatigue life prediction; cuckoo search; neural network.

### INTRODUCTION

As the blade is the most important component within wind turbines in capturing energy, it must be designed structurally strong to support the different loads to which it may be exposed. The design of the wind turbine depends heavily on the materials of the blade, which must have a high stiffness, low density and long fatigue life properties [1]. The class of materials that have met these requirements best has been fiber-reinforced composites using mostly glass or carbon. The glass fiber-reinforced plastic (GFRP) composites are generally characterized by good static and fatigue mechanical properties combined with low-cost components and fabrication processes [2], which can extend the lifetime of the turbine blades.

Wind turbine blades are typically made from E-glass fibers (for its high electric resistance), which are used as main reinforcement in the composites [3]. A low-cost glass fiber grade combining high strength (2 GPa) and moderate stiffness (76 GPa) are used together with a thermoset polymer matrix such as epoxy, polyester or vinylester [3]. Sandwich constructions, consisting of multiaxial composite laminates, together with balsa wood or polyvinyl chloride (PVC) foam, are used for the outer shell and for the shear webs in the blades, as shown in Figure 1.

The wind turbine blades are manufactured in separate structural components using a range of composite laminate kinds, often including unidirectional (UD) material in spars and several forms of multidirectional (MD) reinforcement, such as biaxial and triaxial fabrics in skins and webs (see Figure 1). Depending on the component fibers, resin, type and direction of loading, each may have a substantial sensitivity to fatigue [5].

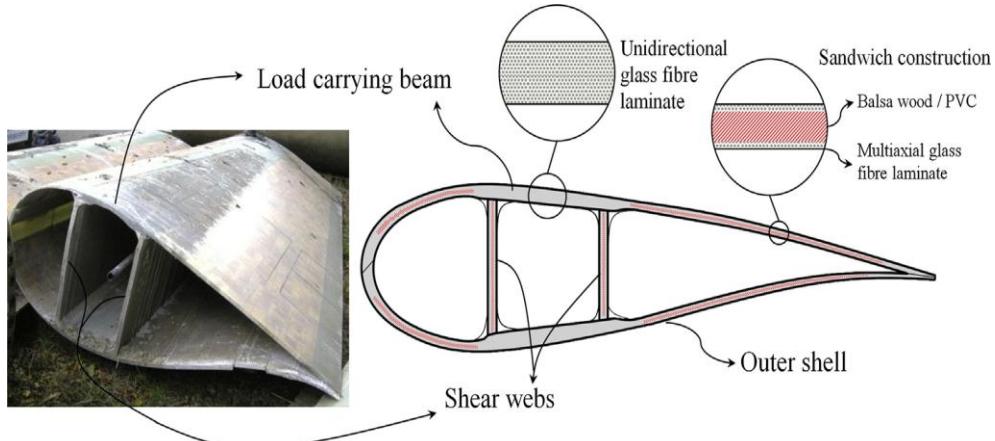


Figure 1. Typical cross-section of rotor blade [4]

To determine safety factors more precisely, detailed information about the effects of different loading conditions (extreme winds, moisture, temperature variations, etc.) and the microstructure parameters of wind blade composites (such as fiber sizing, orientation, nanoscale-engineered matrix, etc.) on their strength and lifetime is required [3]. The lifetime and strength prediction analysis of these parameters are among the important tasks to improve the reliability and performance of the wind turbine rotor blades. In addition, predicting the fatigue conduct of these subcomponents could be the first step towards anticipating the general conduct of laminates under cyclic loading, which can be considered as a way of preventing the failure of our blades. In this perspective, artificial neural networks (ANN) are a very common tool for applications that require data processing for predictive purposes, due to their massively parallel structure. ANN can also deal with many multivariable nonlinear problems for which an accurate analytical solution is difficult to obtain [6].

One of the most common neural network architectures is feedforward neural network (FNN), which has been mainly used due to their well-known universal approximation capabilities. Feedforward means that the signal (dataset) flows in one direction, from the input to the output layer (forward) through one or more hidden layers. This topology allows inserting and combining some types of algorithms in weight training instead of the backpropagation (BP) algorithm and Levenberg Marquardt (LM), which are integrated by default in certain software; these are gradient-based techniques. Currently, there have been many algorithms used to learn and optimize the FNN, among them we can mention: genetic algorithms (GA), particle swarm optimization (PSO), cuckoo search algorithms (CS), and so on.

The power of almost all modern metaheuristics comes from the fact that they imitate the best feature in nature, especially biological systems evolved from natural selection over

millions of years [7]. Cuckoo search (CS) is one of the latest nature-inspired metaheuristic algorithms proposed by Xin-Shen Yang [7] for solving optimization problems. CS is based on the brood parasitism of some cuckoo species. In addition, this algorithm is enhanced by the so-called Lévy flights, rather than by simple isotropic random walks [8]. Recent studies show that CS is potentially far more efficient than PSO and GA [8]. In particular, CS can be modified to provide a relatively high convergence rate to the true global minimum [9].

This work aims to use this new combination (cuckoo search-based neural network CSNN) in the training of SNL/MSU database [10], which was developed by the Sandia National Laboratories (SNL) in collaboration with Montana State University (MSU). The dataset we used is collected from their large public database, for the purpose of performing comparative analysis between unidirectional and multidirectional materials, in terms of fatigue life. The studied materials are all intended for the design of wind turbine blades. The GFRP composites from E-glass fibers and thermoset polymers were the most suitable choice for our analysis, because of their use by the most of wind turbine manufacturers, owners and contractors.

This database is the latest of a series of tests that the SNL have been publishing over the years. The novelty of our work is that it applies CSNN on this newly published data and creates a model that is capable of predicting the fatigue life of different MD/UD composite materials. This model could be used in the future as an alternative to the costly lab tests, as well as to validate new experimental results.

The materials of wind turbine blades and their fatigue tests have attracted attention of many researchers and the academic community in general. However, our research and literature review did not find any studies about the application of artificial intelligence methods on the prediction of fatigue behavior of wind turbine blades materials. The most representative results of using Google search engine with the keywords “artificial intelligence in fatigue life prediction of wind turbine materials” are the works we published earlier [11, 12]. In what follows, we will discuss some studies relevant to this work.

Artificial neural networks (ANN) have been previously used by Ziane et al. [11, 12] to predict the fatigue strength of different composite materials, intended for the design of wind turbine blades, under tension-tension and compression-compression loadings. A backpropagation and particle swarm optimization were used as training algorithms. They had reached the conclusion that the size of the database represents a challenge to the traditional regression, hence the need for an artificial intelligence method that models the problem. Indeed, this work is based on a portion of their data used with the PSO [11], in order to improve the results already found.

Al-Assadi et al. [6, 13] stated that ANN have already been used in modeling the static and cyclic behavior of composites, controlling the manufacturing parameters used in their machining and/or predicting their wear properties. These ANN offer an accurate and cost-effective approach for modeling fatigue life, and are employed as a black box rendering the knowledge of its internal behavior unnecessary to most users.

Carbon fiber and glass fiber-reinforced composites have been used by Mathur et al. [14] to evaluate the performance of ANN in predicting the fatigue lives of laminates under different lay-up. They showed that the prediction of fatigue lives of composite material is affected by various factors such as stress amplitude, stress ratio and statistical scatter of

fatigue life data. Another advantage was that ANN could be used as efficient tool in predicting the fatigue life of composite material when complete data sets are not available.

Jiménez et al. [15] applied artificial neural networks and Weighted K-Nearest Neighbors WKNN as pattern recognition approaches, for detecting and diagnosing the delamination in wind turbine blades. This common structural problem can cause cracks, and partial or total breakage of the blade. They concluded that the performance of diagnostic system testing for multi-level detection of delamination in ANN and WKNN classifiers indicate a high level of accuracy; according to them, ANN was the best classifier.

Recently, Liu et al. [16] presented a paper on the application of PSO-BP neural network for strain prediction of wind turbine blades. They have found that this new approach can be utilized to predict the strain of unmeasured points of wind turbine blades during static testing, and this provides more data for characteristic structural parameters calculation. They have suggested that the outputs can also be used as inputs for another process for life prediction of wind blades.

## EXPERIMENTAL FATIGUE DATA

Wind turbine blades are designed to several major structural conditions, including tip deflection, strength and buckling during severe loading, as well as very high numbers of fatigue cycles and various service environments [17]. Sandia National Laboratories (SNL) performed the experimental stage of this paper with wind turbine-related materials and posted it on the laboratory's website [10]. Moreover, a wide range of prospective blade materials have been included in the course of this work, including E-glass-fiber/polyester, vinylester and epoxy resins in the form of a variety of laminate structures, fiber contents and numerous stitched fabrics.

The types and sources of resins used during the manufacturing process are listed in Table 1. All materials were handled with the resin infusion method in closed molds that were shaped without machining into their final dogbone form. The nomenclature of laminates corresponds to the Sandia National Laboratories. Consequently, the specified fabric details show the stitching and transverse strands or mat to which the main strands are stitched. Laminates were treated by infusion through layers of resin distribution [18, 19]; a more comprehensive description of the manufacturing method can be found in [11, 20].

Standard laminates discussed in this paper include the following reinforcement structures:

- Unidirectional (UD) stitched fabrics where primary strands at  $0^\circ$  are aligned and stitched to a backing including transverse strands and/or mat.
- Multidirectional (MD) laminates reinforced with 'triax' fabrics having layers at  $0^\circ$  and  $\pm 45^\circ$ .

Table 1. MD/UD materials investigated

MD/UD LAMINATES		MATRIX MATERIALS			Cure and post cure temperature (°C)		
General material name	Lay-up	Fiber volume fraction (%)	Type	Resin			
PPG120 0-EP1	$[(\pm 45^\circ)_2 / (0)_2]_s [0]_2$	58 56-61	Epoxy	Hexion MGS RIMR135/RIMH1366	20 and 90		
PPG120 0-UP5	$[(\pm 45^\circ)_2 / (0)_2]_s [0]_2$	58	Polyester	Reichhold Polylite X4627-31 with 2% MCP-75FRED	25 and 70		
PPG120 0-VE4	$[(\pm 45^\circ)_2 / (0)_2]_s [0]_2$	58	Vinylester	Reichhold Dion X4486-14	25 and 70		
PPG120 0-VE5	$[(\pm 45^\circ)_2 / (0)_2]_s [0]_2$	59 57	Vinylester	Reichhold Dion X4235-91	35 and 70		
PPG120 0-VE6	$[(\pm 45^\circ)_2 / (0)_2]_s [0]_2$	60 58	Vinylester	Reichhold Dion X4627-39	25 and 70		
Glass fabric specifications							
Fabric Manufacturer	Designation	Areal weight (g/m <sup>2</sup> )	Component strands warp direction (Weight %)				
			0°	±45°	90°	Mat	Stitch
PPG-Devold LLC	L1200/G50-E07	1261	91	0	4	4	1
	DB810-E05-A	808	0	99	0	0	1

### Fatigue parameters and properties

Fatigue experiments are carried out under load control at varying maximum loads and for different *R*-values, where *R* is the ratio of minimum to maximum load, resulting in typical data sets of stress or strain versus cycles of failure (*S* – *N*), generally curve fit to power law [2, 5]:

$$S = A * N^B \quad (1)$$

$$N = C * S^b \quad (2)$$

Where *S* is the maximum stress or strain, *N* is the number of cycles to failure, *A* and *C* are constants, *B* and *b* are fatigue exponents, with *B* = 1/*b*. The form and notation in Eq. (1) is used to represent data in this paper. The fatigue exponent may also be represented as *n*, where:

$$n = -1/B \quad (3)$$

While the power law model is generally preferred, exponential and three-parameter models have also been used for blade materials; the power law representation has been shown to provide a good fit to  $S - N$  data for small strands up to  $10^{10}$  cycles [2, 5].

Normalizing the stress by the static strength has the effect of reducing discrepancies caused by variations in fiber content and fraction of  $0^0$  plies in MD laminates [5]. The use of strain has a similar effect without normalization. Strain curve fits (Eq. (1)) can differ from stress fits in terms of exponents, and reflect the nonlinearity of stress-strain response at higher stresses, particularly for biax and MD laminates. Strain is often impossible to monitor over the entire coupon lifetime due to instrumentation failure.

Table 2 presents a comparison of fatigue data trends, which included UD fabric and MD laminates, all based on the same strands and resins. Blades are usually constructed from most or all of these materials in which the adjacent materials must withstand similar strains. Comparison of fatigue exponents  $B$  and  $n$  (Eqs. (1) and (3)) and the cycle fatigue strain in the order of millions gives some indication of the most critical areas of blades. The curve fit in Eq. (1) is normalized as a function of the static tensile strength and UTS (Ultimate Tensile Strength determined at the standard test rate of 0.0254 mm/s), by including A/UTS, which does not affect the exponent [5]. These properties must be viewed in the context of actual blade stress distributions and the potential presence of flaws.

Table 2. Summary of tensile strength and fatigue trends ( $R = 0.1$ ) for various blade materials

Material form	Resin	UTS (MPa)	A/UTS	$B$	$n$	$10^6$ cycle strain (%)
MD Laminates, UD fabric L1200/G50-E07 and biax fabric DB810-E05-A						
$[(\pm 45^\circ)_2/(0)_2]_s$	EP-1	704	1.957	-0.130	7.69	0.79
$[(\pm 45^\circ)_2/(0)_2]_s$	VE-4	628	1.955	-0.146	6.85	0.53
$[(\pm 45^\circ)_2/(0)_2]_s$	UP-5	663	1.736	-0.151	6.62	0.42
UD Fabric L1200/G50-E07 Laminates						
$[0]_2$	EP-1	995	1.265	-0.088	11.4	0.88
$[0]_2$	VE-4	912	2.485	-0.170	5.88	0.53
$[0]_2$	UP-5	884	1.940	-0.173	5.78	0.39

## INTELLIGENT PREDICTION METHODS

A program in artificial intelligence has been modeled to see what our qualities are like species, as well as our associative trend [21]. If we want to model human intelligence, then it may be feasible through modeling individuals in a social context. Social behavior allows individuals of a species to adapt to their environment, especially providing them with more information than their sensory abilities can muster.

The numerical prediction consists of predicting values that characterize the input data. The most widely used method for numerical forecasting is the regression [21]. However, as

we have seen above, some classification techniques (such as neural networks, cuckoo search, etc.) can be adapted for prediction.

### Artificial neural networks

Artificial neural networks (ANN) are networks of simple processing elements (called 'neurons') that operate and communicate with other elements on their local data [22, 23, 24]. ANN's design was inspired by an actual brain system, but as shown in Figure 2, the processing elements and architectures used in ANN have gone far from their biological inspiration.  $W_i$  is the synaptic weights matrix linking the input with the hidden layer, and  $W_o$  is the synaptic weights matrix linking the hidden layer with the output.

In latest years, ANN has discovered its application for multiple purposes in the field of fatigue [22]. Depending on the network processing of data, they can be classified as feedforward or recurrent. They can be further categorized as supervised, unsupervised or reinforced ANN according to the learning rules [25].

In general, feedforward ANN consist of a layer of input neurons, a layer of output neurons and one or more layers of hidden neurons [26, 27]. These networks are usually fully connected, meaning that a neuron is connected to all the neurons in the previous layer. Every neuron in the output and hidden layers follows the general model of the neuron [6]. The input signal propagates layer-by-layer through the network in a forward direction. Different transfer functions such as sigmoidal, linear or triangular were used to model the activity of the neurons [13].

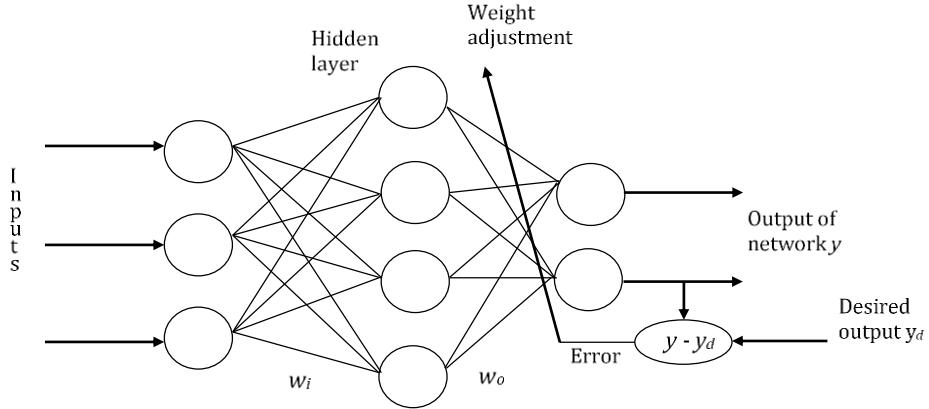


Figure 2. Feedforward neural network with one hidden layer.

The input to a node  $i$  in the  $k^{th}$  layer is given by Eq. (4):

$$net_{i,k} = \left[ \sum_j w_{i,j,k} out_{j,k-1} \right] + \theta_{i,k} \quad (4)$$

Where  $w_{i,j,k}$  represents the weight connection strengths for node  $j$  in the  $(k-1)^{th}$  layer to node  $i$  in the  $k^{th}$  layer;  $out_{j,k}$  is the output of node  $i$  in the  $k^{th}$  layer and  $\theta_{i,k}$  is the threshold associated with node  $i$  in the  $k^{th}$  layer [26].

The backpropagation training algorithm (such as Levenberg-Marquardt) is frequently used to iteratively minimize the cost function as defined later in (Eq. (8)) with respect to the interconnection weights and neurons thresholds. However, the main drawbacks of this

algorithm is that the solution could be trapped in local minima and might converge at slow speed. This disadvantage can be avoided by using cuckoo search training algorithm, which can solve the problem of local minima and achieve fast convergence [8, 9, 28].

### Cuckoo search algorithm

Cuckoo Search (CS) algorithm has been found to be very efficient in solving global optimization problems [7]. This algorithm is inspired by the lifestyle of a family of birds called cuckoo. These birds' lifestyle, egg-laying features and breeding are the basis of the development of this optimization algorithm [29]. Like other evolutionary approaches, CS starts with an initial population (population of cuckoos). There are two types of the population of cuckoos in different societies: mature cuckoos and eggs. The basis of the algorithm is made by stimulating the obligate brood parasitism of some cuckoo species by laying their eggs in the nests of other host birds. Some host nest can keep direct difference. If an egg is discovered by the host bird as not its own, it will either throw the unknown egg away or simply abandon its nest and build a new nest elsewhere [9]. The principle of this species in the wild is the attempt to survive by any means. While competing for being survived, some of them are demised. The survived cuckoos immigrate to better areas and start reproducing and laying eggs [29].

In the process of cuckoo search algorithm,  $n$  randomly chosen nests come into being, and the  $i^{th}$  nest is set  $\text{nest}_i = (x_{i1}, x_{i2}, \dots, x_{id})$ , where  $d$  is the dimension of the problem. The fitness of each nest can be got according to their own location information [7, 30]. The nests are updated according to Eq. (5):

$$\text{nest}_i^{t+1} + \alpha \oplus \text{Lévy}(\lambda), \quad 1 \leq i \leq n \quad (5)$$

Where  $\alpha$  is the step size according to the scale of the problem. The produce  $\oplus$  is entry-wise multiplications. The random walk via Lévy flight is more efficient in exploring the search space as its step length is much longer in the long run [30]. The Levy flight essentially provides a random walk while the random step length is drawn from a Lévy distribution as shown in the Eq. (6):

$$\text{Lévy} \sim u = t^{-\lambda}, \quad 1 < \lambda \leq 3 \quad (6)$$

Which has an infinite variance with an infinite mean. Each nest has a certain probability ( $P_a$ ) to be abandoned. If a nest is abandoned, a new nest will be created according to Eq. (7):

$$\text{nest}_i^{t+1} = \text{nest}_i^t + r(\text{nest}_j^t - \text{nest}_k^t) \quad (7)$$

Where  $r$  is a scale factor uniformly distributed between 0 and 1;  $\text{nest}_j^t$  and  $\text{nest}_k^t$  are other nests, randomly selected in  $t^{th}$  generation [30].

### Cuckoo search-based neural network (CSNN)

In CSNN, CS is applied to optimize the initial weights and biases of backpropagation (BP) network. More specifically, the BP network is considered to be the objective function (fitness function), and the weights and biases are computed by the CS algorithm such as to maximize the objective function [31]. These optimal weights and biases used for the BP network are

expected to be significantly superior to the basic BP network. The weight optimization problem and the size of the population determine the quality of the solution. In the first epoch, the best weights and biases are initialized with CS and then these weights are passed to the BPNN. The weights in BPNN are calculated and compared with the best solution in the backward direction. In the next cycle, CS will update the weights with the best possible solution and CS will continue searching the best weights either until the last cycle/epoch of the network is reached or the MSE (Mean Squared Error) is achieved [9].

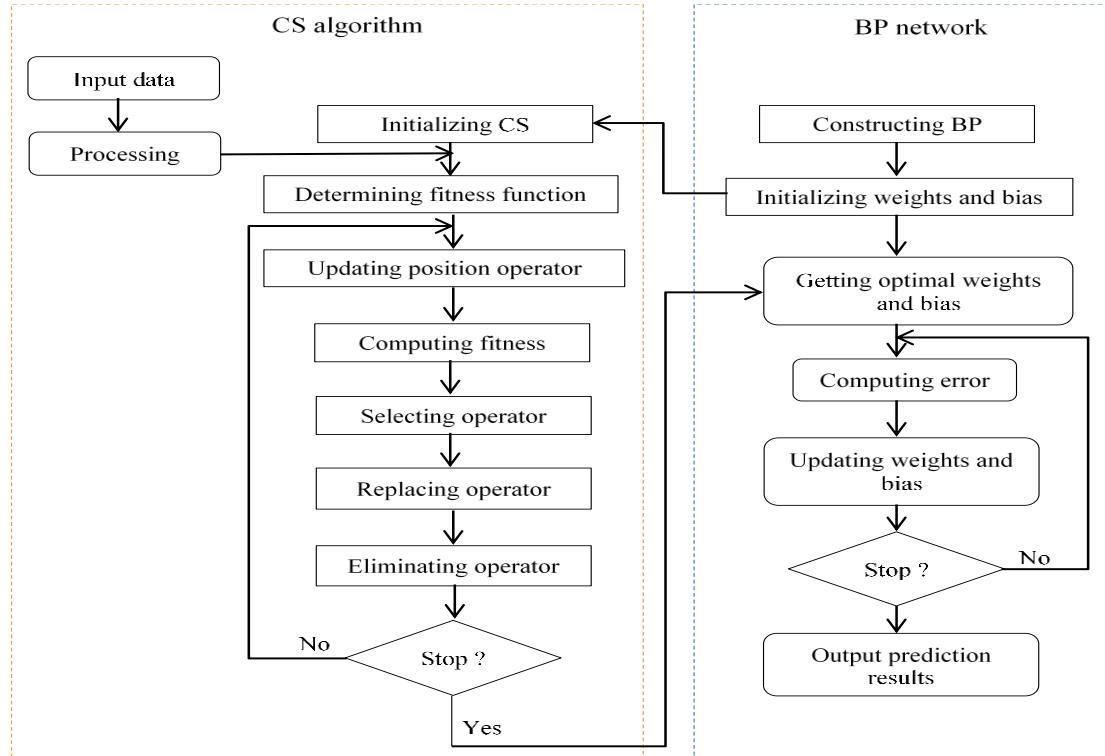


Figure 3. Flowchart for prediction with CSSN [31]

The process of the BP network optimized by the CS is divided into three parts: determining BP network structure, obtaining the best weights and biases through CS, and predicting the output through the neural network. The elements in CSBP include initializing CS, determining fitness function, updating position operator, selecting operator, replacing operator, and eliminating operator in order to find the cuckoo individual with the best fitness. Based on the above analyses, the flowchart of the CSNN algorithm is shown in Figure 3.

We can summarize the flowchart above by the following pseudo code:

---

```

Begin
    Step 1. CS is initialized and passes the best weights to BP network
    Step 2. Load the training data
    Step 3. While MSE < stopping criteria
        Initialize all cuckoo nests
        Pass the cuckoo nests as weights to network
        Feedforward neural network runs using the weights initialized with CS
        Calculate the error backward
        CS keeps on calculating the best possible weight at each epoch until the
        network is converged.
    Step 4. End While
End

```

---

## RESULTS AND DISCUSSION

This work focuses on the prediction of the fatigue life of various composite materials for the design of wind turbine blades, where all the studied materials are submitted to tension-tension fatigue loads. Data was collected from a variety of MSU/DOE fatigue database [10] with a stress ratio of 0.1 ( $R = \sigma_{min}/\sigma_{max} = 0.1$ ). Once the CSNN has been shown to predict fatigue failure correctly under this condition, it is possible to extend the same technique to predict fatigue behavior under distinct stress ratio values.

For the lifetime prediction analysis of previous materials mentioned in Table 1, it is presumed that the fatigue life depends on the number of cycles to failure, minimum ( $\sigma_{min}$ ) and maximum ( $\sigma_{max}$ ) stresses applied to the specimen and the fiber orientation angle ( $\theta$ ). Other parameters that might affect the lifetime of materials, such as the microstructure and process parameters will not be considered in this paper. All specimens will be presumed to have similar characteristics in this respect.

### **Adjustment of CSNN topology parameters**

As mentioned earlier, adequate choice of ANN parameters (inputs, structure...) is critical to obtaining appropriate outcomes. The network was trained and tested using experimental fatigue data from the materials shown in Table 1. In order to achieve the optimum fatigue life prediction, the ANN architecture, training algorithms as well as the number of neurons per hidden layer were regarded.

Firstly, the performance of CS to optimize the weights and bias is tested with a discovery rate  $pa = 0.15$  and a small population size of 25. For each prediction, trial is limited to 1000 epochs and minimum error is kept close to 0. As intelligent algorithms always have some randomness, each run will generate different results. In order to get a typical statistical performance, 15 trials are run for each case. The network results are stored for each trial.

The CS is used to train the feedforward neural network to improve the convergence rate and learning process. The process of learning involves finding a set of weights to minimize the learning error. The goal in this algorithm is to minimize a learning error (cost

function) calculated by using MSE (Eq. (8)). Each cuckoo individual contains all the weights and bias in BP network. According to the weights and bias in BP network, a certain BP network can be constructed. The parameters used for running the CS are mentioned in the paragraph above.

$$j(W) = \frac{1}{2} \sum_{i=1}^N (\hat{y}^i - y^i)^2 \quad (8)$$

Here  $j$  is the objective function, performance or cost function;  $N$  is the number of nodes;  $W$  is the weight matrix;  $\hat{y}$  is the output obtained by the neural network;  $y$  is the desired output.

The selection of these CSNN parameters plays an important role in optimization. A single CS parameter choice has a tremendous effect on the rate of convergence. For this paper, the optimal CS parameters are determined by trial and error experimentations. Optimal here refers to the set of CS parameters that yield the fastest neural network convergence.

Since the range of the number of cycles to failure varied between 170 and 5,000,000 cycles, training the networks to learn such a wide range will produce unacceptable and unbalanced modelling performance. This will happen as the CSNN attempts to minimize the global error for all input patterns. Minimizing the difference between network output and observed data for elevated stress cycle values would therefore lead in inaccurate results for patterns associated with reduced values of the number of failure cycles [26]. A more suitable method would be the range-normalized absolute difference (Eq. (9)) of the number of cycles, to reach a range between 0 and 1. For practical reasons, normalizing (or standardizing) the inputs in neural networks can make training faster and reduce the chances of being stuck in local minima.

$$x_{nrm} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (9)$$

Here  $x_i$  is the value we want to normalize;  $x_{max}$  and  $x_{min}$  are the maximum and minimum values of the number of cycles. The same normalization method was also conducted with the maximum applied tensile stress, which varied between 130 and 690 MPa. This is because the starting point of the optimization process of parameters begins with the calculation of the error as a difference between real and estimated values. Therefore, these two sets of values (number of cycles and max stress) have to have the same range. The Matlab (R2009b) Software was used to construct, train, and test the networks.

The NN used to predict the fatigue life of all materials investigated was a two-layer feedforward network. The normalized maximum tensile stress  $\sigma_{max}$ , ply-orientations (MD/UD fabrics) and the stress ratio  $R$  were used as input parameters; while the normalized number of cycles  $N$  was used as an output, with one computation neuron using a linear activation function. They communicate through a single hidden layer of ten (10) neurons, which uses a sigmoid activation function.

### Fatigue life prediction using CSNN

The proposed modelling procedure is carried out with the help of 166 sets (data size) of experimental fatigue data. These represent a comparison between different materials based on different reinforcing fabrics (see Table 1), in terms of the number of cycles to failure. This can be withstood up to 690 MPa as determined from the curve fits in Table 2. Other measures

of fatigue resistance such as the exponents of the S-N fit in Table 2 would show consistent trends.

One common problem that occurs during neural network training is “data overfitting”, where the network tends to memorize the training examples without learning how to generalize to new situations. The default method on the Matlab software for improving generalization is called “early stopping” which consists in dividing the available training dataset into three subsets. From these 166 sets, only 60% of the samples are assigned to train the proposed CSNN model, 20% to the validation set and the remaining 20% are used for testing purpose.

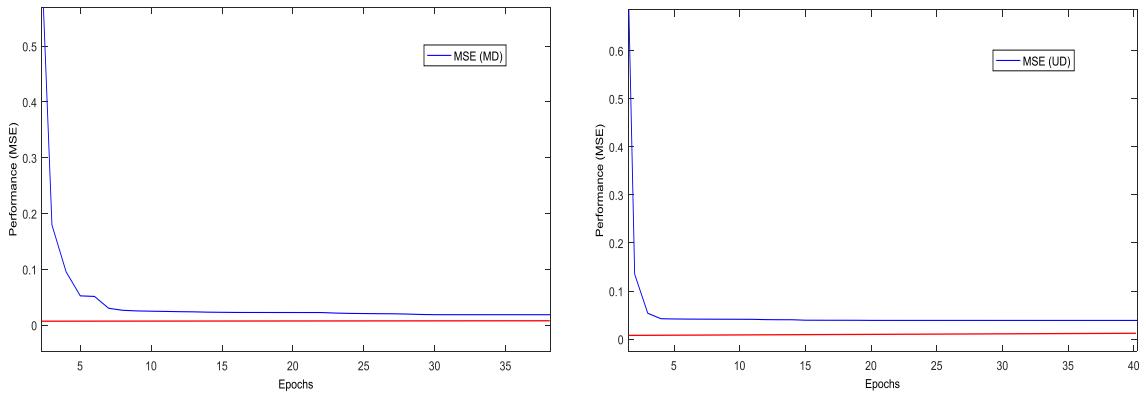


Figure 4. Variation of MSE for the training data according to the number of epochs

Figure 4 shows typical variations of the MSE obtained using CSNN for MD/UD materials considered as a function of the number of epochs. This figure also shows a fast convergence of the MSE to global minima within 40 epochs. The used training proportion in the case of MD laminates is 60% of 78 samples, where the MSE decreases until it reaches the value of 0.0167 (equivalent to 1.67%). While, for the UD laminates, the MSE reaches a value of 0.0380 (equivalent to 3.8%), but this time, with a training proportion of 60% of 88 samples. These MSE values show the effectiveness of our CSNN topology, with ten hidden neurons.

Similarly, the Table 3 describes the CPU time, number of epochs and the MSE of the CSNN model. From this table, we can see that the CSNN method performs well on MD/UD datasets. The CSNN converges to global minima in 8.48 second of CPU time, with an average accuracy of 86% for the MD laminates.

Table 3. CPU time, epochs and MSE for MD/UD training set

MD/UD materials	MD Laminates	UD Laminates
CPU Time (sec.)	8.486	8.678
Epochs	35	40
MSE	0.0167	0.0380
Accuracy (%)	86.472	79.832

Both experimental and predicted results obtained with CSNN are compared in Figs. 5-9 for the materials considered and indicate the relation between the maximum applied stress and the number of cycles to failure. The figures show typical fatigue life predictions of glass-fiber/epoxy, polyester and vinyl esters materials using CSNN model with ten hidden neurons. Each figure presents two plots for different ply orientations. As well as, the figures show a shift between the experiments and the predicted values along the stress axis  $\sigma$  for all laminates studied with  $[(\pm 45^\circ)_2/(0)_2]_s$  and  $[0]_2$  fiber orientations. The nonlinear modeling obtained by CSNN can be utilized to predict the fatigue life for these fiber orientations, for any materials at the desired loading conditions.

Based on actual data in Table 2, the multidirectional glass laminates  $[(\pm 45^\circ)_2/(0)_2]_s$  under tensile fatigue loading ( $R = 0.1$ ) are very sensitive to the fiber orientation and small details in fabric construction. On the other hand, the laminates based on unifabric  $[0]_2$  show good fatigue performance, in terms of fatigue exponent and strain capacity at  $10^6$  cycles (equivalent to 1 after normalization).

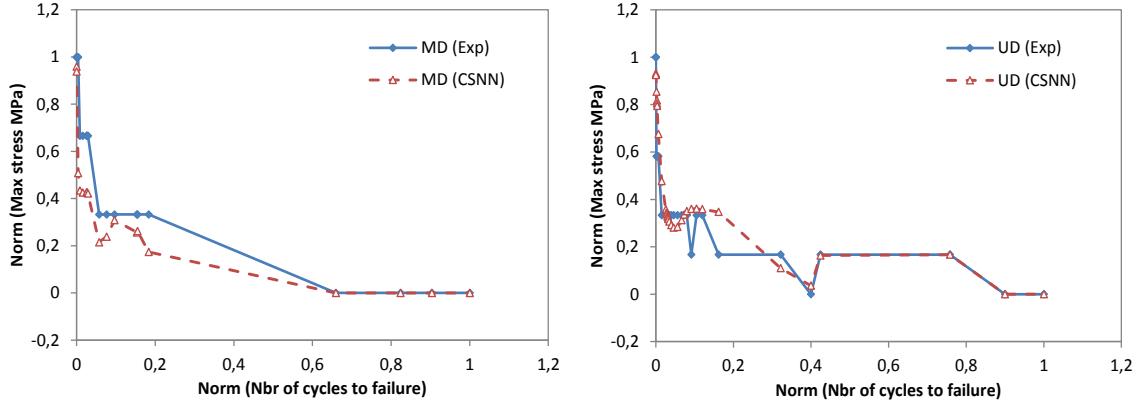


Figure 5. Fatigue life prediction of PPG1200-EP1 glass-fiber/epoxy for multidirectional  $[(\pm 45^\circ)_2/(0)_2]_s$  and unidirectional  $[0]_2$  laminates

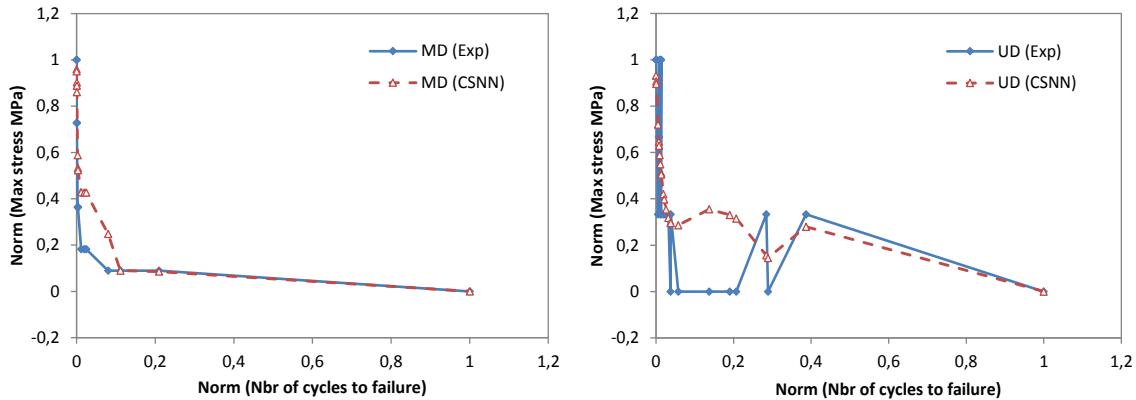


Figure 6. Fatigue life prediction of PPG1200-UP5 glass-fiber/polyester for multidirectional  $[(\pm 45^\circ)_2/(0)_2]_s$  and unidirectional  $[0]_2$  laminates

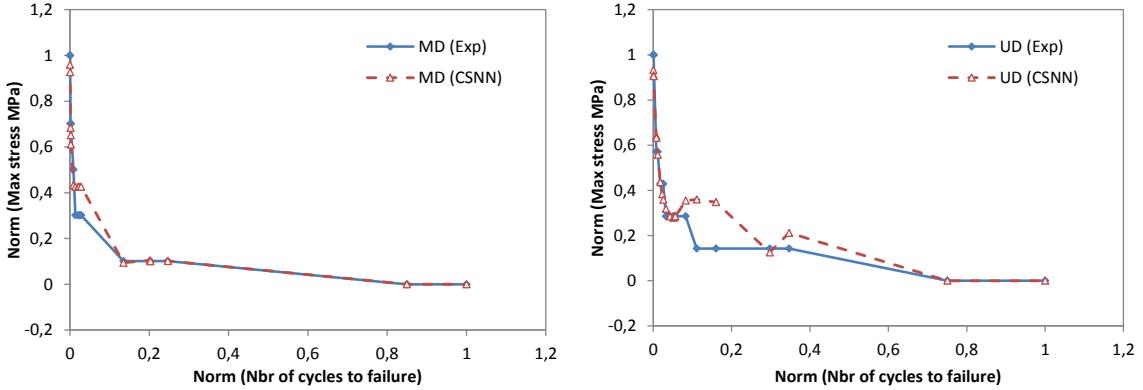


Figure 7. Fatigue life prediction of PPG1200-VE4 glass-fiber/vinylester for multidirectional  $[(\pm 45^\circ)_2/(0)_2]_s$  and unidirectional  $[0]_2$  laminates

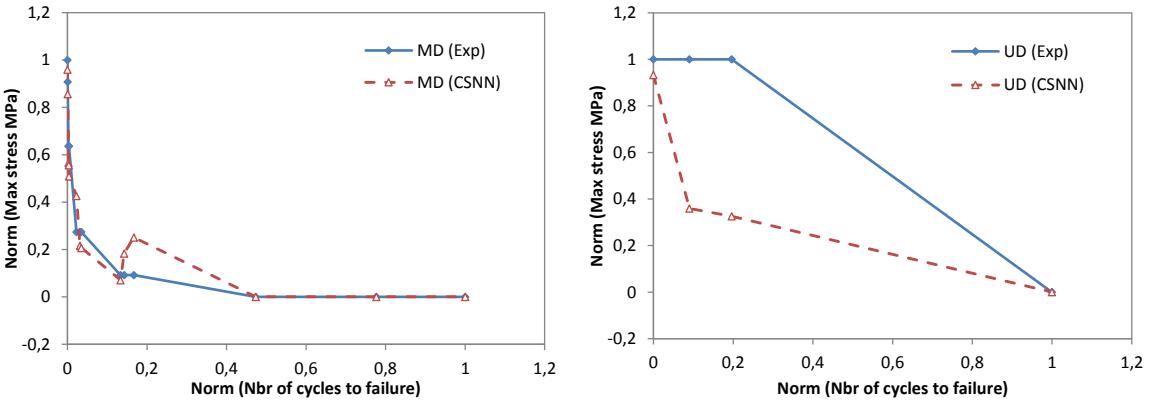


Figure 8. Fatigue life prediction of PPG1200-VE5 glass-fiber/vinylester for multidirectional  $[(\pm 45^\circ)_2/(0)_2]_s$  and unidirectional  $[0]_2$  laminates

The CSNN predictions were obtained using a variety of architectures and topologies with different numbers of hidden neurons. The choice stops when the network converges or reaches a global minimum already predefined as objective function (MSE). Table 4 shows the values of the root mean square error RMSE obtained when predicting the fatigue life of each MD/UD material.

Table 4. RMSE values for all MD/UD materials investigated

Materials	RMSE (%)	
	MD Laminates	UD Laminates
PPG1200-EP1 glass-fiber/epoxy	18.49	10.22
PPG1200-UP5 glass-fiber/polyester	16.05	22.66
PPG1200-VE4 glass-fiber/vinylester	7.30	8.09
PPG1200-VE5 glass-fiber/vinylester	8.34	46.63
PPG1200-VE6 glass-fiber/vinylester	7.40	38.58

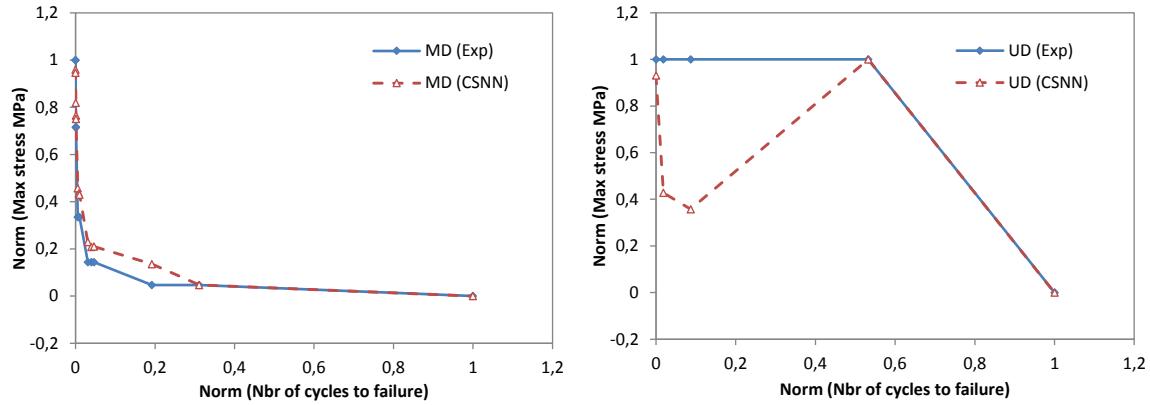


Figure 9. Fatigue life prediction of PPG1200-VE6 glass-fiber/vinylester for multidirectional  $(\pm 45^\circ)_2/(0)_2$  and unidirectional  $[0]_2$  laminates

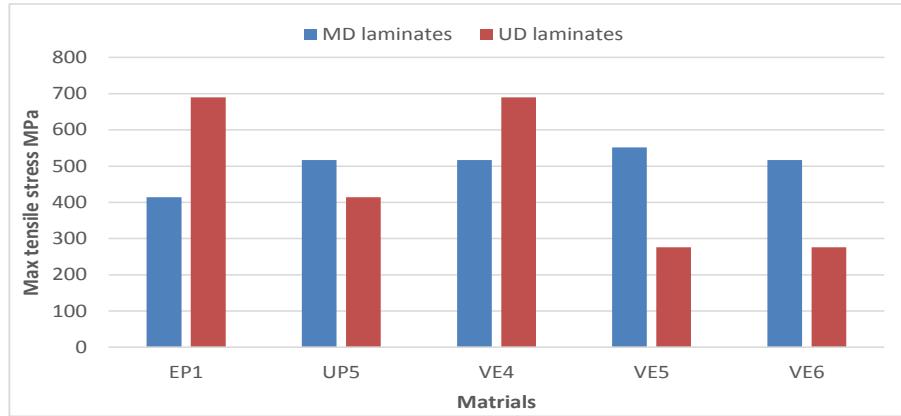


Figure 10. Comparison of fatigue strength of all materials investigated

As it is clear from all these figures, the predicted and experimental results are very close, except in the last two figures (Figure 8 and Figure 9). This is due to insufficient data, particularly with unidirectional laminates. Therefore, of the 166 sets, only 8 are used for the experimental fatigue tests of unidirectional VE5 and VE6 as well as for the training of our CSNN model. The RMSE obtained for these two materials (Figure 8 and Figure 9) were found to be 46.63% and 38.58% respectively, which means the large variation between experimental and predicted values.

To make this result more evident, we needed to quantify the comparison by a bar chart. In Figure 10, both MD and UD laminates are compared in terms of maximum tensile strength. The values mentioned are taken directly from the source database in MPa, without normalization. All materials showed a disparity in the values of the tensile fatigue strength. The MD laminates with  $(\pm 45^\circ)_2/(0)_2$  fiber orientation present a consistency in their values (between 400 MPa and 500 MPa). The decrease in the fatigue strength is very significant for the PPG1200-VE5 glass-fiber/vinylester and PPG1200-VE6 glass-fiber/vinylester, especially with the unifabric  $[0]_2$  laminates. From the same figure,

PPG1200-EP1 glass-fiber/epoxy and PPG1200-VE4 glass-fiber/vinylester showed a higher fatigue strength compared to other materials.

Comparing with the results obtained with PSO-ANN in [11], CSNN gave us better fatigue life predictions, faster computation, more accuracy and above all, a high convergence rate at the true global minimum.

## CONCLUSIONS

Different materials based on different reinforcing fabrics and resins are compared in terms of fatigue life. The combination cuckoo search-based artificial neural network (CSNN) has been used to predict the fatigue life of these composite materials, which are all intended for the design of wind turbine blades. The CSNN model applied in this paper highlight the following conclusions:

- The limitations of traditional fatigue prediction methods based on human experience; hence the need to use neural networks that can provide excellent results
- The prediction of the fatigue behavior of wind turbine blades can greatly help to improve the quality of their prevention
- Reduced lab testing time, which also reduces the cost
- Correct and adjust experimental tests by linear regression of predicted values
- Optimize the MSE between experimental and predicted results
- The size and quality of the database have a major influence on the learning of neural networks. For this reason, the choice of a database is sometimes the only parameter deciding the quality of learning.
- The effects of ANN architecture, training algorithm as well as number of neurons per hidden layer were considered to obtain the optimum fatigue life prediction.
- A supervised network trained by a metaheuristic algorithm gives results with an accuracy that had each of them separately
- CSNN is a very good combination for applications that require fast learning/convergence
- The right selection of CS algorithm parameters plays a key role in optimization

In addition to creating a model that can predict the fatigue life of different MD/UD composite materials. The results obtained by the CSNN approach allowed us to suggest certain types of composite materials, from a lifetime and strength standpoint, for an eventual design of wind turbine blades, taking into consideration the following points:

- The materials based on UD fabric retain good tensile fatigue life compared to those based on MD fabric
- Glass-fiber/epoxy (EP1) and glass-fiber/vinylester (VE4) are least sensitive to the fiber orientation among the five materials investigated

As perspective, further research is needed to determine the possibility of finding unique combinations that always result in the best fatigue life predictions, as well as to improve the ANN's accuracy by using other optimization algorithms in their learning.

## ACKNOWLEDGMENTS

The Authors would like to thank Sandia National Laboratories (SNL) and Montana State University (MSU), for the dataset used in this paper.

## REFERENCES

1. Attaf B. Designing composite wind turbine blades from cradle to cradle. In Recent advances in composite materials for wind turbine blades; Attaf, B., Ed.; The world academic publishing, Hong Kong. 2013; pp. 2-24.
2. Nijssen RPL. Fatigue life prediction and strength degradation of wind turbine rotor blade composites. PhD Thesis. Delft University the Netherlands, Delft. 2006.
3. Mishnaevsky Jr L, Branner K, Petersen HN, Beauson J, McGugan M, F. Sørensen B. Materials for wind turbine blades: an overview. *Materials*. 2017; 10:1-24.
4. Beauson J, Madsen B, Toncelli C, Brøndsted P, Bech JI. Recycling of shredded composites from wind turbine blades in new thermoset polymer composites. *Compos. Part A*. 2016; 90:390-399.
5. Mandell JF, Samborsky DD, Miller DA. Effects of resin and reinforcement variations on fatigue resistance of wind turbine blades. In Advances in wind turbine blade and design. Brondsted P, Nijssen RPL, Eds., Woodhead Publishing Limited, UK. 2013; pp. 210-250.
6. Al-Assadi M, El Kadi H, Deiab IM. Using artificial neural networks to predict the fatigue life of different composite materials including the stress ratio effect. *Appl. Compos. Mater.* 2011; 18:297-309.
7. Yang XS, Deb S. Cuckoo search via Lévy flights. World Congress on Nature & Biologically Inspired Computing. India, 2009.
8. Yang XS. Nature-Inspired Metaheuristic Algorithms Second Edition. Luniver Press, UK, 2010.
9. Nawi NM, Khan A, Rehman MZ. A new back-propagation neural network optimized with cuckoo search algorithm. International Conference on Computational Science and Its Applications. Ho Chi Minh, 2013.
10. SNL/MSU/DOE Composite Material Fatigue Database. Mechanical properties of composite materials for wind turbine blades. Montana State University-Bozeman, Version 25.0, Available online: <http://energy.sandia.gov/> (accessed on 20 October 2016).
11. Ziane K, Zebirate S, Zaitri A. Particle swarm optimization-based neural network for predicting fatigue strength in composite laminates of wind turbine blades. *Composites: Mechanics, Computations, Applications: An International Journal*. 2015; 6:321-338.
12. Ziane K, Zebirate S, Zaitri A. Fatigue strength prediction in composite materials of wind turbine blades under dry-wet conditions: An artificial neural network approach. *Wind Engineering*. 2016; 40:189-198.
13. Al-Assadi M, El-Kadi H, Deiab IM. Predicting the fatigue life of different composite materials using artificial neural networks. *Appl. Compos. Mater.* 2010; 17:1-14.
14. Mathur S, Gope P, Sharma J. Prediction of fatigue lives of composites material by artificial neural network. In Proceedings of the SEM 2007 Annual Conference and Exposition, Springfield, Massachusetts, USA. 2007; Paper 260.
15. Jiménez AA, Gómez Muñoz CQ, García Márquez FP. Machine learning for wind turbine blades maintenance management. *Energies*. 2017; 11:1-16.

16. Liu X, Liu Z, Liang Z, Zhu S, Correia JAFO, De Jesus AMP. PSO-BP Neural Network-Based Strain Prediction of Wind Turbine Blades. *Materials*. 2019; 12:225-234.
17. Mandell JF, Samborsky DD, Miller DA. Analysis of SNL/MSU/DOE Fatigue Database Trends for Wind Turbine Blade Materials, 2010-2015. Research Report No. SAND SAND2016-1441, Sandia National Laboratories, 2016.
18. Samborsky DD, Agastra P, Mandell JF. Fatigue trends for wind blade infusion resins and fabrics. Proc. 51st AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference, Florida, 2010.
19. Agastra P, Samborsky DD, Mandell JF. Fatigue resistance of fiberglass laminates at thick material transitions. Proc. 50th AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics and Materials Conference, California, 2009.
20. Mandell JF, Samborsky DD, Agastra P, Sears AT, Wilson T.J. Analysis of SNL/MSU/DOE Fatigue Database Trends for Wind Turbine Blade Materials. Research Report No. SAND2010-7052, Sandia National Laboratories, 2010.
21. Ziane K. Analyse, évaluation et réduction des risques d'un parc éolien. PhD Dissertation, Université d'Oran 2 Mohamed Ben Ahmed, Oran, 2017.
22. Svozil D, KvasniEka V, Pospichal J. Introduction to multi-layer feedforward neural networks. *Chemometrics and Intelligent Laboratory Systems*. 1997; 39:43-62.
23. Rath AK, Das HC, Parhi DR, Kumar PB. Application of artificial neural network for control and navigation of humanoid robot. *Journal of Mechanical Engineering and Sciences*. 2018; 12:3529-38.
24. Hanief M, Wani MF. Artificial neural network and regression-based models for prediction of surface roughness during turning of red brass (C23000). *Journal of Mechanical Engineering and Sciences*. 2016; 10:1835-45.
25. Mohanty JR, Verma BB, Parhi DRK, Ray PK. Application of artificial neural network for predicting fatigue crack propagation life of aluminum alloys. *Archives of Computational Materials Science and Surface Engineering*. 2009; 1:133-138.
26. Al-Assaf Y, El-Kadi H. Fatigue life prediction of unidirectional glass fiber/epoxy composite laminae using neural networks. *Compos. Struct.* 2001; 53:65-71.
27. Vassilopoulos AP, Georgopoulos EF, Dionysopoulos V. Artificial neural networks in spectrum fatigue life prediction of composite materials. *Int. J. Fatigue*. 2007; 29:20-29.
28. Nawi NM, Khan A, Rehman MZ. A New Cuckoo Search Based Levenberg-Marquardt (CSLM) Algorithm. International Conference on Computational Science and Its Applications, Ho Chi Minh, 2013.
29. Jafari S, Bozorg-Haddad O, Chu X. Cuckoo Optimization Algorithm. In Advanced Optimization by Nature-Inspired Algorithms; Bozorg-Haddad, O., Ed.; Springer: Singapore, 2018; pp. 39-49.
30. Ding J, He X, Jiang B, Wu Y. Parameter identification for area-specific resistance of direct methanol fuel cell using cuckoo search algorithm. In Bio-Inspired Computing - Theories and Applications. Gong M, Linqiang P, Tao S, Tang K, Zhang X, Eds.; Springer: Heidelberg, Germany, 2015; pp. 107-112.
31. Yi J, Xu W, Chen Y. Novel back propagation optimization by cuckoo search algorithm. *The Scientific World Journal*, 2014. <http://dx.doi.org/10.1155/2014/878262>

### CHAPITRE III

## **ALGORITHMES D'OPTIMISATION DU RESEAU NEURONAL POUR PREDIRE LA DUREE DE VIE EN FATIGUE DES PALES D'EOLIENNES SOUS DES CONDITIONS HYGROTHERMIQUES**

### **III.1 RESUME EN FRANÇAIS DU DEUXIEME ARTICLE**

Les effets environnementaux sur les matériaux composites doivent être pris en compte au début de la conception des pales d'éoliennes, sinon les échecs et les itérations de conception se révéleront une perte de temps, d'énergie et d'argent. L'humidité et la température sont les facteurs environnementaux les plus importants qui affectent la dégradation des pales d'éoliennes et, leur influence doit être prise en compte dans le processus de conception. Ils affecteront d'abord la matrice de résine puis, éventuellement, l'interface et les fibres. Le premier objectif de cet article est d'identifier les résines les plus résistantes à l'humidité/température en termes de durée de vie en fatigue. Quatre types de résines sont comparés dans ce travail, représentant les résines les plus couramment utilisées pour la fabrication des pales d'éoliennes. Les résines polymères thermodurcissables, y compris les polyesters et les esters vinyliques ont été usinées sous forme des coupons et testées dans des températures de 20°C et 50°C dans des conditions "sèches" et "humides". Les données expérimentales sur la fatigue, disponibles de « Sandia National Laboratories (SNL) » ont été utilisées pour construire, entraîner et valider notre réseau, ainsi que pour prédire la durée de vie en fatigue dans différentes conditions environnementales. Les performances de trois algorithmes (Backpropagation BP, Particle Swarm Optimization PSO et Cuckoo Search CS) sont comparées pour ajuster les poids synaptiques de ce réseau et pour évaluer leur efficacité de prédire la durée de vie en fatigue des matériaux étudiés, sous les conditions mentionnées ci-dessus. Pour l'évaluation de la précision, l'erreur quadratique moyenne (Mean Square Error MSE) est utilisée comme fonction objective à optimiser par les trois algorithmes.

Ce deuxième article, intitulé « *Neural Network Optimization Algorithms to Predict Wind Turbine Blade Fatigue Life under Variable Hygrothermal Conditions* », fut co-rédigé par moi-même ainsi que par le professeur Adrian Ilinca. Il a été soumis le 21 Février 2020 dans la revue *Wind Engineering*.

### **III.2 NEURAL NETWORK OPTIMIZATION ALGORITHMS TO PREDICT WIND TURBINE BLADE FATIGUE LIFE UNDER VARIABLE HYGROTHERMAL CONDITIONS**

**Abstract.** Moisture and temperature are the most important environmental factors that affect degradation of wind turbine blades and their influence must be considered in the design process. They will first affect the resin matrix and then, possibly, the interface with the fibers. The first objective of this work is to identify which resins are the most robust to moisture/temperature in terms of fatigue life. Four types of resins are compared in this work, representing the most common resins used for wind turbine blades manufacturing. Thermoset polymer resins, including polyesters and vinyl esters, were machined as coupons and tested for the fatigue in air temperatures of 20°C and 50°C under "dry" and "wet" conditions. The fatigue experimental data available from Sandia National Laboratories (SNL) for wind turbine-related materials has been used to build, train and validate an Artificial Neural Network (ANN) to predict the fatigue life under different environmental conditions. The performances of three algorithms (Backpropagation BP, Particle Swarm Optimization PSO and Cuckoo Search CS) are compared for adjusting the synaptic weights of the Artificial Neural Network (ANN) and to evaluate the efficiency in predicting the fatigue life of the materials studied, under the conditions mentioned above. For accuracy evaluation, Mean Square Error (MSE) is used as an objective function to be optimized by the three algorithms.

**Keywords:** Wind turbine blades; fatigue life; artificial neural network; optimization algorithms; composite materials; hygrothermal effect.

#### **1. Introduction**

Blades are one of the most critical components of wind turbines. They capture the wind energy and convert it into mechanical energy for the production of electricity. Defective blades affect significantly the energy conversion efficiency of the wind turbines and blade failures have a significant impact on the cost of energy (repair, maintenance, etc.). Therefore, increased reliability and lifetime of wind turbine blades are important for cost of energy reduction.

Approximately 95% of the modern wind turbine blades are made of fiber-reinforced composites because of their good mechanical characteristics: high stiffness, low density and long fatigue life (Nijssen, 2006). Compared to alternative materials, fiber reinforced composites have other advantages in terms of weight, cost, quality, technical feasibility, market expectation, environmental impact and health and safety. Several key properties are dictated by the matrix resin, including fatigue strength, which is a dominant failure mode in composite material structures, leading to the breakdown of structural integrity in areas such as the trailing edge, spars, and root connections (Li, 2000; Mandell et al., 2000).

Hygrothermal effects on composite materials should be considered in the early phases of design; otherwise, the design iterations and failures will result in a waste of time, energy and money. Usually,

the degree of sensitivity of composites to individual environmental factors is quite different. Temperature and moisture are the most significant variables to consider for the design of wind turbine blades. The primary environmental effects are on the matrix material and then, possibly, on the interface with the fibers.

The purpose of this paper is to identify resins that have good resistance to temperature/moisture while providing better fatigue life. The resins studied are thermosetting polymers including unsaturated polyesters and vinyl esters. They are both suitable for manufacturing wind turbine blades in terms of cost and low viscosity for a ductile processing by “resin transfer molding (RTM)” (Li, 2000).

This study also proposes and compares three algorithms, namely Backpropagation (BP) Levenberg Marquardt, Particle Swarm Optimization (PSO) and Cuckoo Search (CS) in combination with the popular Feedforward Neural Network (FNN) for the prediction of fatigue life of wind turbine blades. These new combinations were used in the training of SNL/MSU database (SNL/MSU, 2016), developed by Sandia National Laboratories (SNL) in collaboration with Montana State University (MSU). The dataset we used is collected from their large public database build for comparative analysis of fatigue life for five resin systems. All the materials studied are used for manufacturing wind turbine blades by most wind turbine manufactures, owners and contractors. The glass fiber-reinforced plastic (GFRP) from E-glass fibers and thermoset polymers were the most appropriate choices for our analysis (Samborsky et al., 1999).

This database is the latest of a series of tests that the SNL have been publishing over the years. The novelty of our work is that it applies these combinations (BPNN, PSO-ANN and CSNN) on this newly published data and creates a model that is capable of predicting the fatigue life of the different resin systems studied. Indeed, this study is based on a portion of the data used with the BP algorithm by (Ziane et al., 2016), in order to improve the results already found. In contrast, this new model could be used in the future as an alternative to the costly lab tests, as well as to validate new experimental results.

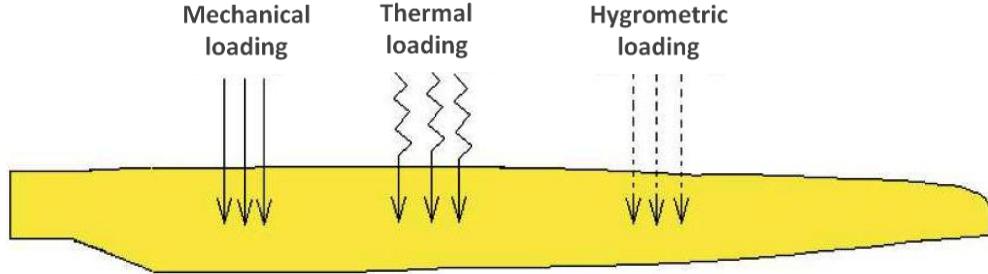
## **2. Hygro-thermo-mechanics of wind turbine blades**

Offshore and onshore wind turbines are exposed, depending on the climatology of the region, to climatic constraints such as variations in temperature, moisture and sand grains associated with storms. These natural phenomena can easily damage the skin of the blade (gelcoat) (Attaf, 2010). However, a composite wind turbine blade is highly durable if the layer of gelcoat that protects it from the external environment has good physicochemical characteristics.

The state of the problem illustrated by the figure 1 is of the hygrothermomechanical type; because the structure of the blade is supposed subjected to three types of loadings of origin (Ziane, 2017):

- Mechanical (wind gust, storms...);
- Thermal (temperature variation);
- Hygrometric (moisture variation).

The constitutive equations governing the hygrothermomechanical behavior of a stratified composite (upper and lower surfaces) and without taking into account the transverse shear are expressed according to (Atta, 2010) by the following compact matrix form:



**Figure 1.** Blade subjected to a loading type hygrothermomechanical (Attaf, 2010)

$$\begin{Bmatrix} N \\ \dots \\ M \end{Bmatrix}_{xy} = \begin{bmatrix} A & \vdots & B \\ \dots & \ddots & \dots \\ B & \vdots & D \end{bmatrix} \begin{Bmatrix} \varepsilon_0 \\ \dots \\ \kappa \end{Bmatrix}_{xy} - \begin{Bmatrix} N^{\Delta T} \\ \dots \\ M^{\Delta T} \end{Bmatrix}_{xy} - \begin{Bmatrix} N^{\Delta m} \\ \dots \\ M^{\Delta m} \end{Bmatrix} \quad (1)$$

Where  $\Delta T$  and  $\Delta m$  respectively represent the variations of temperature and moisture. During the design process, a study on the behavior of the gelcoat to climatic phenomena as well as hygro-thermo-mechanical stresses must be the subject of a particular study in order to predict the undesirable effects in the short and/or long-term (Ziane, 2017; Attaf, 2010).

### 3. Data and method

During its service, the blade is subject to problems of variation of stresses from one cycle to another. This variation can have the consequence of a degradation of the structural resistance through the phenomena of accumulation of stresses and fatigue.

A number of specimens (sections) must be realized in accordance with the principles of blade construction. These specimens will then be tested at a sufficient level until rupture under alternating load. A testbed and strain gauges for performing the tests are required. The experimental results obtained by Sandia National Laboratories (SNL/MSU, 2016) will make it possible to estimate the life of the blade with a sufficiently acceptable degree of confidence. On average, this lifetime is estimated at 20 years (attaf, 2010).

#### 3.1. Fatigue data

The purpose of the neural networks and optimization algorithms used in this paper is to predict the fatigue behavior of wind turbine blade composites, under the hygrothermal effect, and in extreme conditions (dry/wet). The specimens used for this process were tested in air temperatures of 20° C and 50° C. The experimental stage was carried out by Sandia National Laboratories (SNL) with wind turbine-related materials and released on their website (SNL/MSU, 2016). In addition, a wide variety of prospective blade materials were included in this work, including E-glass-fiber/polyester and vinylester resins in the form of a multidirectional laminate constructions [0/±45/0]<sub>s</sub>, fiber contents (35-36 %) and many stitched fabrics.

Table 1 lists the types and sources of resins and reinforcement used during the manufacturing process. All materials were treated in closed molds with the resin infusion process, which were molded into their final dogbone shape without machining. The laminate nomenclature corresponds to the Sandia National Laboratories. Therefore, the fabric details given indicate the content of stitching and transverse strands or mat to which the primary strands are stitched. Laminates were processed by RTM through resin distribution layers (Samborsky et al., 2010; Agastra et al., 2009); a more detailed description of the fabrication process may be found in (Mandell et al., 2010; Ziane et al., 2016).

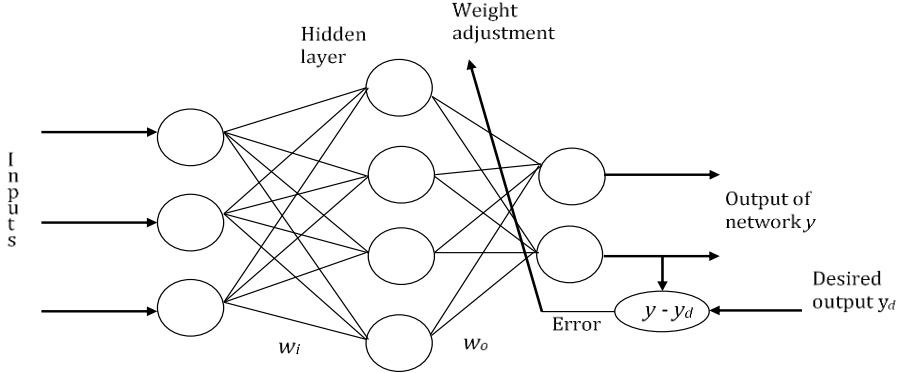
**Table 1.** Different resins investigated

LAMINATE			MATRIX MATERIALS				
General material name	Lay-up	Volume fiber (%)	Resin	Description	Resin trade name	Supplier	
MD-DD5P-UP2	[0/±45/0] s	35-36	Ortho-polyester	Orthophthalic	CoRezyn 63-AX-051	Interplastics Corporation	
			Iso-polyester	Isophthalic	CoRezyn 75-AQ-010		
MD-DD5P-VE	[0/±45/0] s	35-36	Vinyl ester 411C-50	Unmodified	Derakane 411C-50	Dow Chemical	
			Vinyl ester 8084	Rubber toughened	Derakane 8084		
FIBER REINFORCING FABRICS							
E-glass fabric	Fabric orientation	Type	Areal weight (g/m <sup>2</sup> )	Supplier			
Knytex D155	0° unidirectional fabrics	Stitched unidirectional	527	Owens corning fabrics			
Knytex DB120	±45 Fabrics	Bias, stitched	393	Owens corning fabrics			

### 3.2. Backpropagation neural network BPNN

Artificial neural networks (ANNs) have been shown to be useful for a variety of engineering applications, including characterization of fatigue behavior. Because of their massively parallel structure, they can solve many nonlinear and multivariate problems, for which an accurate analytical solution will be difficult to obtain.

The popular topology of a neural network model is illustrated in Figure 2, which typically consists of one or more input layers, output layers and hidden layers where weights are trained. Each layer comprises one or more neurons; the neurons are interconnected so that the information passes from one layer to another, that is to say from the input layer to the output layer, through the hidden layers. Various transfer functions such as sigmoidal, linear or triangular have been used to model neuronal activity (Al-Assaf and El-Kadi, 2001; Vassilopoulos et al., 2007).



**Figure 2.** Feedforward neural network with one hidden layer (Ziane et al., 2015).

Where  $w_i$  is the synaptic weight matrix linking the input with the hidden layer, and  $w_o$  is the synaptic weight matrix linking the hidden layer with the output, according to the following equation (Al-Assaf and El-Kadi, 2001; Vassilopoulos et al., 2007; Ziane et al. 2015, 2016):

$$net_{i,k} = [\sum_j w_{i,j,k} out_{j,k-1}] + \theta_{i,k} \quad (2)$$

Where  $w_{i,j,k}$  represents the weight connection strengths for node  $j$  in the  $(k-1)^{th}$  layer to node  $i$  in the  $k^{th}$  layer;  $out_{j,k}$  is the output of node  $i$  in the  $k^{th}$  layer and  $\theta_{i,k}$  is the threshold associated with node  $i$  in the  $k^{th}$  layer.

Mean squared error MSE (Equation 3) was used as an objective function to optimize, and weights were tuned to minimize their values, throughout the prediction process.

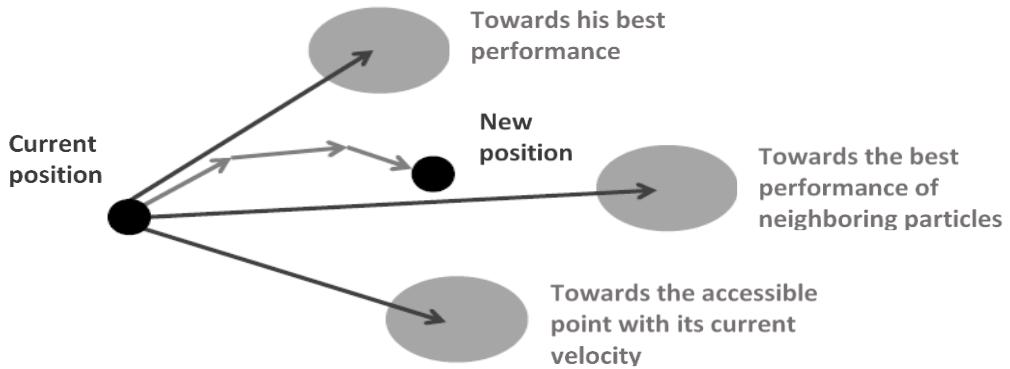
$$j(W) = \frac{1}{2} \sum_{i=1}^N (y^i - y_d^i)^2 \quad (3)$$

Here  $j$  is the objective function, performance or cost function;  $N$  is the number of nodes;  $W$  is the weight matrix;  $y$  is the output obtained by the neural network;  $y_d$  is the desired output.

In this study, two other metaheuristic algorithms (PSO and CS) were used to avoid the local optimum trap. Both were deployed to optimize MSE by adjusting the neural network weights. The details of these two proposed algorithms are described in the next sections.

### 3.3. Particle swarm optimization PSO

Particle swarm optimization or PSO is an intelligent optimization algorithm; it belongs to a class of optimization algorithms called metaheuristics. PSO is based on the intelligence paradigm of swarms and is inspired by the social behavior of animals, such as fish and birds. PSO is a simple yet powerful algorithm, which has been successfully applied to huge applications in various fields of science and engineering. Initially, PSO is introduced by Kennedy and Eberhart (Kennedy and Eberhart, 1995), where they sought to model social interactions between "particles" to achieve a given goal in a common search space. Each particle having a certain capacity for memorizing and processing information. The basic rule was that there should be no conductor, or even any knowledge by the particles of all information, only local knowledge. A simple model was then developed.



**Figure 3.** Displacement of a particle (Ziane, 2017).

The algorithm works by initializing a flock of birds randomly over the searching space, where every bird is called as a "particle". These particles fly with a certain velocity and find the global best position after some iteration (Zhang et al., 2007). During flight, each particle update its velocity vector, based on its momentum and the influence of its best position ( $P_b$ ) as well as the best position of its neighbors ( $P_g$ ), and then computes a new position (Ziane et al. 2015). Figure 3 illustrates briefly the concept of PSO.

In a search space of dimension  $d$ , the particle  $i$  of the swarm is modeled by its vector position  $\vec{x}_i = (x_{i1}, x_{i2}, \dots x_{id})^T$ , and by its velocity vector  $\vec{v}_i = (v_{i1}, v_{i2}, \dots v_{id})^T$ , designating by  $A^T$  the transpose of a matrix  $A$ . The quality of its position is determined by the value of the objective function at this point. This particle keeps in memory the best position by which it has already passed, which we note  $\vec{p}_i = (p_{i1}, p_{i2}, \dots p_{id})^T$ . The best position reached by its neighboring particles is noted  $\vec{g}_i = (g_{i1}, g_{i2}, \dots g_{id})^T$ . At time  $t$ , the velocity vector is calculated from Equation (4):

$$v_{ij}(t + 1) = wv_{id}(t) + c_1r_1(p_{id}(t) - x_{id}(t)) + c_2r_2(g_{id}(t) - x_{id}(t)) \quad (4)$$

In the above equation (Equation 4)  $v_{id}$  and  $p_{id}$  are the velocity and position of particle  $i$  ( $i = 1, 2, \dots n$ ), where  $n$  is the number of particles;  $d = 1, 2, \dots m$ , where  $m$  is the number of input variables to be optimized;  $w$  is usually a constant, called "inertia weight factor";  $c_1$  and  $c_2$  are cognitive and social acceleration factors respectively that scale the old velocity and increase new velocity toward  $P_{best}$  (local best result) or  $G_{best}$  (global best result);  $r_1$  and  $r_2$  represent random numbers that are uniformly distributed in the interval  $[0,1]$  (Ziane et al. 2015; Ziane 2017).

### 3.4. Cuckoo search algorithm

Cuckoo search (CS) algorithm was inspired by the brood parasitism of cuckoo birds. In fact, their breeding strategy is characterized by the laying of their eggs in the nests of other species (host birds). If a host bird discovers the eggs are not theirs, it will throw them away. Otherwise, simply abandon its nest and build another elsewhere. CS is a metaheuristic optimization algorithm, which is based on the following rules:

- Every cuckoo lays solely one egg at a time and the eggs are exactly set in a nest (randomly select nest);
- The nest having better quality eggs, which are carried onto the next round;

- The number of nest is fixed and the quality of nest is static and is not alterable.

In CS, each egg in a nest represents a solution and each cuckoo can lay a single egg (which represents a solution), the goal is to use the new and potentially better solution to replace a less good solution in a nest. This metaheuristic is thus based on this parasitic behavior of the species of cuckoos associated with a logic of displacement of the "Lévy flight" type, which is specific to certain birds and certain fly species (Yang and Deb, 2009).

The Lévy flight is a random process, which consists of taking a series of random steps. From the mathematical point of view, two consecutive steps need to be performed to generate random numbers with Lévy flights: The generation of steps and the choice of a random direction. To do this, one of the most efficient method is to use the so-called Mantegna algorithm, where the step length  $s$  can be determined as in equation (Equation 5).

$$s = \frac{u}{|v|^{1/\beta}} \quad (5)$$

Here  $u$  and  $v$  are centered Gaussian distributions;  $\beta$  is the scale parameter and its recommended range is [1,2].

In the process of cuckoo search algorithm,  $n$  randomly chosen nests come into being, and the  $i^{th}$  nest is set  $nest_i = (x_{i1}, x_{i2}, \dots, x_{id})$ , where  $d$  is the dimension of the problem. The fitness of each nest can be got according to their own location information (Yang and Deb, 2009; Ding, 2015). The nests are updated according to Equation (6):

$$nest_i^{t+1} + \alpha \otimes \text{levy}(\beta), \quad 1 \leq i \leq n \quad (6)$$

Where  $\alpha$  is the step size according to the scale of the problem. The produce  $\otimes$  is entry-wise multiplications. The random walk via Lévy flight is more efficient in exploring the search space as its step length is much longer in the long run (Ding, 2015). Each nest has a certain probability ( $P_a$ ) to be abandoned. If a nest is abandoned, a new nest will be created according to Equation (7):

$$nest_i^{t+1} = nest_i^t + r(nest_j^t - nest_k^t) \quad (7)$$

Where  $r$  is a scale factor uniformly distributed between 0 and 1;  $nest_j^t$  and  $nest_k^t$  are other nests, randomly selected in  $t^{th}$  generation (Ding, 2015).

### 3.5. Data preparation

Data preparation is important for ensuring the built model's accuracy and robustness. The accuracy of the collected data influences the precision, and the amount of data used to train the model affects robustness (Anga et al. 2018). As mentioned above, the data were collected from the extensive database of Sandia National Laboratories to compare four types of thermosetting resins (cited in Table 1) in terms of fatigue lives and hygrothermal effect. The size of the database collected is 122 sets distributed over the four resins in question (Ortho-polyester, Iso-polyester, Vinyl ester 411C-50 and Vinyl ester 8084). Before we began to model the data, we had to normalize it to be in a range from 0 to 1. Since the number of cycles to failure ranged from 16 to 6,000,000 cycles, and the maximum applied compressive stress

was -13.8 to -41.4 MPa, we used the range-normalized absolute difference method based on the equation (8):

$$\text{Normalized value} = (\text{value} - \text{minValue}) / (\text{maxValue} - \text{minValue}) \quad (8)$$

This method was applied to both data ranges (number of cycles and max stress). Indeed, the starting point of the parameter optimization process starts with the error estimation as a difference between real and predicted values. These two sets of values must therefore have the same range. The normalization of inputs in neural networks can, for practical reasons, make learning faster and reduce the chances of being trapped in local minima.

**Table 2.** Sample parameters of ortho-polyester 63-AX-051

Testing temperature T (°C)	Stress ratio R	UCS* (MPa)	Hygrometric conditions
50° C Wet	10	-34.5	Wet coupons (1.0% distilled water)
50° C Dry	10	-34.5	
20° C Wet	10	-31	
50° C Dry	10	-37.9	

\*UCS: Ultimate compressive stress

On an excel file, where the data has been processed from Table 2 to Figure 4. We first started sorting the data in ascending order based on hygrothermal conditions and the resin types. Then we normalized them in a way that allows us to apply the different neural network combinations mentioned earlier, and for each resin, we put the properties that can be extracted from the prediction, such us: MSE, number of epochs, etc.

Ortho-polyester 63-AX-051	Normalization	BPNN Prediction	MSE/E poc	PSO-ANN	MSE/E poc	CSNN Prediction	MSE/E poc
T=50° C Wet	1	0.9554	Er = 3.069e-04	0.9443	1.0048	Er = 2.059e-04	0.6668
	0.66666667	0.00086402		0.6685	0.3334		0.3332
	0.33333333	0.02334031		0.3246	0.3332		0.3323
	0.33333333	0.02755256		0.3244	0.1326		0.1326
	0.33333333	0.0339168		0.3278	0.1296		0.1296
	0.13043478	0.08773334		0.1342	0.0295	Epochs = 277	0.1304
	0.13043478	0.11820646		0.1296	0.0295		0.1303
	0.13043478	0.21252717		0.1296	0.0098		0.0357
	0	0.49803612		0.1296	0.0299		0.0234
	0	0.64075062		0.1296	0.0597		-0.0189
T=50° C Dry	0	-0.0621		0.0867	0.0867	Epochs = 62	0.0867
	1	0.9377	Er = 0.001	1.0012	0.9391		0.6811
	0.61666667	0.03688757		0.6051	0.6117		0.5667
	0.61666667	0.05558395		0.6443	0.2345		0.2345
	0.61666667	0.07295254		0.5636	0.2274		0.2274
	0.23333333	0.09251325		0.2348	0.1846		0.1846
	0.23333333	0.1293062		0.227	0.0189		0.0189
	0.23333333	0.15942322		0.226	-0.0133		-0.0133
	0	0.37709582		0.226	-0.0233		-0.0233
	0	0.63917		0.226	-0.0422		-0.0422
T=20° C Wet	0	-0.0422	Epochs = 54	0.1846	0.0633	Epochs = 23	0.0633
	0	-0.0653		0.226	-0.0843		-0.0843
	1	0.9377		0.226	0.0146		0.0146
	1	0.6823		0.226	0.0146		0.0146
	0.6121	0.6443		0.226	0.0146		0.0146
	0.5889	0.5889		0.226	0.0146		0.0146
	0.2418	0.2418		0.226	0.0146		0.0146
	0.2264	0.2264		0.226	0.0146		0.0146
	0.1846	0.1846		0.226	0.0146		0.0146
	0.0189	0.0189		0.226	0.0146		0.0146
T=20° C Dry	0	-0.0133	Epochs = 112	0.226	0.0345	Epochs = 3	0.0345
	-0.0133	-0.0133		0.226	0.0345		0.0345
	-0.0233	-0.0233		0.226	0.0345		0.0345
	-0.0422	-0.0422		0.226	0.0345		0.0345
	-0.0843	-0.0843		0.226	0.0345		0.0345
	0	0.0146		0.226	0.0345		0.0345
	0	0.0146		0.226	0.0345		0.0345
	0	0.0146		0.226	0.0345		0.0345
	0	0.0146		0.226	0.0345		0.0345
	0	0.0146		0.226	0.0345		0.0345

**Figure 4.** Excel file summary for the preparation of Ortho-Polyester data.

#### 4. Proposed hybrid models for fatigue life prediction

In order to create a model that can predict the fatigue life of the various resins investigated with reasonable accuracy, a total number of 122 experimental fatigue data entries were used in the training process, and the parameters of input and output are tabulated in Table 3.

To improve accuracy, the training data were split into three different sets to fulfil the training requirements according to the “early stopping” method, integrated by default in the Matlab software (R2016b), in which 60% of the data were used as the training set, 20% was used for validation, and the remaining 20% was used for testing purposes.

**Table 3.** Input and output parameters.

Input parameters	Output parameters
Normalized maximum compressive stress $\sigma_{max}$	
Normalized minimum compressive stress $\sigma_{min}$	
Ply-orientations ( $^{\circ}$ )	
Fiber contents (%)	
Stress ratio ( $R = \sigma_{min}/\sigma_{max} = 10$ )	
Hygrothermal conditions ( $^{\circ}\text{C}$ and %)	Normalized number of cycles to failure $N$

The NN used to predict the fatigue life of all resin matrices was a two-layer feedforward network. The network consists of a single hidden layer of ten (10) neurons using a sigmoid activation function, while the output uses a linear activation function with one computation neuron. This will be considered as a fixed architecture of all our proposed combinations, and we will try each time to replace the BP algorithm (Levenberg-Marquardt) by one of the suggested algorithms.

#### 4.2. PSO-based ANN

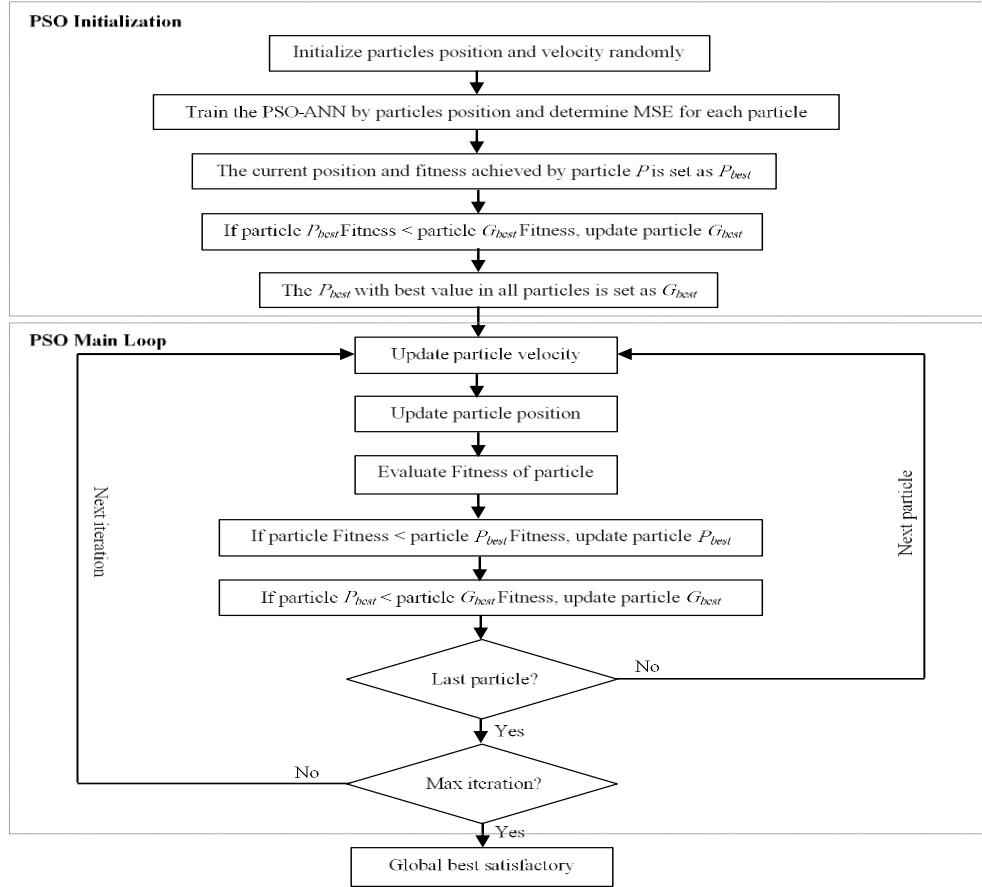
A neural network optimized by a particle swarm algorithm is also called a PSO-ANN (Particle swarm optimization-based artificial neural network) combination. This algorithm takes the weights and biases of the trained neural network as a single particle. For training a neural network using the PSO, the fitness value of each swarm particle (member) is the value of the error function evaluated at the particle's current position and the particle's position vector corresponds to the network's weight matrix (Ziane et al. 2015 ; Gudise and Venayagamoorthy, 2003). The number of PSO dimensions is taken as the total number of neural network weights and biases. The PSO-ANN combination procedure is illustrated in the flowchart of Figure 5.

Returning to the parameters; to improve the convergence rate and the learning process, the parameters presented in Table 4 were better suited for the execution of the PSO algorithm.

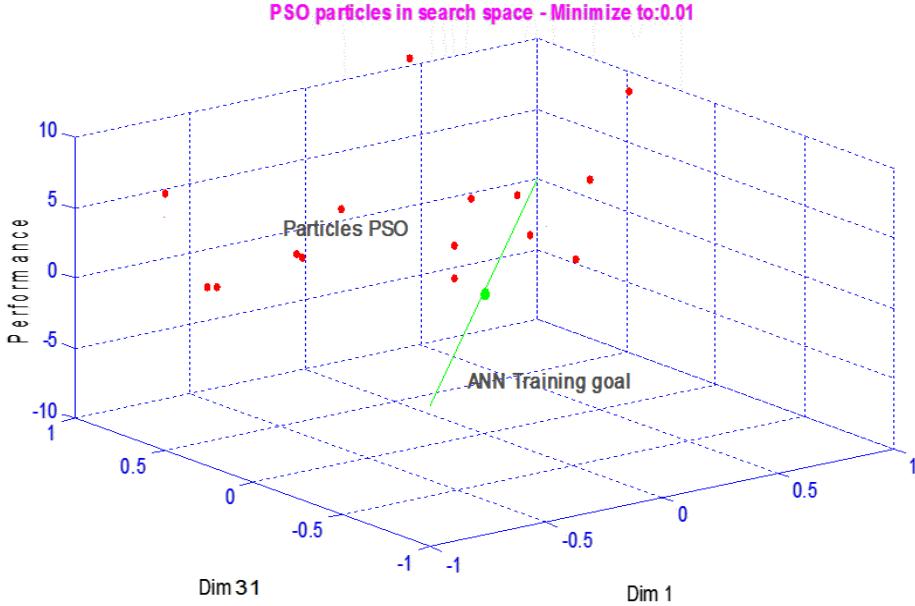
**Table 4.** Parameters of PSO algorithm.

Parameters	Values
Number of particles	20
Number of generations (max iterations)	1000
Maximum velocity $V_{max}$	0.9
Minimum velocity $V_{min}$	0.4
Cognitive and social acceleration factors $c_1$ and $c_2$	2
Search space range	[-100,100]
Inertia weight factor $w$	0.72

In this combination, the number of dimensions of the PSO domain corresponds to the number of weights and biases of the neural network, from which each PSO dimension corresponds to a weight or bias of the neural network. Since it is not possible to display more than three dimensions, we will only show the first and the last dimension in the x and y axes. The z-axis corresponds to the performance function of the neural network, which also represents the objective function of the PSO (Figure 6). The goal of PSO will be to optimize the MSE of our network.

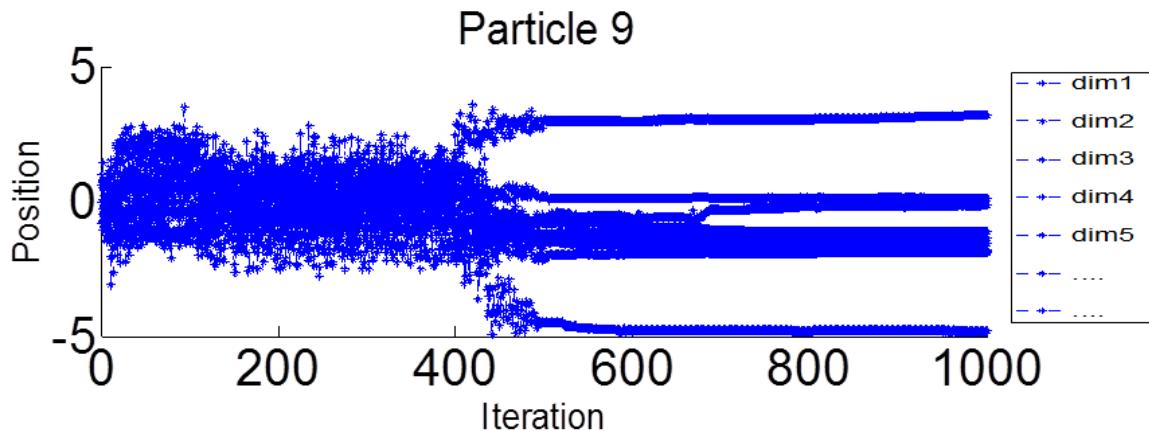


**Figure 5.** Use of PSO to train a feedforward NN (Ziane et al. 2015).



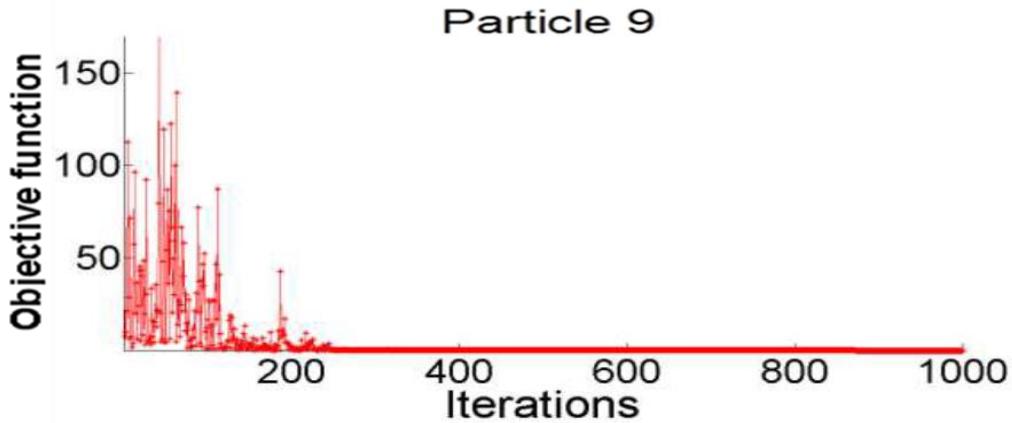
**Figure 6.** Particles of PSO in the search space.

For our topology, we have 31 dimensions where the PSO particles search an optimum. These 31 dimensions correspond to the weights and biases of our neural network (two layers, one of 10 and the other of a single neuron, give 20 weights and 11 biases). In this search space, each particle will have projections on the dimensions that correspond to the parameters (weight and bias) of the NN. In our case, the number of parameters is 31 (20 weights and 11 biases). So, if we want to follow the evolution of the position of a particle (choose a particle among the 20 used in our PSO-ANN combination), we will see that this evolution will have 31 projections. Each projection corresponds to a parameter (weight or bias) of the NN.



**Figure 7.** Position of the particle 9 according to the iterations from dim1 to dim31.

The Figure 7 represents the change of the position of the particle 9 in projection on the 31 parameters (or dimensions); dim1...dim31 represent the parameters of the NN (weight and bias).

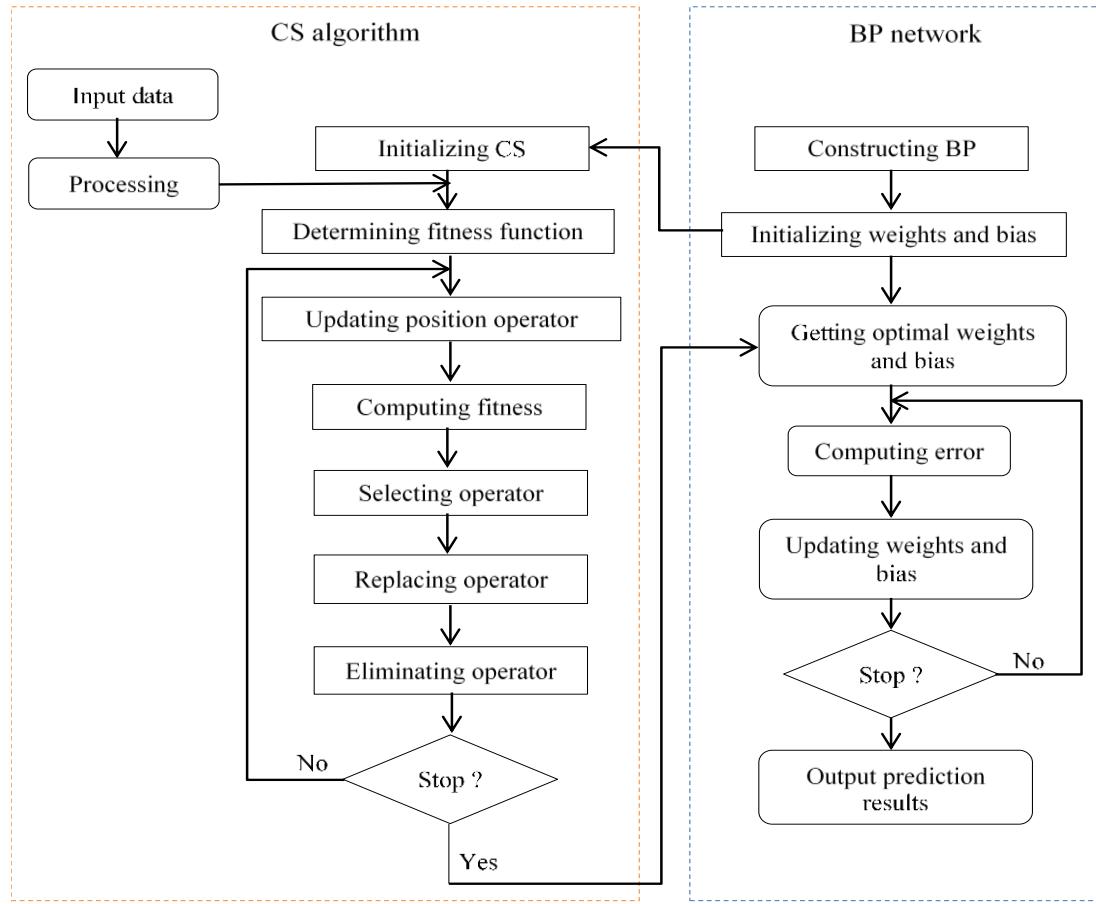


**Figure 8.** Evolution of the objective function according to particle 9.

Similarly, if we want to follow the value of the objective function of a particle, the projection on the z-axis will give us the value of the objective function at any iteration. This value converges when the particles are clustered near an optimum. Figure 8 shows the evolution of the objective function according to particle 9.

#### 4.2. CS-based NN (CSNN)

In CSNN, CS is used to optimize backpropagation (BP) network's initial weights and biases. More precisely, the BP network is regarded as the objective function (fitness function) and the weights and biases are calculated by the CS algorithm to maximize the objective function (Yi et al., 2014). It is expected that these optimal weights and biases used for the BP network will be significantly higher than the default BP network. In the first epoch, CS initializes the best weights and biases and then transfers it to the BPNN. Then, BPNN weights are calculated and compared with the best solution in the backward direction. In the next cycle, CS will update the weights with the best possible solution and CS will continue to search for the best weights until the network's last cycle/epoch is reached or the MSE is achieved (Nawi, 2013). The flowchart of the CSNN combination is described in Figure 9.



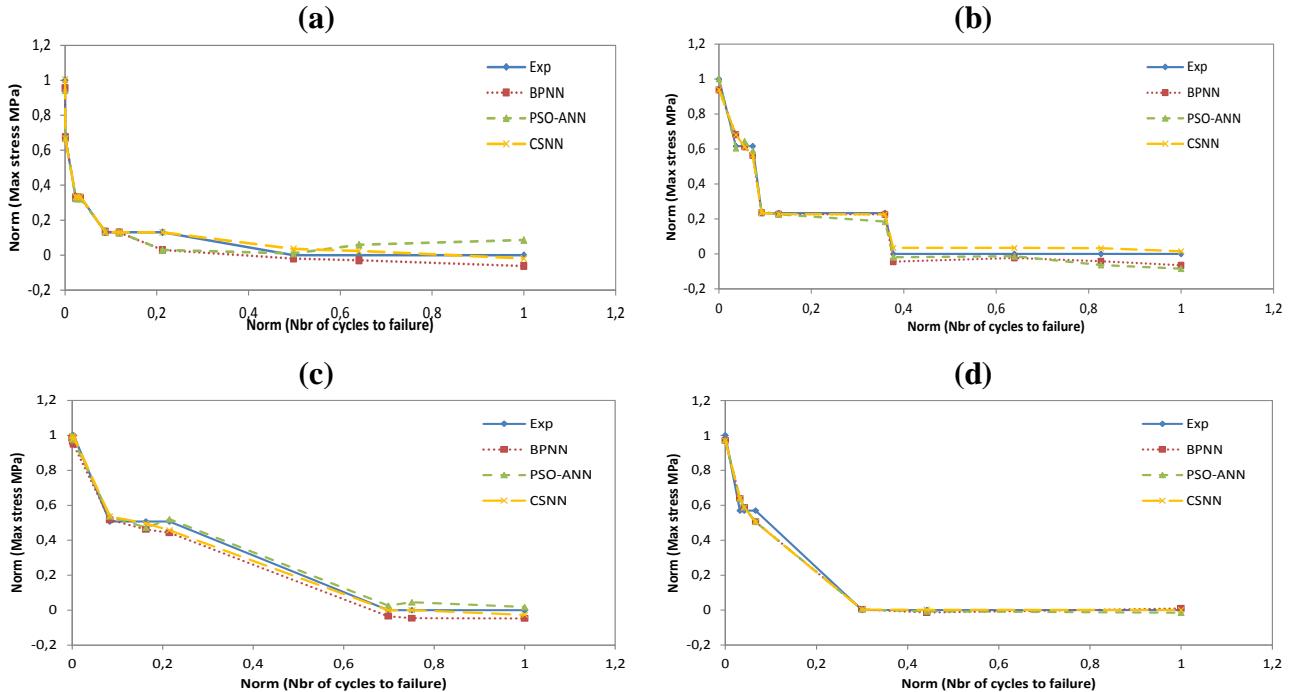
**Figure 9.** Flowchart of CSNN combination (Yi et al., 2014).

CS performance is tested with a discovery rate  $pa = 0.15$  to optimize weights and bias and a small population size of 20. For each prediction, trial is limited to 1000 epochs and minimum error is kept close to 0. Because intelligent algorithms always have a certain randomness, different results will be generated by each run. For each case, 10 tests are run to get a standard statistical result. The results of the network will be saved for each test.

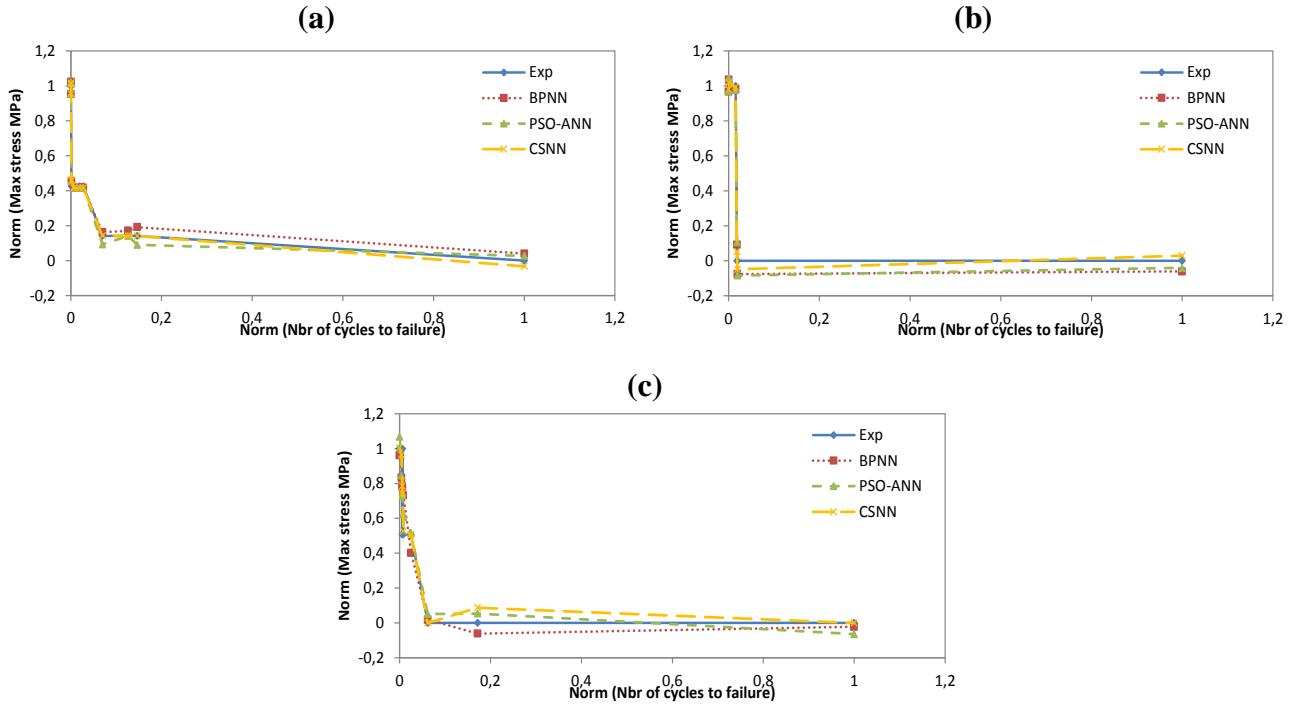
## 5. Results and discussion

In this section, we have used neural networks combined with three different algorithms (BP, PSO, and CS), called BPNN, PSO-ANN and CSNN respectively, as described in Section 4. These three hybrid models have been exploited to evaluate their effectiveness in predicting the fatigue life of wind turbine blade materials. The materials in question are composites based on thermosetting resins, namely the ortho-polyester resin (CoRezyn 63-AX-051), the iso-polyester resin (CoRezyn 75-AQ-010) and the two vinyl ester resins (Derakane 411C-50) and (Derakane 8084). In the first step, we have trained our NN with the BP algorithm with three different temperature: 50 °C wet, 20 °C dry and 20 °C wet, and this in order to preselect the best architecture of our network, which it will follow us throughout the evaluation and prediction process. The choice of the suitable architecture ends when the network converges or reaches a global minimum already predefined as an objective function (MSE). For the materials

considered, both experimental and predicted results obtained with BPNN, PSO-ANN and CSNN are compared in Figures 10-13 and show the relationship between the maximum applied compressive stress ( $\sigma_{\max}$ ) and the number of cycles to failure ( $N$ ). For illustration and comparative purposes, we have presented in the same figure and for each studied temperature four plots for different experimental and predicted values obtained with BPNN, PSO-ANN and CSNN, where they show typical fatigue life predictions. In all these figures, it can be noted that the prediction plots follow their experimental reference, which means the efficiency of the combinations we propose. However, CSNN plot is almost superimposed on that of the experimental, because of its simplicity of use of mathematical models in comparison with PSO-ANN, as well as its ability to adjust weights without determining a gradient by comparing with BPNN. In the training process, we found that BPNN and CSNN converged more quickly to a minimal error, whereas PSO-ANN requires a considerable number of iterations to do so.



**Figure 10.** Experimental and predicted values of ortho-polyester resin fatigue life (CoRezyn 63-AX-051). (a): T=50 °C wet; (b): T=50 °C dry; (c): T=20 °C wet; (d): T=20 °C dry

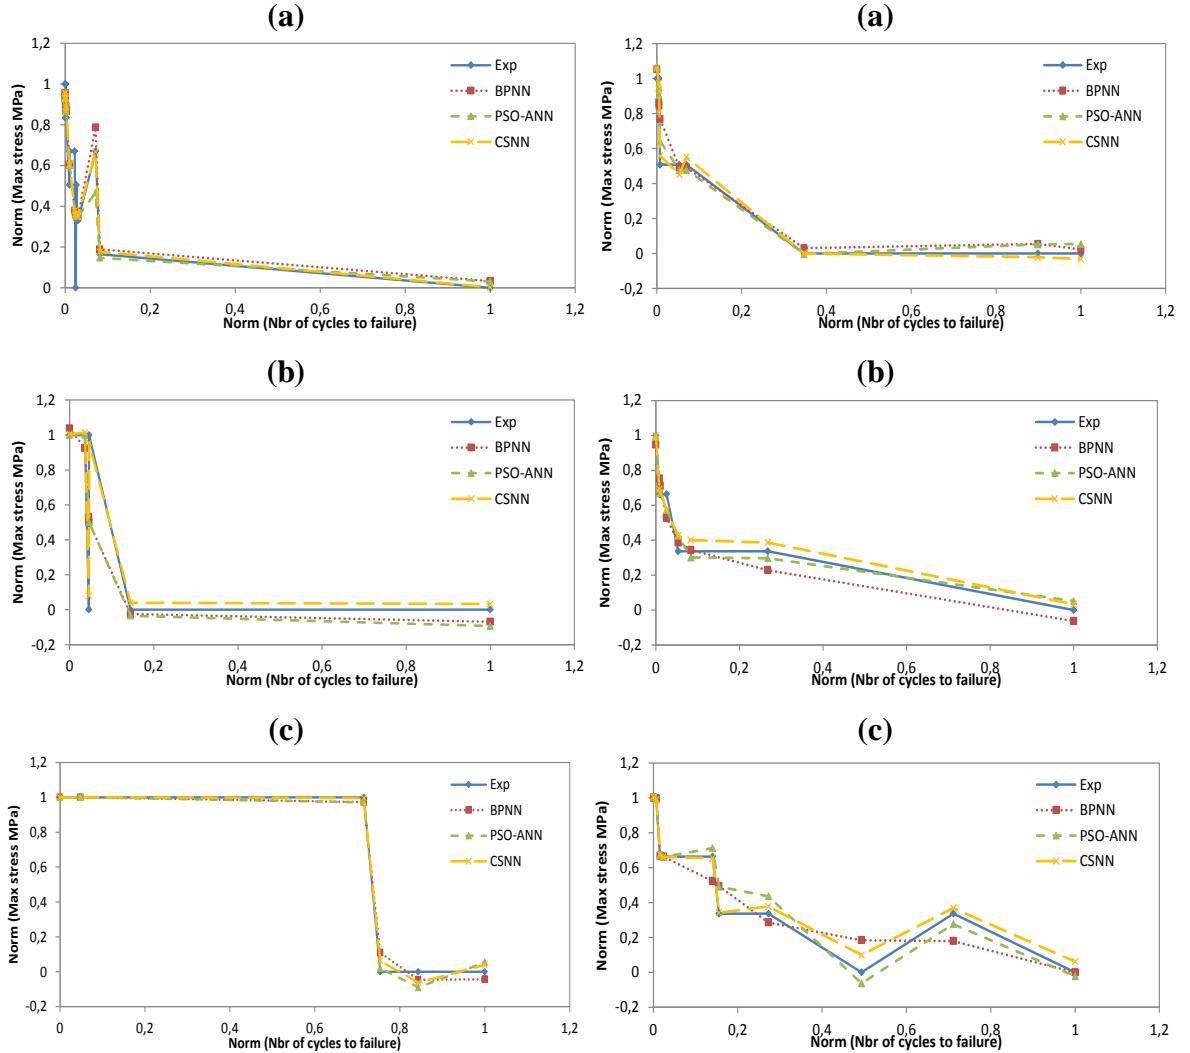


**Figure 13.** Experimental and predicted values of vinyl ester resin fatigue life (Derakane 8084). **(a):**  $T=50\text{ }^{\circ}\text{C}$  wet; **(b):**  $T=20\text{ }^{\circ}\text{C}$  dry; **(c):**  $T=20\text{ }^{\circ}\text{C}$  wet.

In terms of error, we further evaluated the erroneously predicted values for the three combinations used and presented their prediction errors in Table 5. The table contains the values of the root mean square errors (RMSE), number of epochs, CPU times and the prediction accuracies. It is clear that the prediction performance of CSNN is better than that of PSO-ANN and BPNN, with the exception of certain prediction values mentioned above. In the case of ortho-polyester, the maximum RMSE reaches at  $20\text{ }^{\circ}\text{C}$  dry 3.74% for BPNN, 3.74% for PSO-ANN and 3.87% for CSNN. At  $20\text{ }^{\circ}\text{C}$  dry in the case of iso-polyester, the maximum RMSR is about 29.96% for BPNN, 28.86% for PSO-ANN and 4.12% for CSNN. As for the case of vinyl ester (Derakane 411C-50), the maximum error reaches at  $50\text{ }^{\circ}\text{C}$  wet 11.26% for BPNN, 6.40% for PSO-ANN and 4.24% for CSNN. While the max RMSE at  $20\text{ }^{\circ}\text{C}$  wet of the vinyl ester (Derakane 8084) is 15.58% for BPNN, 13.92% for PSO-ANN and 12.68% for CSNN. In the same table, we can note that the lowest number of epochs corresponds to the CSNN combination, with the shortest calculation times and best prediction accuracies.

**Table 5.** RMSE, epochs and prediction accuracies for all materials and combinations.

Material	Environmental conditions	BPNN				PSO-ANN				CSNN			
		RMSE (%)	Epochs	CPU Time (s)	Accuracy (%)	RMSE (%)	Epochs	CPU Time (s)	Accuracy (%)	RMSE (%)	Epochs	CPU Time (s)	Accuracy (%)
Ortho-polyester (CoRezyn 63-AX-051)	50 °C wet	1.75	277	9.371	94.443	1.81	228	227.73	94.394	1.41	62	6.632	94.761
	50 °C dry	3.16	54	7.453	92.006	3.31	112	111.50	93.115	3.09	23	2.961	92.138
	20 °C wet	3.60	18	5.820	92.878	2.06	32	31.71	93.618	1.99	3	0.267	94.204
	20 °C dry	3.74	14	5.158	92.867	3.74	11	10.95	92.869	3.87	10	1.292	92.655
Iso-polyester (CoRezyn 75-AQ-010)	50 °C wet	12.56	1000	28.886	81.330	12.56	1000	909.09	81.333	12.56	1000	32.490	81.322
	20 °C dry	29.96	152	8.674	63.117	28.86	381	379.32	63.975	4.12	144	8.769	91.630
	20 °C wet	5.19	5	2.051	87.675	4.47	16	15.54	91.052	4	16	1.39	91.750
Vinyl ester (Derakane 411C-50)	50 °C wet	11.26	98	7.903	82.366	6.40	157	152.09	88.088	4.24	131	7.277	91.243
	20 °C dry	6.55	1000	28.760	86.078	4.79	1000	991.07	90.894	4.69	1000	32.327	90.113
	20 °C wet	9.79	133	8.342	84.611	6.55	416	414.17	87.879	1.96	327	11.168	94.131
Vinyl ester (Derakane 8084)	50 °C wet	1.90	122	8.197	94.248	1.86	169	158.43	94.312	1.84	112	8.023	94.344
	20 °C dry	5.29	195	8.847	87.141	6.08	217	210.21	88.496	3.14	259	10.806	92.018
	20 °C wet	15.58	599	17.299	77.753	13.92	627	621.40	79.504	12.68	1000	32.112	81.102



**Figure 11.** Experimental and predicted values of iso-polyester resin fatigue life (CoRezyn 75-AQ-010). (a): T=50 °C wet; (b): T=20 °C dry; (c): T=20 °C wet.

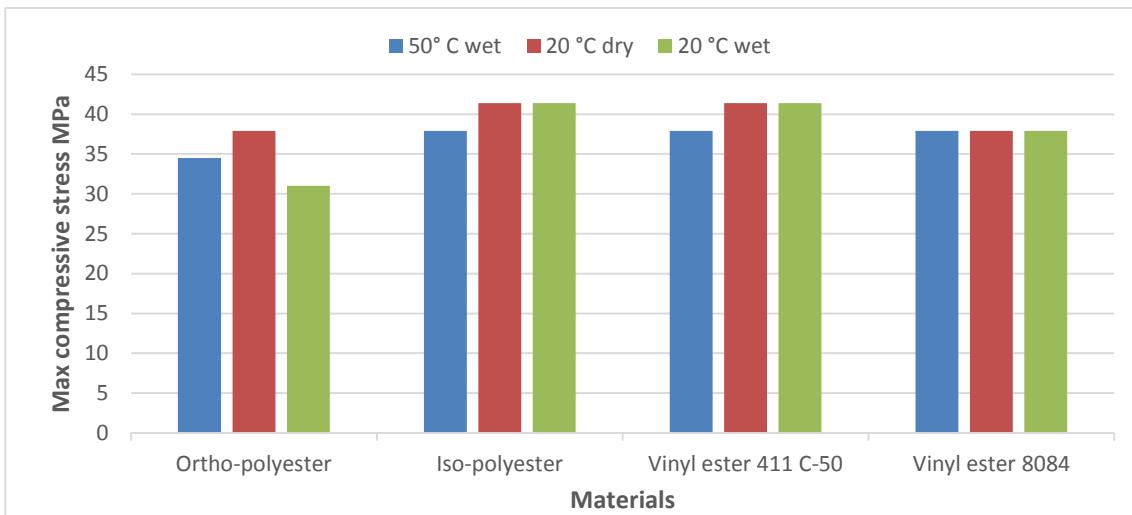
**Figure 12.** Experimental and predicted values of vinyl ester resin fatigue life (Derakane 411C-50). (a): T=50 °C wet; (b): T=20 °C dry; (c): T=20 °C wet.

To make these results more clear, we had to use a bar chart to quantify the comparison. The different materials studied were compared in Figure 14 in terms of the maximum compressive stress and according to the hygrothermal conditions. The values shown on the Figure were taken directly from the source database without normalization. According to the figure, the iso-polyester and the vinyl ester 411 C-50 have a high fatigue strength compared to the two remaining. The decrease in the fatigue strength is very significant for the ortho-polyester at

20 °C. On the other hand, the vinyl ester 8084 still retains the same fatigue strength, regardless of the hydrothermal effect. All materials showed a significant decrease at 50 °C.

## 6. Conclusion

The use of artificial neural networks in the evaluation of composite materials of wind turbine blades will be considered as an alternative and economical solution. This will also allow us to reduce the duration of laboratory tests and let the network predict fatigue life. Depending on the results obtained, it is possible to propose iso-polyester and vinylester 411 C-50 as the most appropriate resins for an eventual design of wind turbine blades, under the hydrothermal effect, and this, from a lifetime and strength standpoint.



**Figure 14.** Fatigue strength comparison of all resins investigated

The proposed hybrid neural network models BPNN, PSO-ANN and CSNN reproduce the same non-linear characteristics obtained in the laboratory with an acceptable error. The key element that can decide the quality of prediction and learning is simply the database, which must be relatively consistent for the network to predict future values with minimal error. The ANN architecture (number of neurons, topology, etc.) is also considered as an important factor deciding the quality of learning more than the learning parameters. We have pointed out that the CSNN is better than the BPNN and PSO-ANN in terms of prediction, because of its simplicity of use of mathematical models, as well as its ability to adjust weights without determining a gradient. CSNN gave us better fatigue life predictions, faster computation, more accuracy and above all, a high convergence rate at the true global minimum.

More research is needed to determine the possibility of finding specific combinations that always lead to the best predictions of fatigue life, as well as to improve the accuracy of ANN using other optimization algorithms in the phase of learning.

## References

- Anga, J.Y., Abdul Majida, M.S., Mohd Norb, A., Yaacobc, S., Ridzuana, M.J.M. First-ply failure prediction of glass/epoxy composite pipes using an artificial neural network model. *Composite Structures*, vol. 15, pp. 579-588, 2018.
- Agastra, P., Samborsky, D. D., and Mandell, J. F., Fatigue resistance of fiberglass laminates at thick material transitions, Proc. 50th AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics and Materials Conf., California, USA, pp. 1–23, 2009.
- Al-Assaf, Y. and El-Kadi, H., Fatigue life prediction of unidirectional glass fiber/epoxy composite laminae using neural networks, *Compos. Struct.*, vol. 53, no. 1, pp. 65–71, 2001.
- Attaf, B. Eco-conception et développement des pales d'éoliennes en matériaux composites. *Revue des Energies Renouvelables SMEE'10* Bou Ismail Tipaza. pp. 37–48, 2010.
- Ding J, He X, Jiang B, Wu Y. Parameter identification for area-specific resistance of direct methanol fuel cell using cuckoo search algorithm. In Bio-Inspired Computing - Theories and Applications. Gong M, Linqiang P, Tao S, Tang K, Zhang X, Eds.; Springer: Heidelberg, Germany, 2015; pp. 107-112.
- Gudise, V. G. and Venayagamoorthy, G. K., Comparison of particle swarm optimization and backpropagation as training algorithms for neural networks, Proc. IEEE Swarm Intelligence Symposium SIS'03, Indianapolis, USA, pp. 110–117, 2003.
- Kennedy, J. and Eberhart, R., Particle swarm optimization, Proc. IEEE Int. Conf. on Neural Networks, Perth, WA, pp. 1942–1948, 1995.
- Li M (2000) Temperature and moisture effects on composite materials for wind turbine blades. MS Thesis. Montana State University, Bozeman, MT.
- Mandell J, Samborsky DD, Li M. Selection of fiberglass matrix resins for increased toughness and environmental resistance in wind turbine blades. *AIAA Journal* 57(1): 354–366, 2000.
- Mandell, J. F., Samborsky, D. D., Agastra, P., Sears, A. T., and Wilson, T. J., Analysis of SNL/MSU/ DOE Fatigue Database Trends for Wind Turbine Blade Materials, SANDIA National Laboratories, SAND2010-7052, 2010.

Nawi NM, Khan A, Rehman MZ. A new back-propagation neural network optimized with cuckoo search algorithm. International Conference on Computational Science and Its Applications. Ho Chi Minh, 2013.

Nijssen, R.P.L. (2006), “Fatigue life prediction and strength degradation of wind turbine rotor blade composites”, Ph.D. Dissertation, Delft University the Netherlands, Delft.

Samborsky, D. D., Agastra, P., and Mandell, J. F., Fatigue trends for wind blade infusion resins and fabrics, Proc. 51st AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conf., Florida, USA, 2010.

Samborsky DD, Mandell J and Cairns DS (1999) Selection of reinforcing fabrics for wind turbine blades. AIAA Journal 24(6): 32–42.

SNL/MSU/DOE Composite Material Fatigue Database. Mechanical properties of composite materials for wind turbine blades. Montana State University-Bozeman, Version 25.0, Available online: <http://energy.sandia.gov/> (accessed on 20 October 2016).

Vassilopoulos, A. P., Georgopoulos, E. F., and Dionysopoulos, V., Artificial neural networks in spectrum fatigue life prediction of composite materials, Int. J. Fatigue, vol. 29, no. 1, pp. 20–29, 2007.

Yang XS, Deb S. Cuckoo search via Lévy flights. World Congress on Nature & Biologically Inspired Computing. India, 2009.

Yi J, Xu W, Chen Y. Novel back propagation optimization by cuckoo search algorithm. The Scientific World Journal, 2014. <http://dx.doi.org/10.1155/2014/878262>.

Zhang, J. R., Zhang, J., Lok, T. M., and Lyu, M. R., A hybrid particle swarm optimization-back-propagation algorithm for feedforward neural network training, Appl. Math. Computation, vol. 185, no. 2, pp. 1026–1037, 2007.

Ziane K, Zebirate S, Zaitri A. Fatigue strength prediction in composite materials of wind turbine blades under dry-wet conditions: An artificial neural network approach. Wind Engineering. 2016; 40:189-198.

Ziane K, Zebirate S, Zaitri A. Particle swarm optimization-based neural network for predicting fatigue strength in composite laminates of wind turbine blades. Composites: Mechanics, Computations, Applications: An International Journal. 2015; 6:321-338.

Ziane K. Analyse, évaluation et réduction des risques d'un parc éolien. PhD Dissertation, Université d'Oran 2 Mohamed Ben Ahmed, Oran, 2017.

## CONCLUSION GÉNÉRALE

Les matériaux des pales d'éoliennes et leurs tests de fatigue ont attiré l'attention de nombreux chercheurs et de la communauté universitaire en général. Cependant, notre recherche et notre revue de la littérature n'ont trouvé aucune étude sur l'application de méthodes d'intelligence artificielle sur la prédiction du comportement à la fatigue des matériaux des pales d'éoliennes. Les résultats les plus représentatifs en utilisant le moteur de recherche Google avec les mots clés « *Artificial intelligence in fatigue life prediction of wind turbine materials* » sont les travaux que nous avons publiés auparavant [13, 14].

L'un des problèmes posés par les éoliennes en termes d'ingénierie réside dans la charge variable à laquelle les pales de rotor sont soumises. Ceci peut avoir un impact négatif sur leurs performances et peut même entraîner des pannes prématuées. De tels défauts peuvent faire obstacle à l'adoption des éoliennes pour la production d'électricité, en particulier sur les installations au large (offshore) qui sont difficiles d'accès.

L'analyse du comportement dynamique des pales a un rôle primordial dans la conception des aérogénérateurs, car ces pales sont soumises à des forces de vent très variables favorisant ainsi le cumul de la fatigue, sachant que ce phénomène est l'un des problèmes majeurs qui entravent le bon fonctionnement des éoliennes.

Pour modéliser ce phénomène « fatigue », nous avons utilisé les RNA pour prédire le comportement en fatigue, tels que la durée de vie ainsi que la tenue en fatigue. Les RNA appliqués dans ce mémoire ont mis en lumière les conclusions suivantes :

- Les limitations des méthodes traditionnelles de prédiction de la fatigue qui se basent sur l'expérience humaine, d'où la nécessité d'utiliser les réseaux de neurones (RN) qui peuvent apporter d'excellents résultats ;
- La prédiction du comportement en fatigue des pales d'éoliennes peut aider considérablement à améliorer la qualité de leur prévention ;

- La réduction du temps des essais aux laboratoires, ce qui réduit aussi le coût ;
- Corriger et ajuster les essais expérimentaux par la régression linéaire des valeurs prédictives ;
- Optimiser l'erreur quadratique moyenne entre les résultats expérimentaux et prédictifs ;
- La taille et la qualité de la base de données ont une influence majeure sur l'apprentissage des RNA. C'est la raison pour laquelle le choix d'une base de données est parfois le seul paramètre décisif de la qualité de l'apprentissage ;
- L'architecture du RNA (nombre de couches cachées, nombre de neurones, fonctions d'activations) est un facteur important décisif de la qualité de l'apprentissage plus que les paramètres d'apprentissage (taux d'apprentissage) ;
- Un réseau supervisé entraîné par un algorithme métaheuristique pour la prédiction donne des résultats ayant une précision et une souplesse meilleures qu'avait chacun d'eux séparément ;
- Les modèles de réseaux neuronaux hybrides proposés BPNN, PSO-ANN et CSNN reproduisent les mêmes caractéristiques non linéaires obtenues en laboratoire avec une erreur acceptable.
- CSNN est une très bonne combinaison pour les applications qui nécessitent un apprentissage/convergence rapide, en raison de sa simplicité d'utilisation des modèles mathématiques, ainsi que de sa capacité à ajuster les poids sans déterminer de gradient;
- CSNN nous a donné de meilleures prédictions de la durée de vie en fatigue, des calculs plus rapides, plus de précision et surtout, un taux de convergence élevé au minimum global.
- La bonne sélection des paramètres de l'algorithme CS joue un rôle clé dans l'optimisation ;

Par l'utilisation des méthodes de l'intelligence artificielle (BPNN, PSO-ANN, CSNN), nous avons pu créer un modèle capable de prédire la durée de vie et la tenue en fatigue de plusieurs matériaux composites stratifiés, sous l'effet de plusieurs facteurs (environnement, orientation de fibres...). En outre, les résultats obtenus par les RNA nous ont aidés à proposer quelques types de matériaux composites de point de vue durabilité et durées de vie pour une éventuelle conception des pales d'éoliennes, en prenant en considération les points suivants:

- Les matériaux à base de tissu UD conservent une bonne résistance à la fatigue par traction par rapport à ceux à base de tissu MD ;
- La fibre de verre/époxy (EP1) et la fibre de verre/vinylester (VE4) sont les moins sensibles à l'orientation des fibres parmi les cinq matériaux étudiés ;
- La température et l'humidité ont des effets très importants sur la tenue en fatigue des matrices de résine.

En fonction des résultats obtenus, il est possible de proposer l'iso-polyester et le vinylester 411 C-50 comme résines les plus appropriées pour une éventuelle conception de pales d'éoliennes, sous l'effet hydrothermal, et ce, du point de vue de la durée de vie et de la tenue en fatigue.

## **PERSPECTIVES**

Le présent travail est loin d'être achevé. Plusieurs points peuvent être traités en perspectives futures :

- Des recherches supplémentaires seront nécessaires pour déterminer la possibilité de trouver des combinaisons uniques dont résultent toujours les meilleures prédictions de la fatigue.
- Développer la filière des matériaux composites, et ce, dans l'espoir d'établir une activité de recherche et d'innovation dans le domaine des énergies renouvelables et particulièrement de l'énergie éolienne.

- Moderniser le procédé de fabrication des pales d'éoliennes avec la prise en compte des aspects d'ecoconception et d'autre part, développer et améliorer des procédures de qualification, de réparation et de recyclage après la fin de vie de ces pales.
- Analyser d'autres risques qui peuvent dégrader la structure éolienne.

## RÉFÉRENCES BIBLIOGRAPHIQUES

- [1] Chehouri, R. Younes, J. Perron, A. Ilinca – “Optimal design for a composite wind turbine blade with fatigue and failure constraints”, Transactions of the Canadian Society for Mechanical Engineering, vol. 39, no.1, 2015
- [2] Chehouri, R. Younes, A. Ilinca, J. Perron – “Review of Performance Optimization Techniques Applied to Wind Turbines”, Applied Energy, v.142, pp. 361-388, 2015
- [3] Attaf. B: Eco-conception et développement des pales d'éoliennes en matériaux composites. Revue des Energies Renouvelables SMEE'10, pp.37-48, 2010
- [4] Yang XS, Deb S. Cuckoo search via Lévy flights. World Congress on Nature & Biologically Inspired Computing. India. 2009.
- [5] Attaf. B: Eco-moulage des Pales d'Eoliennes et Panneaux Solaires en Matériaux Composites via la Technologie RTM. Journal of Fundamental and Applied Sciences Vol. 2 (1), pp.35-46, 2010
- [6] Tardif. T: Modélisation et analyse des phénomènes aéroélastiques pour une pale d'éolienne. Thèse de MS, UQAR, Rimouski (Canada), 2009
- [7] Prombut. P: Caractérisation de la propagation de délaminage des stratifiés composites multidirectionnels. Université Paul Sabatier, Toulouse (France), 2007
- [8] Hachmane. B: Analyse expérimentale du comportement mécanique d'un matériau composite soumis à des sollicitations d'impact. Thèse de Doctorat, UMBB, Boumerdes (Algérie), 2013
- [9] Djouabi. N: Analyse de l'endommagement de plaque composite en verre/époxy soumises à la fatigue par chocs. Mémoire de Magister. UMBB, Boumerdes (Algérie), 2012.

- [10] Attaf . B: Pales d'Eoliennes: Procédés de Fabrication, Procédures de Qualification, Réparation et Recyclage. Rendez-vous du Composite, Marché spécial éolien, Gosnay (France), 2012
- [11] Renard. J: Fatigue des matériaux composites renforcés de fibres continues. Techniques de l'ingénieur AM 5410.
- [12] Maltais. P: Développement d'une méthode de prédition de la durée de vie en fatigue de structures tubulaires soudées en aluminium. Mémoire de maîtrise, UQAC, Chicoutimi (Canada), 2008
- [13] Encyclopédie libre Wikipédia : [https://fr.wikipedia.org/wiki/Courbe\\_de\\_W%C3%B6hler](https://fr.wikipedia.org/wiki/Courbe_de_W%C3%B6hler) (consulté le 10 Janvier 2020)
- [14] Darwiche. M: 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. Thèse de Doctorat, Université du Maine, France, 2013.
- [15] Ziane K. Analyse, évaluation et réduction des risques d'un parc éolien. PhD Dissertation, Université d'Oran 2 Mohamed Ben Ahmed, Oran, 2017.
- [16] Ziane K, Zebirate S, Zaitri A. Particle swarm optimization-based neural network for predicting fatigue strength in composite laminates of wind turbine blades. Composites: Mechanics, Computations, Applications: An International Journal. 2015; 6:321-338.
- [17] Ziane K, Zebirate S, Zaitri A. Fatigue strength prediction in composite materials of wind turbine blades under dry-wet conditions: An artificial neural network approach. Wind Engineering. 2016; 40:189-198.