



الجمهورية الجزائرية الديمقراطية الشعبية  
REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

MINISTRE DE L'ENSEIGNEMENT SUPERIEUR  
ET DE LA RECHERCHE SCIENTIFIQUE

جامعة الشهيد الشيخ العربي التبسي – تبسة

Université Echahid Cheikh Larbi Tebessi – Tébessa –

Faculté des Sciences et de la Technologie

Département de Génie Mécanique



## THÈSE DE DOCTORAT

Présentée pour l'obtention du **diplôme de Doctorat LMD**

Spécialité : GÉNIE MÉCANIQUE

Option : CONSTRUCTION MECANIQUE

Présentée par :

**FISSAH BELGACEM**

---

### MODÉLISATION DE LA RÉSISTANCE AU CHOC THERMIQUE D'UN MATÉRIAU FRAGILE : CÉRAMIQUE DE TYPE ALUMINE ( $Al_2O_3$ )

---

Présentée et soutenue publiquement, le **19/03/2023**, devant le jury composé de :

|                       |  |                               |
|-----------------------|--|-------------------------------|
| <b>A.N. BELAZIZIA</b> | Pr, Université Echahid Cheikh Larbi Tebessi, Tébessa       | <b>Président</b>              |
| <b>H. BELGHALEM</b>   | MCA, Université Echahid Cheikh Larbi Tebessi, Tébessa      | <b>Directeur de thèse</b>     |
| <b>B. MAMEN</b>       | MCA, Université Echahid Abbes Laghrour, Khenchela          | <b>Co- Directeur de thèse</b> |
| <b>M.T. HANNACHI</b>  | Pr, Université Echahid Cheikh Larbi Tebessi, Tébessa       | <b>Examineur</b>              |
| <b>B. CHERMIME</b>    | MCA, Université Echahid Abbes Laghrour, Khenchela          | <b>Examineur</b>              |
| <b>A.L. SAHRAOUI</b>  | MCA, Université Echahid Cheikh Larbi Tebessi, Tébessa      | <b>Examineur</b>              |
| <b>M.DJEDDOU</b>      | Pr, Université Echahid Larbi ben El M'hidi, Oum El Bouaghi | <b>Invité</b>                 |

2022/2023

# Remerciements

Cette étude a été réalisée dans le laboratoire des mines (Université Echahid Cheikh Larbi Tebessi, Tébessa). J'adresse mes remerciements et ma gratitude au directeur du laboratoire, le **professeur Harakati El-Hadi**.

J'exprime ma gratitude au professeur superviseur, **Dr Hadj Belghalem**, pour ses orientations, ses conseils, sa patience et son accompagnement constant à mon égard. Je remercie également le Co-superviseur, **Dr Belgacem Mamen** de l'Université Abbas Laghrour Khenchela, pour son aide et ses encouragements. Ce soutien et ces encouragements m'ont toujours offert un environnement de travail très agréable et chaleureux, ce qui m'a motivé à travailler avec détermination et sérieux.

Des remerciements sont également adressés au **Professeur Djeddou Massaoud** de l'Université de Larbi Ben m'hidi Oum El Bouaghi pour son soutien et sa contribution efficace.

Un grand merci à tous les membres du jury, au **professeur Abdennacer Belazizia** de l'université de Tébessa pour avoir accepté la présidence du jury et aux membres du jury, le **professeur Mohamed Tahar Hanachi** de l'université de Tébessa, le **Dr Chermime Brahim** de l'Université Abbas Laghrour Khenchela et le **Dr Abdelatif Sahraoui** de l'université de Tébessa

Les remerciements ne seront pas complets sans remercier le chef du département de génie mécanique, **Dr Rabah Agoune** et tous les professeurs respectés de notre département.

# Résumé

Ce travail porte sur la modélisation de la résistance aux chocs thermiques d'un matériau fragile : les céramiques de type Alumine ( $Al_2O_3$ ) par des réseaux de neurones artificiels. Considérant que les méthodes classiques sont très coûteuses en termes de mise en œuvre expérimentale et nécessitent beaucoup de temps et en raison du chevauchement et de l'influence de nombreux paramètres qui doivent être contrôlés.

Notre contribution est de modéliser de manière prédictive la résistance aux chocs thermiques de l'alumine dans les meilleurs délais et avec une grande efficacité. Nous avons utilisé des modèles de réseaux de neurones simples et hybrides.

L'efficacité des réseaux utilisés a été testée à l'aide d'un ensemble de critères statistiques utilisés dans la littérature scientifique dans ce domaine, mais pour que les résultats prédictifs obtenus soient applicables, ils ont été comparés aux résultats expérimentaux. Il a été constaté dans cette étude que notre approche a un grand potentiel pour modéliser la relation entre le paramètre de résistance au choc thermique et les paramètres d'élaboration et physiques qui sont difficiles à modéliser à l'aide de modèles mathématiques. L'efficacité du modèle prédictif obtenu est convaincante.

Ces travaux ouvrent des perspectives prometteuses pour le contrôle des paramètres affectant la résistance aux chocs thermiques des matériaux céramiques. Elle peut être généralisée et exploitée sur d'autres matériaux fragiles ayant des propriétés physiques similaires à l'alumine.

---

**Mots clés :** Modélisation, Réseaux de Neurones Artificiels, Choc Thermique, Alumine

# Abstract

This work deals with the modeling of the thermal shock resistance of a brittle material: Alumina ( $Al_2O_3$ ) type ceramics by artificial neural networks. Considering that, classical methods are very expensive in terms of experimental implementation and require a lot of time because of the overlapping and influence of many parameters that must be controlled.

Our contribution is to predictively model the thermal shock resistance of alumina in the shortest possible time and with high efficiency. We have used simple and hybrid neural network models.

The effectiveness of the networks used was tested using a set of statistical criteria used in the scientific literature in this area, but for the predictive results obtained to be applicable, they were compared to experimental results.

It was found in this study that our approach has great potential to model the relationship between the thermal shock resistance parameter and the processing and physical parameters that are difficult to model using mathematical models. The effectiveness of the resulting predictive model is convincing.

This work opens promising perspectives for the control of parameters affecting the thermal shock resistance of ceramic materials. It can be generalized and exploited on other brittle materials with physical properties similar to alumina.

---

**Keywords :** Modeling, Artificial Neural Networks, Thermal Shock, Alumina



## نمذجة مقاومة الصدمات الحرارية لمادة هشة: السيراميك من نوع الألومينا ( $Al_2O_3$ )

### المخلص:

يتعلق هذا العمل بنمذجة مقاومة الصدمات الحرارية لمادة هشة: سيراميك من نوع الألومينا ( $Al_2O_3$ ) بواسطة الشبكات العصبية الاصطناعية. بالنظر إلى أن الطرق الكلاسيكية مكافئة للغاية من حيث إنجازها تجريبيا وتتطلب وقتا كبيرا ونظرا لتداخل وتأثير العديد من المعلمات التي يجب التحكم فيها.

تتمثل مساهمتنا في نمذجة تنبؤية لخاصية مقاومة الصدمة الحرارية لمادة الألومينا في أسرع وقت وبكفاءة عالية. استخدمنا نماذج من الشبكات العصبية البسيطة والمُهجنة. تم اختبار كفاءة الشبكات المستعملة باستعمال مجموعة من المعايير الإحصائية المستعملة في الأدبيات العلمية في هذا المجال ومع ذلك، لكي تكون النتائج التنبؤية المُحصل عليها قابلة للتطبيق، تم مقارنتها بالنتائج التجريبية.

وُجد في هذه الدراسة أن نهجنا لديه إمكانيات كبيرة لنمذجة العلاقة التي تربط الصدمة الحرارية بمعلمات الانشاء والمعلمات الفيزيائية والتي يصعب وصفها باستخدام النماذج الرياضية. كفاءة النموذج التنبؤي المُحصل عليه مقنعة. يسمح هذا العمل بفتح آفاق واعدة بخصوص التحكم في المعلمات المؤثرة في مقاومة الصدمة الحرارية للمواد السيراميكية. يمكن تعميمها واستغلالها على مواد هشة أخرى ذات خصائص فيزيائية مشابهة لمادة الألومينا.

---

الكلمات المفتاحية: الشبكات العصبية الاصطناعية، الصدمة الحرارية، الألومينا.

# Table des matières

|  |             |
|--|-------------|
| <b>Remerciements</b>   | <b>i</b>    |
| <b>Résumé</b>  | <b>ii</b>   |
| <b>Abstract</b>  | <b>iii</b>  |
| <b>Résumé en arabe</b>                                       | <b>iv</b>   |
| <b>Table des matières</b>                                    | <b>iv</b>   |
| <b>Liste des figures</b>                                     | <b>viii</b> |
| <b>Liste des tableaux</b>                                    | <b>xi</b>   |
| <b>Introduction générale</b>                                 | <b>13</b>   |
| <b>1 Etude Bibliographique</b>                               | <b>16</b>   |
| 1 Introduction . . . . .                                     | 17          |
| 2 Les réseaux de neurones artificiels en matériaux . . . . . | 17          |
| 2.1 Généralités sur la céramique . . . . .                   | 21          |
| 2.1.1 Définition de la céramique . . . . .                   | 21          |
| 2.2 Classification des matériaux céramiques . . . . .        | 22          |
| 2.3 Classification des céramiques techniques . . . . .       | 23          |
| 2.3.1 Classification selon la composition . . . . .          | 23          |
| 2.3.2 Classification selon leurs applications . . . . .      | 24          |
| 2.4 Propriétés générale des céramiques . . . . .             | 26          |
| 2.5 L'alumine . . . . .                                      | 26          |
| 2.5.1 Production de l'alumine . . . . .                      | 26          |
| 2.5.2 L'alumine structure et propriétés . . . . .            | 26          |
| 2.6 Elaboration des céramiques . . . . .                     | 28          |
| 2.6.1 Traitement des poudres céramiques . . . . .            | 28          |
| 2.6.2 Mise en forme des poudres céramiques . . . . .         | 29          |
| 2.6.3 Traitement thermique . . . . .                         | 31          |
| 2.7 L'élaboration des échantillons . . . . .                 | 33          |
| 3 Conclusion . . . . .                                       | 38          |

|          |   |           |
|----------|---|-----------|
| <b>2</b> | <b>Choc thermique</b>   | <b>42</b> |
| 1        | Introduction . . . . .  | 43        |
| 2        | Mécanismes de transfert de chaleur . . . . .                        | 43        |
| 2.1      | Résistance aux chocs thermiques . . . . .                           | 46        |
| 2.2      | Paramètres de choc thermique (paramètres R) . . . . .               | 46        |
| 2.2.1    | Approche thermoélastique . . . . .                                  | 46        |
| 2.2.2    | Approche énergétique . . . . .                                      | 48        |
| 2.2.3    | Approche en termes de FIC . . . . .                                 | 50        |
| 3        | Essai de Choc Thermique . . . . .                                   | 50        |
| 3.1      | Procédure Expérimentale . . . . .                                   | 50        |
| 3.2      | Ecart de température critique . . . . .                             | 52        |
| 4        | Conclusion . . . . .  | 54        |
| <b>3</b> | <b>Réseaux de neurones</b>  | <b>57</b> |
| 1        | Introduction . . . . .  | 58        |
| 2        | Du neurone biologique au neurone formel . . . . .                   | 60        |
| 3        | Classes de réseaux de neurones . . . . .                            | 63        |
| 3.1      | Réseau de neurones non bouclé . . . . .                             | 63        |
| 3.2      | Réseau de neurones bouclé (ou récurrent) . . . . .                  | 64        |
| 4        | Types de réseaux de neurones . . . . .                              | 64        |
| 5        | Fonctionnement d'un réseau . . . . .                                | 66        |
| 6        | L'apprentissage . . . . .   | 67        |
| 6.1      | L'apprentissage supervisé . . . . .                                 | 67        |
| 6.2      | L'apprentissage non-supervisé . . . . .                             | 67        |
| 6.3      | L'apprentissage par renforcement . . . . .                          | 68        |
| 6.4      | Règles d'apprentissage . . . . .                                    | 68        |
| 7        | Configuration optimale du réseau neuronal . . . . .                 | 74        |
| 8        | Avantage des réseaux neuronaux . . . . .                            | 74        |
| <b>4</b> | <b>Résultats et discussions</b>                                     | <b>78</b> |
| 1        | Introduction . . . . .  | 80        |
| 1        | Base de données . . . . .   | 82        |
| 1.1      | La densité . . . . .  | 82        |
| 1.2      | Le module de Young . . . . .  | 82        |
| 1.3      | La contrainte à la rupture . . . . .                                | 83        |
| 1.4      | La ténacité . . . . .   | 83        |
| 2        | Modélisation des paramètres mécaniques . . . . .                    | 84        |
| 2.1      | Méthodes utilisées . . . . .  | 84        |
| 2.1.1    | Régression linéaire multiple . . . . .                              | 84        |
| 2.1.2    | Réseau de neurones à fonction de base radiale (RBFNN) . . . . .     | 84        |
| 2.2      | Résultats et discussion . . . . .                                   | 85        |
| 2.2.1    | Résultats de la régression . . . . .                                | 85        |
| 2.2.2    | Résultats RBFNN . . . . .   | 88        |
| 2.2.3    | Comparaison des Résultats Prédits et Expérimentaux . . . . .        | 91        |
| 2.2.4    | Conclusions . . . . .   | 93        |
| 3        | Modélisation du paramètre de résistance au choc thermique . . . . . | 94        |
| 3.1      | Méthodes utilisées . . . . .  | 94        |

---

|                                   |   |            |
|-----------------------------------|---|------------|
| 3.1.1                             | Théorie de l'entropie de Shannon . . . . .                | 96         |
| 3.1.2                             | Réseau neuronal à régression généralisée (GRNN) . . . . . | 97         |
| 3.1.3                             | Machines d'apprentissage extrême (ELM) . . . . .          | 99         |
| 3.2                               | Évaluation des performances . . . . .                     | 100        |
| 3.3                               | Résultats et discussions . . . . .                        | 100        |
| 3.3.1                             | Modèle M1 (6 entrées) . . . . .                           | 102        |
| 3.3.2                             | Modèle M2 (4 entrées) . . . . .                           | 104        |
| 3.4                               | Conclusion . . . . .                                      | 110        |
| <b>Conclusion et perspectives</b> |   | <b>115</b> |
| 1                                 | Conclusions de l'étude . . . . .                          | 115        |
| <b>Liste des publications</b>     |   | <b>118</b> |

# Liste des figures

|      |   |    |
|------|---|----|
| 1.1  | Variation des paramètres mécaniques en fonction des propriétés physiques (densité et granulométrie) . . . . .   | 20 |
| 1.2  | Variation des paramètres mécaniques en fonction des propriétés physiques (densité et granulométrie) . . . . .   | 20 |
| 1.3  | Classification des céramiques. . . . .  | 23 |
| 1.4  | Structure hexagonal d'alumine $\alpha$ ( $Al_2O_3$ ) [21] . . . . .   | 27 |
| 1.5  | Pressage uniaxial . . . . .   | 29 |
| 1.6  | Représentation schématique de la technique de pressage isostatique. . . . .   | 30 |
| 1.7  | Cycles de déliantage et de frittage [24]. . . . .   | 32 |
| 1.8  | Les caractéristiques d'un appareil SPS [17]. . . . .  | 33 |
| 1.9  | La forme de moule utilisé pour le coulage en barbotine . . . . .  | 34 |
| 1.10 | Les étapes de la procédure d'élaboration par coulage en barbotine. . . . .  | 35 |
| 1.11 | cycle de séchage [24]. . . . .  | 36 |
| 1.12 | Étapes de préparation des échantillons : a) moule-pistons, b) pose de feuille de graphite c) assemblage moule - pistons – feuille de graphite, d) Installation du groupe entre les presses de la machine SPS, e) Installation du fil d'impulsion de courant électrique, f) échantillon pendant le processus de frittage . . . . . | 37 |
| 2.1  | Variation de la différence de température critique $\Delta T_c$ responsable de la propagation des fissures. Selon le modèle de Hasselman en fonction de la longueur $a$ et de la densité volumique des fissures $N$ . ( $\mu_0 = 0.25$ ) [10] . . . . .   | 49 |
| 2.2  | Dispositif de choc thermique . . . . .  | 51 |
| 2.3  | Un schéma simplifié de l'appareil . . . . .   | 51 |
| 2.4  | Une indentation Vickers sur un échantillon . . . . .  | 52 |
| 2.5  | Spectre d'EA obtenu pour l'alumine ( $\alpha - Al_2O_3$ ) à $\Delta T = 1000^\circ C$ . . . . .   | 53 |
| 3.1  | Le cadre de la recherche réalisée en appliquant les réseaux de neurones artificiels dans de nombreux domaines [1] . . . . .   | 59 |
| 3.2  | Mise en correspondance entre : a) neurone biologique et b) neurone artificiel. . . . .  | 61 |
| 3.3  | Un réseau de neurone non bouclé. . . . .  | 63 |
| 3.4  | Un Structure d'un réseau de neurone récurrent (bouclé). . . . .   | 64 |
| 3.5  | Un neurone artificiel. . . . .  | 66 |
| 3.6  | Un Organigramme d'Apprentissage. . . . .  | 70 |
| 3.7  | Un Neurone artificiel. . . . .  | 71 |

|      |   |     |
|------|---|-----|
| 4.1  | Variation des paramètres mécaniques en fonction des propriétés physiques (densité et granulométrie) . . . . .   | 81  |
| 4.2  | Schéma illustratif des entrées et sorties utilisées pour construire les modèles . . .   | 81  |
| 4.3  | Mesure du module de Young (méthode dynamique). . . . .  | 82  |
| 4.4  | Montage de flexion 4 points. . . . .  | 83  |
| 4.5  | Modèle de structure de réseau neuronal à fonction de base radiale (RBFNN). . .  | 84  |
| 4.6  | Comparaison entre les résultats prédits et expérimentaux pour le module de Young.   | 88  |
| 4.7  | Valeurs expérimentales et prédites du module de Young avec le coefficient de corrélation. . . . .   | 89  |
| 4.8  | Comparaison entre les résultats prédits et expérimentaux pour la résistance à la rupture. . . . .   | 89  |
| 4.9  | Valeurs expérimentales et prédites de la résistance à la rupture avec le coefficient de corrélation. . . . .  | 90  |
| 4.10 | Valeurs expérimentales et prédites de la résistance à la rupture avec le coefficient de corrélation. . . . .  | 91  |
| 4.11 | Valeurs expérimentales et prédites de la résistance à la rupture avec le coefficient de corrélation. . . . .  | 91  |
| 4.12 | Valeurs expérimentales et prédites de la résistance à la rupture avec le coefficient de corrélation. . . . .  | 92  |
| 4.13 | Valeurs expérimentales et prédites de la résistance à la rupture avec le coefficient de corrélation. . . . .  | 93  |
| 4.14 | Valeurs expérimentales et prédites de la résistance à la rupture avec le coefficient de corrélation. . . . .  | 93  |
| 4.15 | Organigramme de procédure pour les analyses numériques utilisées dans la prédiction de la température critique de choc thermique de l'alumine. . . . .      | 95  |
| 4.16 | Diagramme explicatif de la théorie de l'entropie de Shannon. . . . .  | 97  |
| 4.17 | Diagramme explicatif de la théorie de l'entropie de Shannon. . . . .  | 98  |
| 4.18 | Diagramme explicatif de la théorie de l'entropie de Shannon. . . . .  | 101 |
| 4.19 | Tendances des tracés $\Delta T_c$ prédits pour le $M1 - RBFNN$ , le $M1 - GRNN$ et le $M1 - ELM$ en phase de formation. . . . .                             | 102 |
| 4.20 | Tendances des tracés $\Delta T_c$ prédits pour le $M1 - RBFNN$ , le $M1 - GRNN$ et le $M1 - ELM$ en phase de test. . . . .                                  | 103 |
| 4.21 | $\Delta T_c$ mesuré et $\Delta T_c$ prédit avec : (a) $M1 - RBFNN$ , (b) $M1 - GRNN$ , et (c) $M1 - ELM$ . . . . .  | 104 |
| 4.22 | Tendances des tracés $\Delta T_c$ prédit pour le $M2 - RBFNN$ , $M2 - GRNN$ et $M2 - ELM$ en phase de formation. . . . .                                    | 105 |
| 4.23 | Tendances des tracés $\Delta T_c$ prédit pour le $M2 - RBFNN$ , $M2 - GRNN$ et $M2 - ELM$ en phase de formation. . . . .                                    | 106 |
| 4.24 | $\Delta T_c$ mesuré et prédit avec : (a) $M2 - RBFNN$ , (b) $M2 - GRNN$ et (c) $M2 - ELM$ . . . . .   | 106 |
| 4.25 | Différences d'erreurs entre les valeurs $\Delta T_c$ mesurées et prédites sur la base des modèles $M2 - RBFNN$ et $M1 - RBFNN$ . . . . .                    | 107 |
| 4.26 | Diagramme de Taylor qui démontre la meilleure performance pour la modélisation prédictive de $\Delta T_c$ En utilisant les modèles M1 (6 entrées) . . . . . | 108 |
| 4.27 | Diagramme de Taylor qui démontre la meilleure performance pour la modélisation prédictive de $\Delta T_c$ En utilisant les modèles M2 (4 entrées) . . . . . | 108 |

---

|   |     |
|---|-----|
| 4.28 Comparaison entre les valeurs mesurées et prédites de $\Delta T_c$ en utilisant le modèle $M1 - RBFNN$ et $M2 - RBFNN$ . . . . . | 109 |
|---|-----|

# Liste des tableaux

|     |  |     |
|-----|--|-----|
| 1.1 | Classification des céramiques en fonction de leurs applications. . . . .   | 25  |
| 1.2 | Les principales propriétés de l'alumine . . . . .  | 27  |
| 2.1 | Sévérité du choc thermique . . . . .   | 46  |
| 2.2 | Valeurs d'écart de température critiques . . . . .   | 53  |
| 3.1 | Résultats résumés de l'application des ANNs concernant la prédiction, la reconnaissance des formes et la classification [1]. . . . . | 59  |
| 3.2 | Les principales fonctions de transfert . . . . .   | 62  |
| 3.3 | Types de réseaux neuronaux et leurs applications. . . . .  | 65  |
| 4.1 | Résultats de l'ANOVA pour le module de Young . . . . .   | 86  |
| 4.2 | Résultats de l'ANOVA pour $\sigma_R$ . . . . .   | 86  |
| 4.3 | Coefficients de corrélation de Pearson entre les variables explicatives et $\sigma_R$ . . . . .                                      | 87  |
| 4.4 | Résultats de l'ANOVA pour $K_{1c}$ . . . . .   | 87  |
| 4.5 | Coefficients de corrélation de Pearson entre les variables explicatives et $(K_{1c})$ . . . . .                                      | 87  |
| 4.6 | Paramètres de performance . . . . .  | 90  |
| 4.7 | Combinaison des entrées des deux modèles développés . . . . .  | 101 |
| 4.8 | Résultats des performances des modèles RBFNN, GRNN et ELM. . . . .   | 102 |
| 4.9 | Écart-type des valeurs mesurées et prédites de $\Delta T_c$ . . . . .  | 109 |



# Introduction générale

Les matériaux céramiques sont largement utilisés en ingénierie et sont souvent soumis à des changements brusques de température qui peuvent facilement provoquer la rupture de ces matériaux, les experts ont tenté de contrôler les paramètres affectant la résistance aux chocs thermiques pour empêcher la rupture de ces matériaux. Ceci est très difficile car il faut beaucoup de temps pour tester et déterminer les paramètres qui affectent les paramètres de résistance aux chocs thermiques. Cependant, le marché a besoin d'une solution qui réduit le temps de développement et de production de matériaux aux propriétés spécifiques. Les délais extrêmement courts et les exigences de qualité des produits nécessitent désormais une bonne maîtrise et une optimisation du processus de production.

Aujourd'hui, les améliorations proviendront principalement des gains à réaliser dans la maîtrise des procédés d'élaboration de ces matériaux et dans la maîtrise des paramètres d'élaboration et des paramètres physiques affectant les propriétés mécaniques et thermiques. De nombreux articles de recherche dans le domaine de l'ingénierie des matériaux se sont appuyés sur des simulations numériques pour identifier les comportements thermomécaniques, mais les simulations numériques reposent sur des modèles mathématiques et des lois de comportement qui doivent satisfaire aux principes généraux de la mécanique qui sont physiquement acceptables.

Ces modèles mathématiques doivent, d'une part, prendre en compte le comportement de ces matériaux lors d'un changement brutal de température et prendre en compte tous les paramètres intervenant dans l'élaboration et d'autre part, ils doivent être simples, afin de faciliter leur identification et implémentation dans des codes de calcul. En effet, la simulation numérique du choc thermique est très complexe du fait de l'imbrication d'un grand nombre de phénomènes physiques. La prise en compte de tous ces phénomènes, même de manière simple, demande un temps de calcul très long.

Ces dernières années, de nombreuses recherches scientifiques se sont appuyées sur les

réseaux de neurones artificiels pour prédire le comportement mécanique des matériaux. En s'appuyant sur une modélisation prédictive réaliste, fiable et rapide du comportement de résistance aux chocs thermiques de l'alumine et des matériaux fragiles, cette modélisation est basée sur les paramètres physiques et les paramètres de mise en œuvre de ces matériaux pour déterminer le meilleur procédé de production. En donnant accès à des paramètres difficiles à atteindre par l'expérimentation, et qui améliorent la compréhension des phénomènes prédictifs. De plus, elle permet d'analyser l'influence de paramètres en négligeant les paramètres ayant une faible influence sur le comportement de la résistance aux chocs thermiques de ces matériaux avant le processus de fabrication proprement dit. Ainsi, de nouveaux matériaux céramiques peuvent être testés avant leur production.

L'objectif de ce travail est de construire des modèles prédictifs de la résistance aux chocs thermiques d'un matériau fragile (alpha alumine) basés sur les réseaux de neurones artificiels. En effet, les réseaux de neurones artificiels sont apparus comme une nouvelle branche de modélisation de relations linéaires et non linéaires complexes, qui ont montré une grande performance.

Dans ce travail nous proposons, d'utiliser les réseaux de neurones artificiels pour prédire la résistance au choc thermique.

Le désir est d'utiliser un outil de modélisation " rapide et efficace", qui permet d'optimiser les procédés d'élaboration des matériaux fragiles dans un temps très court.

En conclusion, la contribution de ce travail est d'apporter des solutions aux problèmes liés à :

1) Problèmes de modélisation complexe du comportement aux chocs thermiques des matériaux céramiques.

2) L'utilisation de méthodes d'intelligence artificielle pour déterminer la force de l'influence des paramètres physiques et d'élaboration liés à la résistance aux chocs thermiques des matériaux céramiques, notamment l'alumine. Ainsi déterminer les paramètres les plus influents dans la construction du modèle requis.

Ce travail est divisé en quatre chapitres :

**Le premier chapitre** est consacré à la présentation d'une étude bibliographique des principaux travaux qui ont été traité dans la littérature scientifique antérieure utilisant les réseaux de neurones artificiels dans le domaine de la mécanique et des matériaux, où l'attention a été portée sur la littérature qui traite du comportement mécanique et ther-

mique des matériaux.

Nous avons également fourni dans ce chapitre des informations de base sur les matériaux céramiques afin de définir la classification de ces matériaux, les méthodes de production et la description des méthodes de frittage utilisées pour produire les échantillons d'alumine, sous des conditions d'élaboration. Les résultats expérimentaux liés au comportement mécanique et thermique obtenus ont été analysés.

**Le deuxième chapitre** est destiné à la présentation des approches traditionnelles adoptées pour étudier la résistance aux chocs thermiques des matériaux fragiles. Les trois approches les plus importantes sont présentées, dont lesquelles la corrélation entre le paramètre de choc thermique et les paramètres physiques a été détaillée.

**Le troisième chapitre** est consacré à la présentation des méthodes des réseaux de neurones artificiels. Après avoir donné un bref aperçu des méthodes les plus importantes d'ANN, on a pu détailler les différents éléments de base de cet outil mathématique. Nous avons limité notre présentation aux aspects qui seront utiles pour la suite de ce travail.

**Le quatrième chapitre** est consacré aux méthodes de réseaux de neurones utilisées dans cette recherche. Les résultats prédits par ces méthodes ont été présentés.

L'efficacité des modèles a été testée par de nombreux critères statistiques, de plus, les résultats prédictifs ont été comparés aux résultats expérimentaux, et sur cette base, le modèle le plus performant a été choisi. Une synthèse et une comparaison entre les méthodes utilisées ont été illustrées à la fin de ce chapitre.

# Chapitre 1

## Etude Bibliographique

### Objectifs

Dans ce chapitre, nous présentons une revue détaillée de la littérature sur l'application des méthodes de réseaux de neurones artificiels pour prédire le comportement mécanique et physique des matériaux céramiques. Nous fournissons ensuite des définitions de ces matériaux et une présentation de leurs propriétés communes. Nous définissons ensuite le matériau alumine en termes de propriétés et de processus d'élaboration.

### Sommaire

|       |  |    |
|-------|--|----|
| 1     | Introduction . . . . .                                     | 17 |
| 2     | Les réseaux de neurones artificiels en matériaux . . . . . | 17 |
| 2.1   | Généralités sur la céramique . . . . .                     | 21 |
| 2.1.1 | Définition de la céramique . . . . .                       | 21 |
| 2.2   | Classification des matériaux céramiques . . . . .          | 22 |
| 2.3   | Classification des céramiques techniques . . . . .         | 23 |
| 2.3.1 | Classification selon la composition . . . . .              | 23 |
| 2.3.2 | Classification selon leurs applications . . . . .          | 24 |
| 2.4   | Propriétés générale des céramiques . . . . .               | 26 |
| 2.5   | L'alumine . . . . .  | 26 |
| 2.5.1 | Production de l'alumine . . . . .                          | 26 |
| 2.5.2 | L'alumine structure et propriétés . . . . .                | 26 |
| 2.6   | Elaboration des céramiques . . . . .                       | 28 |
| 2.6.1 | Traitement des poudres céramiques . . . . .                | 28 |
| 2.6.2 | Mise en forme des poudres céramiques . . . . .             | 29 |
| 2.6.3 | Traitement thermique . . . . .                             | 31 |
| 2.7   | L'élaboration des échantillons . . . . .                   | 33 |
| 3     | Conclusion . . . . .                                       | 38 |

## 1 Introduction

Étant donné que notre étude est basée sur des approches de réseaux de neurones artificiels pour prédire le paramètre de résistance au choc thermique (le premier paramètre  $R$ ). Nous avons effectué une recherche bibliographique sur les méthodes modernes basées sur l'intelligence artificielle, telles que les méthodes de réseaux de neurone et les algorithmes de réduction dimensionnelle... etc., ces méthodes ont été utilisées pour prédire les propriétés mécaniques et d'autres paramètres des matériaux céramiques et les matériaux fragiles qui ont des propriétés similaires au matériau étudié.

Ensuite, nous avons présenté un bref résumé de la définition et des propriétés des matériaux céramiques. Nous nous sommes concentrés sur les méthodes de préparation et d'élaboration liées à l'alumine, car ce sont les paramètres d'élaboration et les résultats expérimentaux des propriétés mécaniques et thermiques qui ont été utilisés pour construire les modèles prédictifs.

## 2 Les réseaux de neurones artificiels en matériaux

Les réseaux de neurones artificiels appliqués aux sciences de l'ingénieur ont une histoire récente. La découverte de l'algorithme d'apprentissage par back-propagation à gradient d'erreur pour les réseaux multicouches a relancé l'intérêt général pour ce thème de recherche en 1986. Ce progrès a permis d'envisager l'application des techniques connexionnistes à des problèmes réels. Actuellement, on assiste à un intérêt croissant pour le transfert des méthodes développées dans une discipline pour l'analyse de problèmes dans d'autres disciplines.

Un réseau neuronal artificiel (ANN), ou réseau neuronal (NN) en abrégé, utilise des nœuds mathématiques ou des neurones interconnectés pour former un réseau capable de modéliser des relations fonctionnelles complexes. Cette technique est particulièrement adaptée aux problèmes qui impliquent la manipulation de paramètres multiples et une interpolation non linéaire et qui, par conséquent, ne se prêtent pas facilement aux approches théoriques et mathématiques conventionnelles.

Donc, les réseaux neuronaux ont connu une application croissante dans la détermination des propriétés (mécaniques et physiques) des matériaux, en particulier les matériaux complexes multiphasés et composites, plus difficiles à analyser, qui sont de plus en plus populaires. Récemment, deux chercheurs ont publié une série de trois articles dans le journal *Materials & Design*, utilisant un réseau neuronal pour prédire la résistance à la traction et la densité [1], la résistance à la flexion et la dureté [2] de composites à matrice

d'aluminium renforcés par des particules Al-Si-Mg, ainsi que le mélange et la fraction volumique des pores dans un (Ceramic cake)  $Al_2O_3/SiC$  [3]. La méthodologie du réseau neuronal utilisée dans ces articles et le sujet traité sont identiques, à l'exception des changements de type et de propriétés des matériaux.

Un autre article [4] a étendu le travail de [2] en utilisant les mêmes données expérimentales. Cet article traite principalement de ces quatre articles et les utilise ensemble comme exemples pour mettre en évidence les plus importants. Les problèmes liés à l'utilisation des réseaux de neurones sont également plus fréquents. Dans un souci d'objectivité et d'équilibre, cet article fait également référence à d'autres travaux publiés dans le même domaine pour montrer que les préoccupations exprimées sont assez générales, limitant toujours le plein potentiel des techniques de modélisation par réseaux de neurones et pour profiter de l'occasion pour faire des recommandations de meilleures pratiques [5].

Dans une étude réalisée par **A. M. Hassan et al.** [6], Ils ont étudié le potentiel de l'utilisation d'un réseau neuronal à rétropropagation à action directe pour prédire certaines propriétés physiques et la dureté des composites Al-Cu/SiC synthétisés par coulée. Pour construire le réseau proposé, deux vecteurs d'entrée sont utilisés, à savoir le pourcentage en poids de cuivre et la fraction volumique des particules de renforcement. La densité, la porosité et la dureté sont les vecteurs de sorties. Une étude de l'effet de l'ajout d'un alliage de cuivre élémentaire et de carbure de silicium comme particules de renforcement pour la matrice métallique Al-4wt % en poids de Mg a été étudiés à l'aide de réseaux de neurones artificiels, des résultats satisfaisants sont obtenus où l'erreur relative absolue maximale de la valeur prédite ne dépasse pas 5,99 %.

Un modèle a été développé par **S. Malinov et al.** [7], pour analyser et prédire la relation entre les paramètres de traitement thermique et les propriétés mécaniques des alliages de titane en appliquant un réseau neuronal artificiel (ANN). Les paramètres d'entrée d'un réseau neuronal (NN) sont la composition de l'alliage, les paramètres de traitement thermique et la température de travail (test). Les paramètres de sortie du réseau neuronal du modèle NN proposé sont les neuf propriétés mécaniques les plus importantes : la résistance à la traction, la limite d'élasticité, l'allongement, la réduction de surface, la résistance au choc, la rigidité, le module d'élasticité, la résistance à la fatigue et la ténacité. Le modèle est basé sur un réseau de neurones multicouches. Les chercheurs ont développé une interface utilisateur graphique (GUI) pour l'utilisation du modèle et ont conclu que la performance du réseau neuronal est excellente. Ils concluent que le modèle peut être utilisé pour prédire les propriétés des alliages de titane à différentes températures en fonction des paramètres de traitement et des cycles de traitement thermique. Il peut également être utilisé pour améliorer les paramètres de traitement et de traitement

thermique.

Dans un article scientifique publié en 2021 par **Mohamadi, M et al.** [8], la méthode ANN avec algorithme de rétro-propagation (BP) a été appliquée aux propriétés mécaniques et thermiques des hybrides PA66/Bronze afin d'évaluer efficacement et de prédire avec précision le comportement global des composites avec un nombre limité d'expériences. Les chercheurs ont conclu que l'ANN est une méthode fiable et efficace pour prédire différentes propriétés de systèmes multicomposants, même lorsque des données expérimentales disponibles sont limitées. Ils soulignent également que pour les travaux futurs, des charges hybrides avec des géométries et des propriétés différentes peuvent être utilisées pour maintenir la ténacité des polymères, ou l'effet des agents de couplage sur les différentes propriétés des composés chargés de métal.

Dans un article de **Li et al.**, [9], un réseau neuronal hybride qui combine un réseau neuronal convolutif avec un réseau neuronal LSTM (Long Term Memory) à long terme est proposé pour extraire les caractéristiques des matériaux afin de prédire la température critique des supraconducteurs. Les données de ces matériaux sur les supraconducteurs proviennent de la base de données des matériaux eux-mêmes maintenue par l'Institut national des sciences des matériaux du Japon. Les algorithmes ont été évalués par les métriques RMSE, MAE et  $R_2$ . Le réseau neuronal hybride développé a une valeur RMSE de 83,565 K, une valeur  $R_2$  de 0,899 et une valeur MAE de 5,023.

**Viatkin D. et al.** [10], ont développé un modèle permettant d'utiliser la formule chimique d'un matériau et de prédire ensuite la température critique de supraconductivité de ce matériau. Une approche basée sur l'utilisation de plusieurs structures de réseaux neuronaux et de leurs combinaisons pour analyser les formules chimiques a été étudiée et décrite. L'utilisation de réseaux neuronaux dont la structure dépend de l'usage des couches LSTM (Long Short Term Memory) et de convolution a été discutée.

L'étude de la ténacité pour des composés Nb-siliciure a été menée par **Guan. K et al.** [11], ont utilisé un réseau neuronal artificiel (ANN). L'architecture du réseau neuronal artificiel utilisé est illustrée à la figure 1.1. Les effets de différentes entrées sur la ténacité ont été examinés et évalués par le réseau entraîné. Les chercheurs ont conclu que lorsque toutes les entrées candidates étaient prises en compte, le réseau neuronal obtenait des performances exceptionnelles. Ils ont produit un nouvel alliage qui présente une microstructure et une ténacité améliorée, conformément aux prévisions du modèle. L'un des résultats importants auxquels ils sont parvenus est que la ténacité du nouvel alliage était de  $19,5 \text{ MPa.m}^{1/2}$ , soit 25,5 % de plus que le meilleur alliage introduit ( $15,5 \text{ MPa.m}^{1/2}$ ).




FIGURE 1.1 – Variation des paramètres mécaniques en fonction des propriétés physiques (densité et granulométrie)

Dans une recherche menée par **Liu, G et al.** [12], un réseau feedforward a été développé avec un réseau neuronal artificiel à rétropropagation (ANN BP) pour prédire la résistance à la traction (UTS) et optimiser la microstructure. L'UTS de la sortie du réseau ANN a été mesurée. Cinq facteurs distincts utilisés pour les entrées du réseau ANN sont résumés et mesurés (figure 1. 2). Le résultat de cette étude est un modèle ANN avec une grande précision et une bonne capacité de généralisation pour prédire la résistance à la traction dans la gamme  $343.5 \sim 1063.3 MPa$ . En se basant sur le modèle ANN amélioré, les chercheurs ont proposé une nouvelle méthode pour concevoir la microstructure de l'alliage Nb-Si afin d'obtenir l'UTS désirée. Des cartes de conception du silicium établies par le modèle ANN et une amélioration de la microstructure de l'échantillon de  $343,5 MPa$  et l'UTS a atteint la cible UTS ( $600 MPa$  avec succès).

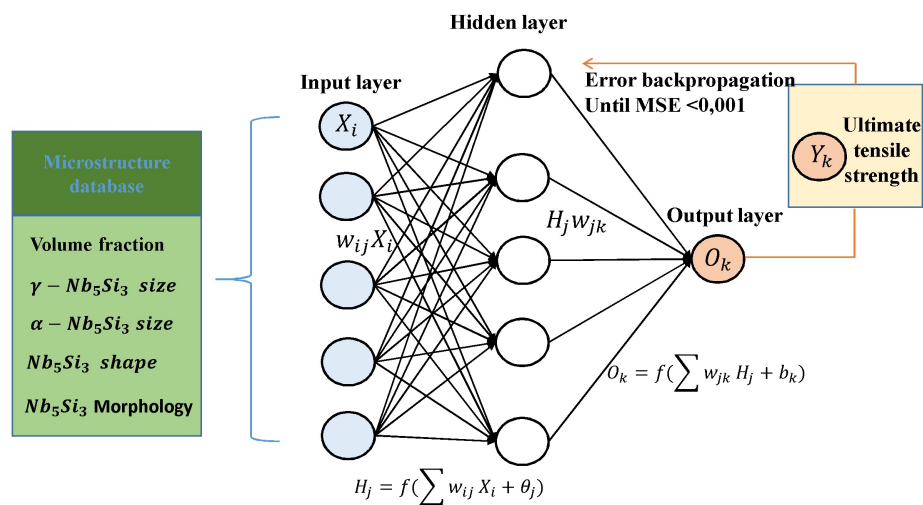


FIGURE 1.2 – Variation des paramètres mécaniques en fonction des propriétés physiques (densité et granulométrie)



En 2018, **R. Pramoda et al.** [13], ont construit un réseau neuronal artificiel (ANN) pour prédire les propriétés tribologiques des composés Al7075-Al2O3 en utilisant la technique d'optimisation **Levenberg-Marquardt** pour établir une relation non linéaire entre la densité, la perte de hauteur d'usure, la distance de glissement et le pourcentage pondéral du renforcement des particules. Un bon accord a été observé entre les résultats du modèle expérimental et de l'ANN. Pour la partie de la recherche relative à la modélisation prédictive à l'aide d'un réseau neuronal artificiel, les chercheurs ont conclu que :

- Une relation non linéaire a été établie à l'aide de l'ANN entre le pourcentage en poids du renforcement en Al2O3, la distance de glissement, la densité, la charge appliquée et la perte de hauteur d'usure.
- Les résultats expérimentaux et les résultats du modèle ANN sont en accord étroit les uns avec les autres.
- Un réseau neuronal artificiel compétent et efficacement entraîné est capable de prédire la perte en termes de hauteur d'usure de l'alliage de base Al7075 et de ses MMC renforcés à l' $Al_2O_3$ .

Dans une étude visant à prédire les propriétés physiques de la gamma-alumine poreuse préparée par la méthode de coulée en gel, **Hasan Sh et al.** [14], ont conçu un modèle de réseau neuronal artificiel pour prédire les propriétés (porosité, densité, retrait et surface). Les paramètres d'entrée du modèle étaient la température de frittage, la concentration en cellules de levure et le temps de trempage, tandis que les paramètres de sortie étaient la porosité, la densité, le rétrécissement et la surface. Les chercheurs ont réalisé d'importantes économies de coûts et de temps en utilisant le modèle de réseau neuronal artificiel (ANN). Ils ont conclu que les résultats du réseau neuronal artificiel concordaient de manière convaincante avec les données expérimentales et que le réseau neuronal artificiel fournissait des données plus utiles.

## 2.1 Généralités sur la céramique

### 2.1.1 Définition de la céramique

Le terme céramique vient de grec *keramikos* qui signifie terre cuite ou terre à potier. Les potiers ont choisi des matières premières argileuses qui ont la propriété de donner avec l'eau une pâte plastique qui se modèle aisément et qui devient dure, solide et inaltérable après cuisson [15].

De nombreuses définitions ont été proposées qui dépendent du point de vue qu'on adopte, chaque définition ayant sa justification du point de vue de celui qui la propose [16,17]. Beaucoup de chercheurs et des organisations techniques ont donné des définitions de céramiques, les plus importants de ces définitions sont :

- D'après **Kingery (1976)** : C'est l'art de la science de fabriquer et d'utiliser des objets solides dont les constituants essentiels sont des matériaux ni organiques ni métalliques.

- C'est un matériau de synthèse, ni organique ni métallique, dont l'élaboration fait appel à des traitements thermiques («**British Ceramic Society**» 1976).

- D'après **G. Fantozzi** la céramique est considérée comme étant le domaine scientifique, technique et industriel qui s'occupe de la fabrication et des propriétés des solides inorganiques non métalliques [15].

- Les matériaux céramiques sont les matériaux de synthèse, majoritairement constitués de phases inorganiques à liaisons essentiellement ion-covalentes, non totalement vitreux, et généralement consolidés par frittage de l'objet voulu, les poudres de départ étant fréquemment préparées à partir de poudres broyées [16] .

## 2.2 Classification des matériaux céramiques

Les matériaux céramiques peuvent être classés de plusieurs façons, nous pouvons choisir différents types de critères pour classer les matériaux céramiques, mais en gros, deux critères importants ont été largement acceptés comme critères de classification, à savoir la classification basée sur la composition chimique de ces matériaux et la classification basée sur leurs applications techniques.

La plupart des céramiques peuvent donc être classées sur cette base. On distingue deux secteurs d'activités industrielles regroupant deux familles de matériaux céramiques (figure.1.3).

**Les céramiques traditionnelles** : sont en général des silicates ou des aluminosilicates. Ce type de céramiques est préparé par traitement thermique de matières premières naturelles telles que le kaolin (argile), le quartz (sable) et le feldspath. Il comprend tous les types connus de poterie, de céramique chinoise, de grès, de porcelaine et d'autres matériaux contenant des matières de nature verdâtre (argile), terreuse ou calcaire, de sorte que la proportion d'argile s'y situe entre 20 et 100 % [18-20] .

**Les céramiques techniques** : sont essentiellement des composés non silicatés de grande pureté et pour cela sont élaborés à partir de matières premières déjà synthétisées [21] .

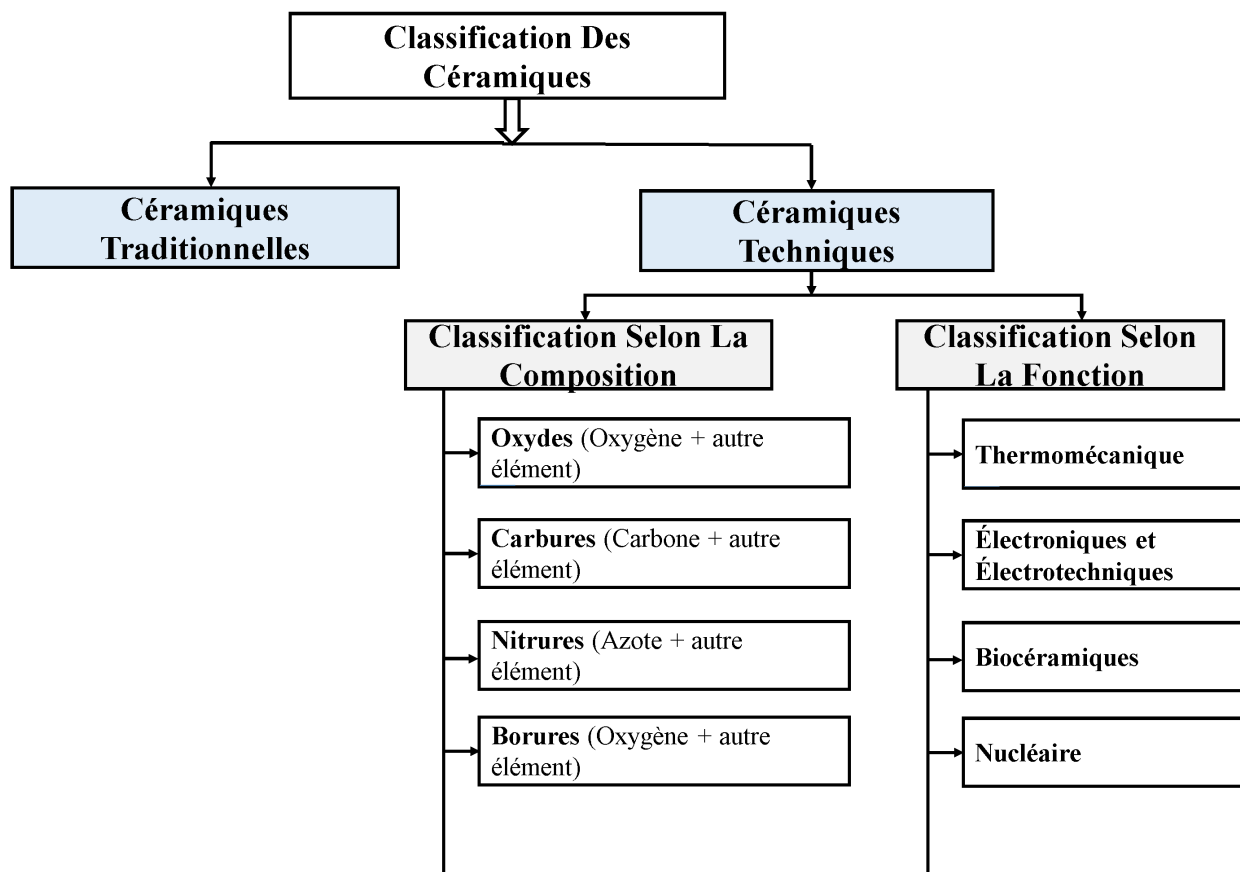


FIGURE 1.3 – Classification des céramiques.

Par la suite, nous nous intéressons à la classification des céramiques techniques en raison de sa relation avec le sujet de l'étude.

## 2.3 Classification des céramiques techniques

### 2.3.1 Classification selon la composition

Les céramiques techniques sont classées en plusieurs groupes en fonction de leur composition minérale ou chimique. On peut se référer à 4 groupes principaux :

**Oxydes** : Les oxydes céramiques font partie des composés céramiques techniques les plus importants et les plus utilisés, ces derniers se retrouvant presque dans tous les domaines. En particulier l'oxyde d'aluminium, de magnésium, de silicium et de zirconium, et ils sont utilisés dans plusieurs domaines, notamment : mécanique, thermique, électronique, biomédical, chimique, optique,...etc. [22] .

**Carbures** : Les carbures ont une température de fusion très élevée par rapport aux autres céramiques techniques, une grande dureté et une très mauvaise conductivité ther-

mique et électrique, par contre, ils sont fragiles. Les carbures, en particulier les carbures de tungstène, de vanadium, de tantale et de titane, sont utilisés comme outils de coupe, et ils sont également utilisés dans plusieurs domaines, notamment : mécanique, thermique et électronique [22, 23] .

**Nitrures** : Il s'agit d'un groupe de composés céramiques qui contiennent l'élément azote dans leur formule chimique, notamment le nitrure de silicium, de bore, de titane et autres. Les nitrures se forment à haute température et ont donc un point de fusion élevé. Il est utilisé dans plusieurs domaines, notamment thermiques, mécaniques, nucléaires et autres. Il est également utilisé dans la fabrication d'outils de coupe, d'outils abrasifs, de matériaux réfractaires...etc. [22] .

**Borures** : C'est un groupe de composés chimiques qui contiennent du bore, y compris les borures de titane, de zirconium, de baryum. Les borures ont une température de fusion très élevée, comprise entre 1 900 et 3 000 °C, et ont une faible résistance électrique. Il possède une stabilité et une dureté élevées, mais il ne résiste pas à l'oxydation sous températures supérieures à 1200 ° C. Son application la plus courante est la fabrication de creusets pour la métallisation sous vide [22] .

### 2.3.2 Classification selon leurs applications

En plus des fonctions traditionnelles connues pour les matériaux céramiques, de nombreuses applications industrielles et biomédicales ont vu le jour ces dernières années et peuvent être classées en fonction de leurs utilisations spécifiques. Ces fonctions et applications sont synthétisées dans le tableau ci-après :

TABLE 1.1 – Classification des céramiques en fonction de leurs applications.

| <b>Fonctions</b>  | <b>Applications</b>   |
|---|---|
| <b>Les céramiques traditionnelles</b>                           | - produit pour le bâtiment<br>(sanitaire, carreaux de sol,<br>de mur, briques, tuiles...)<br>- articles domestiques<br>(vaisselle, objets décoratifs, poterie...)   |
| <b>Les biocéramiques</b>  | - prothèse de la hanche,<br>remplacement de l'os,<br>restauration dentaire,<br>implants dentaires...  |
| <b>Céramiques pour l'électronique<br/>et l'électrotechnique</b> | -informatique, téléphonie,<br>communication par satellites,<br>automobile, condensateurs,<br>circuits d'interconnexion,...  |
| <b>Céramiques électrochimiques</b>                              | -cellules galvaniques,<br>générateurs électrochimiques<br>à oxygène, piles à combustibles...  |
| <b>Céramiques pour l'énergie nucléaire</b>                      | -combustibles<br>(oxyde d'uranium,<br>oxyde mixtes d'uranium<br>et de plutonium)...   |
| <b>Céramiques pour l'environnement</b>                          | -filtration,<br>séparation membranaire,<br>catalyse hétérogène d'adsorption<br>(physisorption ou chimisorption)...  |
| <b>Céramiques thermomécanique</b>                               | - pièces d'usure<br>(buse de sablage, roulement à billes,<br>guide fils, soupapes.)<br>- plaques de blindage,<br>protection individuelle.<br>- isolant thermique, barrières thermiques,<br>éléments de four ... |
| <b>Les réfractaires</b>   | -sidérurgie, métallurgie, pétrochimie.  |

## 2.4 Propriétés générale des céramiques

Les principales propriétés mécaniques, thermiques, physiques et chimiques des céramiques sont dominées (par ordre d'échelle croissante) par la nature de leurs liaisons atomiques, de leurs structures cristallines et de leurs microstructures [7]. Les céramiques sont caractérisées par de fortes liaisons atomiques chimiques de nature covalente ou ionique, et parfois les deux liaisons combinent à la fois ionique et covalente, l'une dominant l'autre [24].

On peut résumer ces propriétés comme suit [17] :

- **Réfractarité** : températures de fusion élevées ;  $800^{\circ}\text{C}(\text{NaCl}) < T_f < 4150^{\circ}\text{C}(\text{HfC})$ ,
- **Dureté** : élevée ;  $0.7\text{GPa}(\text{SiO}_2) < H < 90\text{GPa}$  (C diamant),
- **Rigidité** : modules d'élasticité élevés ;  $50\text{GPa}(\text{SiO}_2) < E < 1000\text{GPa}$  (C diamant),
- **Légèreté** : faibles densités ;  $2\text{g/cm}^3(\text{SiO}_2) < d < 5\text{g/cm}^3(\text{ZrO}_2)$ ,
- **Fragilité** : faibles ténacité ;  $0.6\text{MPa}\cdot\text{m}^{1/2}(\text{SiO}_2) < K_{1c} < 10\text{MPa}\cdot\text{m}^{1/2}(\text{ZrO}_2)$ ,
- **Isolant thermique** : faibles conductivités thermiques ;  $1\text{Wm}^{-1}\text{K}^{-1}(\text{SiO}_2) < \lambda < 29\text{Wm}^{-1}\text{K}^{-1}(\text{ZrO}_2)$
- **Isolant électrique** : faibles conductivités électriques ;  $1014\ \Omega\cdot\text{cm}(\text{Al}_2\text{O}_3) < \rho < 29\ \Omega\cdot\text{cm}(\text{SiC})$ ,
- **Stabilité dimensionnelle** : faibles coefficients de dilatation thermique ;  $0.4 \times 10^{-6}\text{K}^{-1}(\text{SiO}_2) < d < 9 \times 10^{-6}\text{K}^{-1}(\text{ZrO}_2)$ ,


## 2.5 L'alumine

### 2.5.1 Production de l'alumine

La principale matière première pour la production d'alumine est la bauxite  $\text{Al}_2\text{O}(\text{OH})_4$ , une roche hydratée abondante présente sous forme de grands gisements dans diverses régions du monde. Dans le procédé Bayer, le minerai de bauxite préparé est digéré sous pression dans une solution aqueuse chaude d'hydroxyde de sodium, puis "ensemencé" pour provoquer la précipitation de cristaux d' $\text{Al}(\text{OH})_3$ , généralement désignés par le terme minéral "gibbsite". La gibbsite est décomposée chimiquement par chauffage (calcination) à une température de  $1200^{\circ}\text{C}$  [25].

### 2.5.2 L'alumine structure et propriétés

**Structure cristallographie de L'alumine  $\alpha$**  : L'alumine  $\alpha$ , est la forme pure obtenue par calcination à température élevée (définit la structure corindon où les oxygènes forment un empilement hexagonal compact avec les ions aluminium logés dans le 2/3 des sites octaédriques).

FIGURE 1.4 – Structure hexagonal d'alumine  $\alpha$  ( $Al_2O_3$ ) [21] .

**Propriétés** : Les principales propriétés de l'alumine  $\alpha$ , données par la littérature sont regroupées dans le tableau 1.2 ci-dessous [26] :

TABLE 1.2 – Les principales propriétés de l'alumine

|   |  |
|---|--|
| Numéro atomique effectif ( $Z_{eff}$ )                | 10,2   |
| Masse molaire (g/mol)                                 | 101,96   |
| Densité (g/cm <sup>3</sup> )                          | 3,98   |
| Nombre d'atomes par unité de volume                   | $2,35 \cdot 10^{23}$                                 |
| Energie de cohésion (eV)                              | 160  |
| Température de fusion (°C)                            | 2050   |
| Coefficient de dilatation à 25 °C (°C <sup>-1</sup> ) | $5 \cdot 10^{-6}$                                    |
| Conductivité thermique (W/m°C)                        | 40 (à 20 °C), 18 (à 300 °C), 4 (à 1200 °C)           |
| Chaleur spécifique (J/kg °C)                          | 750  |
| Indice de réfraction (à 589,3 nm)                     | 1,765  |
| Emissivité  | $<0,02$ à 880 °C ; $\lambda=2,6$ à 3,7 $\mu\text{m}$ |
| Transmission  | De 140 à 6000 nm ( $>85\%$ dans le visible)          |
| Constante diélectrique                                | $\sim 10$  |
| Résistance diélectrique à 60 Hz                       | $4-5 \cdot 10^6$                                     |
| Résistivité ( $\Omega \cdot \text{cm}$ )              | 1016 (à 25 °C), 1011 (à 300 °C)                      |
| Dureté Mohs   | 9  |
| Dureté Knoop (kg.mm <sup>2</sup> )                    | 1600-2200  |
| Module d'élasticité (GPa)                             | 440  |
| Module de rupture (MPa)                               | 440  |
| Module de compression (GPa)                           | 390  |
| Résistance à la compression à 25 °C (GPa)             | 2  |
| Résistance à la traction à 25 °C (MPa)                | 190  |
| Résistance à la flexion (MPa)                         | 550-600  |
| Ténacité (MPa.m <sup>1/2</sup> )                      | 3  |
| Coefficient de poisson                                | 0,30   |

## 2.6 Elaboration des céramiques

La plupart des poudres sont soumises à une étape de broyage afin de casser les agglomérats. Les techniques de mise en forme qui sont utilisées dans la fabrication des céramiques sont multiples. Les méthodes utilisées pour la mise en forme de céramiques massives sont le pressage à sec ou semi-humide. Pour le pressage à sec, les poudres sont atomisées en granules de 50 à 500 microns (pendant l'étape de préparation) pour faciliter le remplissage des matrices de pressage.

Les méthodes de mise en forme par voie humide nécessitent une période de séchage avant l'étape de déliantage. Cette technique se termine par une étape finale appelée frittage. Toutes ces méthodes, utilisant les matières premières, nécessitent des additifs pour faciliter la mise en suspension, ou de liant et de lubrifiant destinés à faciliter le compactage, ces additifs doivent être éliminés avant l'étape de frittage lors d'une opération appelée déliantage.

L'élaboration de céramiques denses se fait par deux voies, soit la voie sèche ou la voie humide. La technique d'élaboration peut être décomposée en trois principales étapes [24] :

- Traitement des poudres.
- Mise en forme.
- Traitement thermique.

### 2.6.1 Traitement des poudres céramiques

Pour les céramiques techniques, on utilise souvent des poudres synthétiques. La nature des matières première est primordiale pour la qualité finale du produit, les critères de sélection des poudres de départ sont [17] :

- La pureté.
- la taille des particules.
- la réactivité des poudres.

Pour le traitement des poudres céramiques, plusieurs techniques ont été utilisées, chacune d'entre elles, selon la qualité de la poudre et ses propriétés, parmi lesquelles le tamisage, la séparation par air et le broyage, qui est l'une des plus importantes d'entre elles. Par cette méthode, la taille des particules peut être réduite en cassant chaque fragment par choc avec d'autres fragments ou des pièces mobiles de broyeurs.

Il existe plusieurs types de broyeurs permettant de réduire les dimensions des produits "millimétriques" jusqu'au micron. La technique de broyage la plus utilisée est l'attrition avec des billes d'acier ou d'alumine en milieu aqueux. La durée de cette opération peut



varier de 3 à plus de 24 heures suivant la quantité de poudre à broyée. Ce procédé permet d'obtenir des particules céramiques de taille inférieure à  $1\mu\text{m}$  [21].

### 2.6.2 Mise en forme des poudres céramiques

Le choix du procédé de la mise en forme d'un corps cru de poudre dépend de plusieurs paramètres, la géométrie de la pièce, sa taille, et l'état de surface. La plupart des méthodes de mise en forme mettent en jeu des additifs (souvent organiques) pour faciliter la mise en suspension, ou de liants et lubrifiants pour le compactage.

Ces additifs organiques doivent être éliminés avant frittage, normalement par pyrolyse en chauffant à l'air, cette étape s'appelle déliantage. Les deux étapes, séchage et déliantage, peuvent provoquer des défauts si l'élimination de liquide ou les additifs est trop rapide [24].

#### a- Voie sèche

Pour la mise en forme par voie sèche des poudres céramiques, le pressage uniaxial et le pressage isostatique sont les techniques de fabrication les plus utilisées des matériaux céramiques.

Pour le pressage uniaxial (figure 1.5), il consiste à compacter la poudre en appliquant une pression dans une direction à l'aide d'un ou plusieurs poinçons, qui peuvent être mobiles ou fixes [27]. Pour la deuxième technique, la pression isostatique est utilisée pour produire des pièces de forme complexe ou de grande taille. La technologie de pressage isostatique permet une meilleure répartition de la pression sur l'ensemble de la pièce.

La technique repose sur l'application d'une force de pression isotrope sur l'ensemble de la pièce (figure 1.6) :




FIGURE 1.5 – Pressage uniaxial .




FIGURE 1.6 – Représentation schématique de la technique de pressage isostatique.

### b- Voie humide

Les procédés de mise en forme par voie humide (extrusion, injection, et le coulage) sont basés sur une matière première sous forme de barbotine ou de pâte. Le choix du procédé dépend principalement de la structure géométrique de la pièce à produire.

La coulée en barbotine (coulage sur moule plâtre, coulage sur moule d'alumine poreux et coulage sous pression), la coulée en bande sont parmi les procédés de formage humide les plus utilisés [24] .

Le processus de mise en forme par voie humide de matériaux céramiques est suivi d'un processus de séchage.

Le séchage est une étape importante dans plusieurs des procédés de mise en forme discutés ci-dessus. Le phénomène de séchage est pratiquement toujours associé à un retrait de la pièce céramique. L'importance du retrait dépend de la méthode de mise en forme et de la quantité de liquide nécessaire pour fournir les propriétés rhéologiques adaptées au procédé. La méthode industrielle la plus répandue est l'étuve à convection où un flux d'air chaud est utilisé pour fournir de la chaleur et retirer du vapeur du liquide [17] .

### 2.6.3 Traitement thermique

Lorsque la poudre est compactée et portée à haute température ( $\sim 2/3$  de  $T_f$ ) les phénomènes de diffusion sont favorisés et les particules se soudent entre elles, provoquant une densification de la poudre. La densification complète est rarement atteinte, des porosités résiduelles restent piégées au niveau des joints. La densification des matériaux est extrêmement importante pour le comportement au choc thermique et résistance mécanique. L'augmentation de la densité améliore la résistance au choc thermique, mais limite sa résistance à la fissuration.

- **délaiantage** : L'ajout d'additifs organiques (liant, plastifiant et lubrifiant) pendant la mise en forme conduit à une dégradation de la qualité du produit. Pour améliorer la densification des poudres, il est nécessaire d'éliminer ces auxiliaires organiques.

La décomposition thermique reste toujours la plus utilisée, le délaiantage se fait dans les fours qui disposent d'un dispositif d'évacuation des gaz, pour éviter toute fissuration des échantillons lors du départ des additifs. La vitesse d'évaporation ou de décomposition des liants doit rester inférieure à la vitesse de diffusion des phases gazeuses, c'est la raison pour laquelle les vitesses de chauffage doivent être faibles.

Le cycle de température est choisi comme suit : vitesse de montée  $15^\circ \text{C} / \text{h}$ , température  $600^\circ \text{C}$  (température max), durée du palier 2h, descente libre [24].

- **Le Frittage** : Le frittage est un processus faisant évoluer par traitement thermique un système constitué de particules individuelles (ou un aggloméré poreux), en l'absence de pression externe exercée ou sous l'effet d'une telle pression, de sorte qu'au moins certaines des propriétés du système (sinon toutes) soient modifiées dans le sens d'une réduction de l'énergie libre globale du système. Parallèlement, cette évolution entraîne une diminution importante (sinon complète) de la porosité initiale [28] .

La forme générale de la courbe de frittage est similaire à celle de délaiantage (figure 1.7).

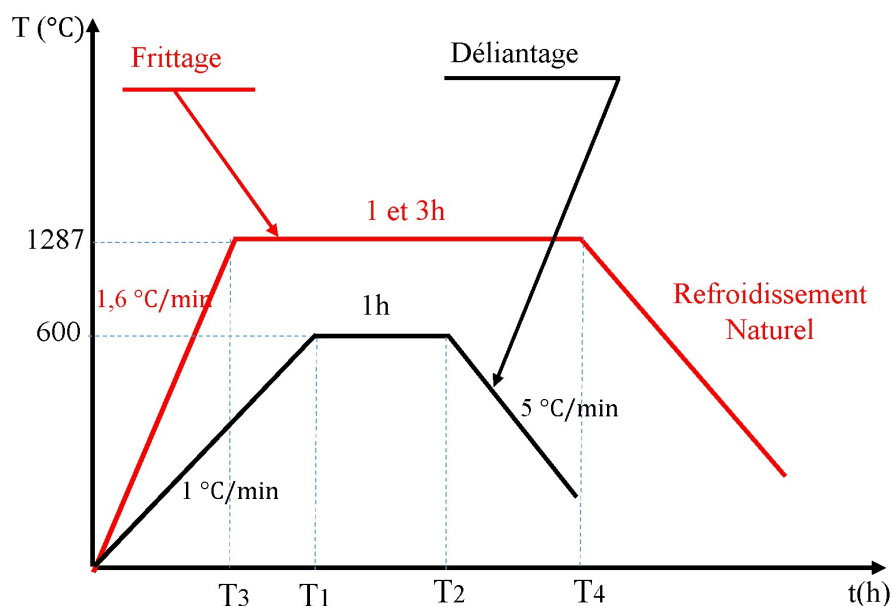


FIGURE 1.7 – Cycles de déliantage et de frittage [24].

### 1- Frittage naturel

Le frittage permet de transformer la poudre compactée (corps cru) en une masse solide et cohérente par l'effet de la température (inférieure à la température de fusion du constituant principal). En frittage naturel, aucune contrainte externe n'est appliquée : c'est le procédé de frittage le plus simple qui nécessite des températures élevées pouvant entraîner une croissance granulaire importante, susceptible d'empêcher à son tour l'élimination totale de la porosité [24].

### 2- Frittage spark plasma sintering (SPS)

Le spark plasma sintering (SPS) est un procédé de frittage qui permet de compacter des céramiques et des métaux en poudre à basse température avec un temps de maintien court. Le procédé est similaire au pressage à chaud classique, en ce sens que les précurseurs sont chargés dans une matrice et qu'une pression uniaxiale est appliquée pendant le frittage. Cependant, au lieu d'utiliser une source de chaleur externe, on laisse un courant continu pulsé traverser la matrice de pression électriquement conductrice et dans certains cas, l'échantillon. Cela implique que la matrice agit également comme une source de chauffage et que l'échantillon est chauffé à la fois de l'extérieur et de l'intérieur, comme le montre le dessin schématique de la figure 1.8. Ainsi, les caractéristiques uniques de ce procédé sont les possibilités d'utiliser des taux de chauffage très rapides et des temps de maintien très courts (minutes) pour obtenir des échantillons entièrement denses.

Le transfert de chaleur de la matrice au compact est très efficace dans ce processus, car la matrice elle-même agit comme un élément chauffant. Cependant, il est souvent avancé que les taux de densification améliorés proviennent principalement de l'utilisation d'impulsions de courant continu de haute énergie. Ainsi, les inventeurs du procédé ont affirmé à l'origine que les impulsions génèrent des décharges d'étincelles et même du plasma entre les particules de poudre, ce qui explique l'appellation du pourquoi du procédé frittage par plasma d'étincelles.

Il a été démontré que le SPS permet de consolider des matériaux céramiques en quelques minutes [29].




FIGURE 1.8 – Les caractéristiques d'un appareil SPS [17].

## 2.7 L'élaboration des échantillons

### a) Elaboration par frittage naturel

Une quantité de 50 g de poudre BMA15 est dispersée dans 50 g d'eau de façon à former une barbotine. Pour ajuster le pH, des gouttes d'une solution diluée d'acide chlorhydrique (2 ml de HCl et 18 ml eau distillée) ont été ajoutées à la barbotine pour avoir une solution acide et atteindre ainsi un pH égal à 3. Cette barbotine est broyée en jarre pendant une

durée de 24 heures. Pour éviter la contamination de la poudre, les médias de broyage sont des billes en alumine de différents diamètres. Pendant le broyage, le pH augmente à cause de l'augmentation de la surface spécifique à cause de la diminution du diamètre des grains. L'efficacité du broyage est liée à la viscosité et donc à l'état de la dispersion de la barbotine.

Pour étudier l'évolution de la barbotine en fonction du temps, il est nécessaire de contrôler l'état de la dispersion et du pH toutes les 2 heures de broyage. Il est constaté que le pH de la barbotine diminue au cours du broyage. Cette variation est en corrélation avec l'augmentation de la surface spécifique de la poudre au cours du broyage. Un réajustement du pH a été effectué par l'ajout de gouttes de solution diluée pour stabiliser le pH à 3.08. La valeur du pH après 8 heures de broyage était de 4.65.

Pour réduire les porosités des corps crus, la suspension obtenue après broyage a été dégazée à l'aide d'une pompe à vide pendant 3 à 5 mn pour enlever les bulles d'air. Ensuite la barbotine a été coulée dans des moules en PVC sous forme de barreaux (figure 1.9). Ces moules sont placés sur une plaque en plâtre (un usinage ultérieur est prévu à cause de la contamination). Avant le coulage, les bords du moules sont recouverts d'une couche de graisse de silicone qui va permettre un démoulage rapide et sans contraintes, car les pressions sur les bords peuvent endommager l'échantillon.




FIGURE 1.9 – La forme de moule utilisé pour le coulage en barbotine .

L'organigramme suivant résume les étapes suivies dans l'élaboration des échantillons.

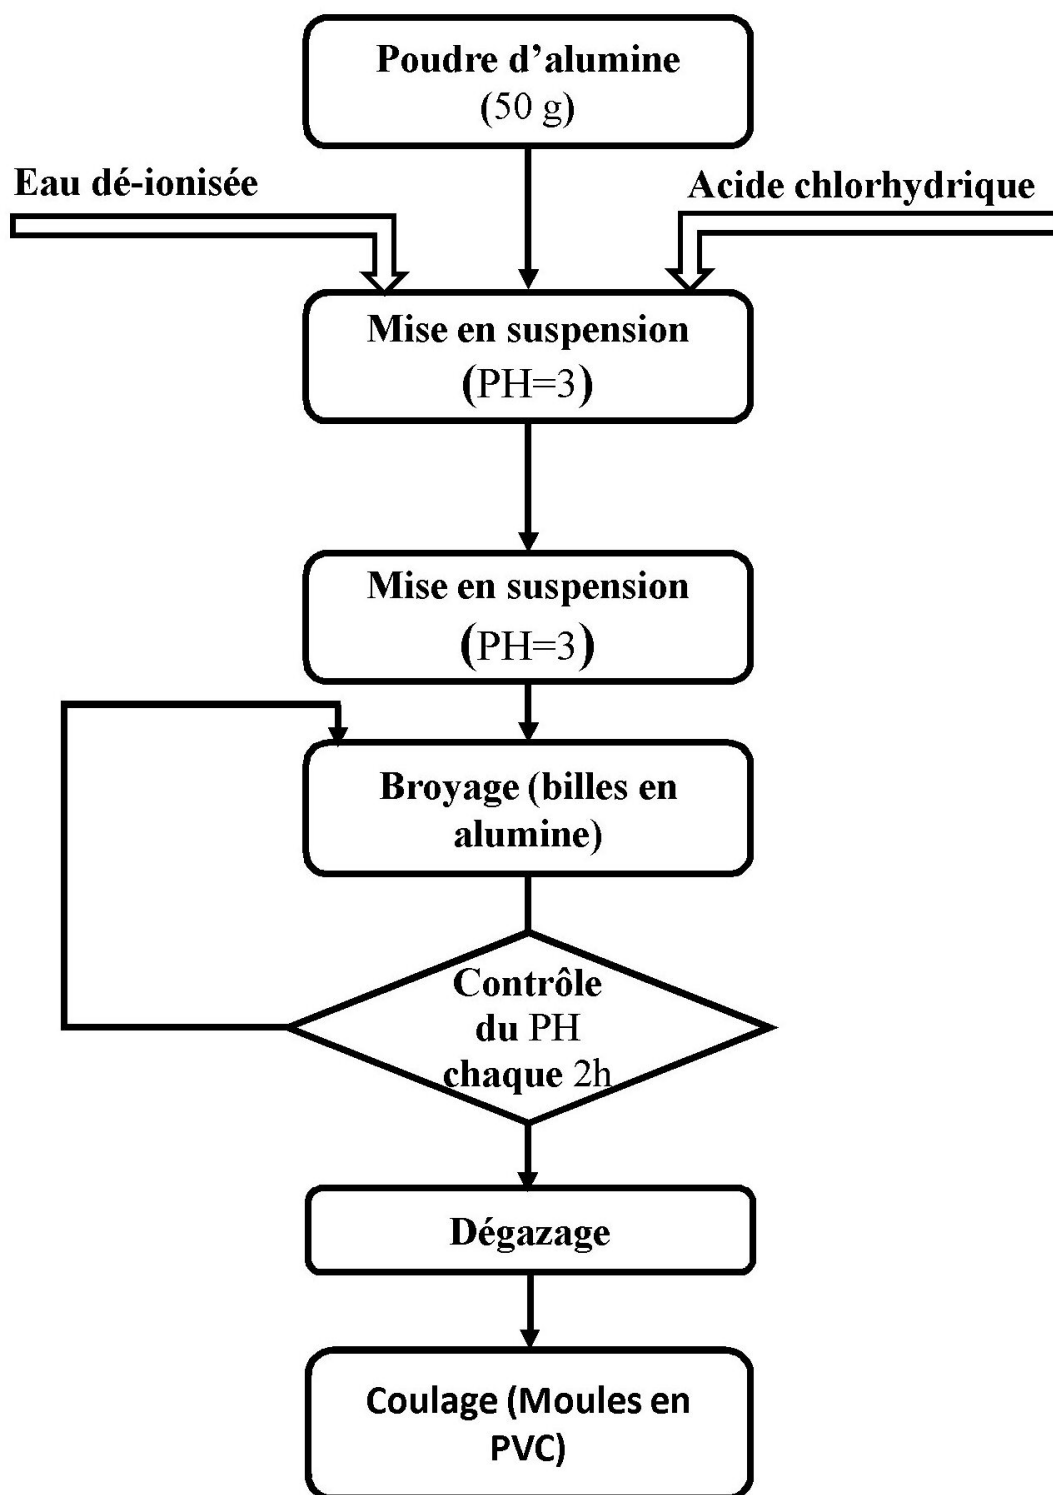


FIGURE 1.10 – Les étapes de la procédure d'élaboration par coulage en barbotine.

Les échantillons ont été séchés en plusieurs étapes, durant lesquelles l'humidité relative dans l'atmosphère décroît progressivement. Pour éliminer ou minimiser la fissuration, un séchage a été réalisé suivant le cycle décrit dans la figure 1.11.

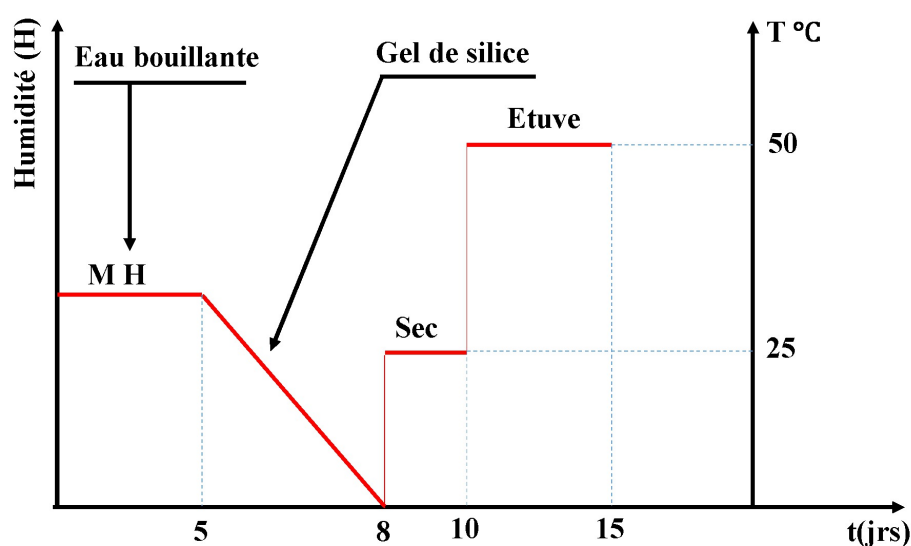


FIGURE 1.11 – cycle de séchage [24].

### b) Elaboration par frittage (SPS)

La poudre doit être déposée à l'intérieur d'une matrice présentant la forme finale souhaitée après frittage (figure 1.12(a)). Puis les poudre sont comprimées, de manière uniaxiale, sous une pression adaptée à la densité a cru mais aussi en fonction de la compressibilité de la poudre. De la qualité du remplissage de la poudre au sein de la matrice dépend le bon déroulement du procédé de frittage et, par conséquent, de l'homogénéité des pièces ainsi frittées.

Après remplissage, la poudre disposée dans la matrice est pré-compactée grâce une presse manuelle. La symétrie de l'ensemble doit être assurée afin que la poudre se situe bien au milieu de la matrice en contrôlant que les pistons dépassent symétriquement de part et d'autre de la matrice (figure 1.12(b)). Un contrôle de niveau est également effectué afin d'assurer une répartition de la poudre la plus homogène possible le long de la surface.

Pour préparer des échantillons ayant une épaisseur supérieure à 5 mm, l'ensemble matrice-piston inférieur est déposé sur une table vibrante. Cette étape est importante pour obtenir des épaisseurs homogènes sur l'ensemble du diamètre, ce qui permet au final de limiter les gradients de densité et de microstructure au sein de la pièce frittée.

Pour les échantillons cylindriques, c'est le cas général, les matrices sont dimensionnées de sortes qu'au diamètre des pistons soit ajouté l'épaisseur d'une feuille de graphite.

On trouve généralement les feuilles de graphite sous diverses épaisseurs ; suivant les im-



pératifs rencontrés, des feuilles de 0.2, 0.4, 0.5 ou 1 mm peuvent être utilisées. La feuille de graphite est disposée sur les surfaces de contact échantillon-matrice (figure 1.12(c)) (sur l'alésage intérieur des matrices et sur la face des pistons en contact). Sa fonction est d'assurer l'étanchéité (éviter la fuite de matière et les bavures), de permettre un bon contact électrique dans l'ensemble pistons-matrice-échantillon, de faciliter le démoulage de l'échantillon et enfin de préserver l'intégrité de l'outillage.

Les échantillons frittés sont en général des pastilles dont le diamètre est égal au diamètre intérieur des matrices, diminué de quelques dixièmes de millimètre dus à la présence de la feuille de graphite qui s'aplatit lors de l'application de la contrainte [30] .




FIGURE 1.12 – Étapes de préparation des échantillons : a) moule-pistons, b) pose de feuille de graphite c) assemblage moule - pistons – feuille de graphite, d) Installation du groupe entre les presses de la machine SPS, e) Installation du fil d'impulsion de courant électrique, f) échantillon pendant le processus de frittage .

### 3 Conclusion

Dans ce chapitre, nous avons présenté une revue détaillée de la littérature sur l'application des méthodes de réseaux de neurones artificiels pour prédire le comportement mécanique et physique des matériaux céramiques et des matériaux ayant des propriétés similaires. Nous avons ensuite fourni des définitions de ces matériaux et présenté leurs propriétés communes. Puis nous avons défini le matériau alumine en termes de propriétés et de processus de production, car ce dernier constitue la base de notre étude. Les méthodes d'élaboration des échantillons sont également présentées.

## Références du Chapitre 1

[1] Altinkok, N., & Koker, R. (2006). Modelling of the prediction of tensile and density properties in particle reinforced metal matrix composites by using neural networks. *Materials & design*, 27(8), 625-631.

[2] Altinkok, N., & Koker, R. (2004). Neural network approach to prediction of bending strength and hardening behaviour of particulate reinforced (Al-Si-Mg)-aluminium matrix composites. *Materials & design*, 25(7), 595-602.

[3] Altinkok, N., Koker, R. (2005). Mixture and pore volume fraction estimation in Al<sub>2</sub>O<sub>3</sub>/SiC ceramic cake using artificial neural networks. *Materials & Design*, 26(4), 305–311.

[4] Koker, R., Altinkok, N., & Demir, A. (2007). Neural network based prediction of mechanical properties of particulate reinforced metal matrix composites using various training algorithms. *Materials & design*, 28(2), 616-627.

[5] Sha, W., & Edwards, K. L. (2007). The use of artificial neural networks in materials science based research. *Materials & Design*, 28(6), 1747–1752.

[6] Hassan, A. M., Alrashdan, A., Hayajneh, M. T., & Mayyas, A. T. (2009). Prediction of density, porosity and hardness in aluminum–copper-based composite materials using artificial neural network. *Journal of Materials Processing Technology*, 209(2), 894–899.

[7] Malinov, S., Sha, W., & McKeown, J. J. (2001). Modelling the correlation between processing parameters and properties in titanium alloys using artificial neural network. *Computational materials science*, 21(3), 375-394.

[8] Mohamadi, M., Alavitabari, S., & Aliasghary, M. (2022). Prediction of mechanical and thermal properties in bronze-filled polyamide 66 composites using artificial neural network. *Polymer Bulletin*, 79(7), 4905-4921.

[9] Li, S., Dan, Y., Li, X., Hu, T., Dong, R., Cao, Z., & Hu, J. (2020). Critical temperature prediction of superconductors based on atomic vectors and deep learning. *Symmetry*, 12(2), 262.

[10] Viatkin, D., Garcia-Zapirain, B., Méndez-Zorrilla, A., & Zakharov, M. (2021). Deep Learning Approach for Prediction of Critical Temperature of Superconductor Ma-

terials Described by Chemical Formulas. *Frontiers in Materials*, 318.

[11] Guan, K., Jia, L., Chen, X., Weng, J., Ding, F., & Zhang, H. (2014). Improvement of fracture toughness of directionally solidified Nb-silicide in situ composites using artificial neural network. *Materials Science and Engineering : A*, 605, 65-72.

[12] Liu, G., Jia, L., Kong, B., Feng, S., Zhang, H., & Zhang, H. (2017). Artificial neural network application to microstructure design of Nb-Si alloy to improve ultimate tensile strength. *Materials Science and Engineering : A*, 707, 452-458.

[13] Pramod, R., Kumar, G. V., Gouda, P. S., & Mathew, A. T. (2018). A study on the Al<sub>2</sub>O<sub>3</sub> reinforced Al7075 metal matrix composites wear behavior using artificial neural networks. *Materials Today : Proceedings*, 5(5), 11376-11385.

[14] Majdi, H. S., Saud, A. N., & Saud, S. N. (2019). Modeling the physical properties of gamma alumina catalyst carrier based on an artificial neural network. *Materials*, 12(11), 1752.

[15] Fantozzi, G., Le Gallet, S., & Niepce, J. C. (Eds.). (2009). *Science & technologies céramiques*. EDP Sciences.

[16] Boch, P. (2001). *Matériaux et processus céramiques*. Hermes Science, Paris.

[17] Haussonne, J. M. (2005). *Céramiques et verres : principes et techniques d'élaboration* (Vol. 16). PPUR presses polytechniques.

[18] Holand, W., & Beall, G. H. (2019). *Glass-ceramic technology*. John Wiley & Sons.

[19] Rahaman, M. N. (2017). *Ceramic processing and sintering*. CRC press.

[20] C. Rizzi, L. Durand(1999). *Les Céramiques Industrielles*, CARMA.

[21] J. Denape, (1996). *Les céramiques à usages mécaniques et thermomécanique*, école nationale d'ingénieurs de Tarbes, France.

[22] West, R. C., & Astle, M. J. (1983). *CRC handbook of chemistry and physics* (pp. F-181). Boca Raton, FL : CRC press.

[23] J.M. Dorlot, J.P. Bailon, J. Masounave, (1991). *Des matériaux*, 2e éditions, Ecole

Polytechnique de Montréal.

[24] Belghalem, H. (2014). Etude de la résistance au choc thermique d'un matériau fragile : cas d'une céramique type alumine (Thèse de doctorat).

[25] Smallman, R. E., & Bishop, R. J. (1999). Modern physical metallurgy and materials engineering. Butterworth-Heinemann.

[26] Louet, N. (2003). Influence du dopage à la silice ou à l'oxyde de calcium sur le frittage et sur l'évolution microstructurale d'une alumine-alpha ultra pure (Thèse de doctorat, Lyon, INSA).

[27] Joliff, Y. (2006). Etude expérimentale et numérique des propriétés d'élasticité de matériaux modèles hétérogènes (Thèse de doctorat, Limoges).

[28] Cizeron, G. (1968). Le frittage sous son aspect physico-chimique. L'industrie céramique, 611(10), 713-729.

[29] Shen, Z., Johnsson, M., Zhao, Z., & Nygren, M. (2002). Spark plasma sintering of alumina. Journal of the American Ceramic Society, 85(8), 1921-1927.

[30] Naïmi, F. (2013). Approches scientifiques et technologiques du frittage et de l'assemblage de matériaux métalliques par SPS : Scientific and technological approaches for sintering and joining of metallic materials by SPS (Thèse de doctorat, Université de Bourgogne).

# Chapitre 2

## Choc thermique

### Objectifs

L'objectif de ce chapitre est de présenter les différentes approches adoptées dans la littérature pour étudier la résistance aux chocs thermiques des matériaux fragiles en général et des matériaux céramiques en particulier et de présenter le protocole expérimental adopté pour déterminer la base de données utilisée dans cette étude.

### Sommaire

|       |   |           |
|-------|---|-----------|
| 1     | Introduction . . . . .                                | <b>43</b> |
| 2     | Mécanismes de transfert de chaleur . . . . .          | <b>43</b> |
| 2.1   | Résistance aux chocs thermiques . . . . .             | 46        |
| 2.2   | Paramètres de choc thermique (paramètres R) . . . . . | 46        |
| 2.2.1 | Approche thermoélastique . . . . .                    | 46        |
| 2.2.2 | Approche énergétique . . . . .                        | 48        |
| 2.2.3 | Approche en termes de FIC . . . . .                   | 50        |
| 3     | Essai de Choc Thermique . . . . .                     | <b>50</b> |
| 3.1   | Procédure Expérimentale . . . . .                     | 50        |
| 3.2   | Ecart de température critique . . . . .               | 52        |
| 4     | Conclusion . . . . .                                  | <b>54</b> |

## 1 Introduction

Un choc thermique se produit lors d'un changement brutal de la température d'un matériau. La plupart des applications des matériaux céramiques impliquent des gradients de température qui varient dans le temps. Ces gradients produisent des déformations différentielles dans les composants et, par conséquent, des contraintes (c'est-à-dire des contraintes thermiques). Si les contraintes créées dépassent la résistance à la rupture du matériau, une dégradation ou même une rupture complète se produit. Avec la corrosion et l'abrasion, la rupture due aux contraintes thermiques est l'un des principaux mécanismes de dégradation de nombreuses pièces céramiques en service [1].

## 2 Mécanismes de transfert de chaleur

Lorsque les matériaux céramiques sont exposés à un changement de température, ils sont dans un état thermodynamique déséquilibré et cherchent donc à homogénéiser leur température avec un transfert thermique. La deuxième loi de la thermodynamique stipule que l'énergie thermique ne peut être transférée entre deux milieux que s'il existe un gradient de température (déséquilibre thermique) entre eux. Par conséquent, nous pouvons dire que le transfert de chaleur tend à normaliser les températures de ses composants lorsque le système sort de l'équilibre thermodynamique. Trois principaux mécanismes de transfert de chaleur peuvent être distingués : la conduction, la convection et le rayonnement. que l'on peut classer en trois modes :

**Conduction** : La conduction thermique est la propagation de la chaleur de molécules à molécules dans un corps ou dans plusieurs corps contigus et opaques, sans transfert de matière. La chaleur est alors transmise par contact immédiat des particules de températures différentes, ce qui définit l'échange d'énergie entre les molécules, les atomes, et les électrons libres [2-4].

La densité de flux de chaleur est proportionnelle au gradient de température.

$$\varphi = \frac{d\phi}{dS} = -\lambda \frac{\partial \theta}{\partial X} \quad (2.1)$$

$\varphi$  : flux de chaleur en Watts,

$\theta$  : température en degrés Celsius,

$S$  : surface d'échange en  $m^2$ ,

$X$  : coordonnée du point considéré en m,

$\lambda$  : conductivité thermique en Watts /m °C.

**Équation de la chaleur** : Un bilan d'énergie, et l'expression de la loi de Fourier conduit à l'équation générale de conduction de la chaleur. Elle est donnée sous sa forme unidimensionnelle :

$$\frac{\partial}{\partial x}(\lambda \frac{\partial T}{\partial x}) + P = \rho \cdot c \frac{\partial T}{\partial t} \quad (2.2)$$

Où :

$P$  : est l'énergie produite au sein même du matériau en  $W.m^{-3}$ ,

$\rho$  : la masse volumique du matériau en  $kg.m^{-3}$ ,

$c$  : la chaleur massique du matériau en  $J.kg^{-1}.K^{-1}$ .

L'équation de la chaleur dans le cas le plus général :

$$\frac{\partial}{\partial x}(\lambda_x \frac{\partial T}{\partial x}) + \frac{\partial}{\partial y}(\lambda_y \frac{\partial T}{\partial y}) + \frac{\partial}{\partial z}(\lambda_z \frac{\partial T}{\partial z}) + P = \rho \cdot c \frac{\partial T}{\partial t} \quad (2.3)$$

Cette équation peut se simplifier dans un certain nombre de cas :

1) Si le milieu est isotrope :  $\lambda_x = \lambda_y = \lambda_z = \lambda$

2) S'il n'y a pas de génération d'énergie à l'intérieur du système :  $P=0$

3) Si le milieu est homogène,  $\lambda$  n'est fonction que de  $T$

Les trois hypothèses citées précédemment permettent d'écrire :

$$\lambda \left( \frac{\partial^2 T}{\partial x^2} + \frac{\partial^2 T}{\partial y^2} + \frac{\partial^2 T}{\partial z^2} \right) + \frac{d\lambda}{dT} \left[ \left( \frac{\partial T}{\partial x} \right)^2 + \left( \frac{\partial T}{\partial y} \right)^2 + \left( \frac{\partial T}{\partial z} \right)^2 \right] = \rho \cdot c \frac{\partial T}{\partial t} \quad (2.4)$$

Au cas où  $P$  est nulle et où l'on fait de plus l'approximation que la conductivité thermique  $\lambda$  ne dépend pas de la position :

$$\lambda \frac{\partial^2 T}{\partial x^2} = \rho \cdot c \frac{\partial T}{\partial t} \quad (2.5)$$

**Convection** : La convection est le transfert de chaleur par les volumes de gaz ou de liquide se déplaçant dans l'espace. L'échange de chaleur entre un liquide ou un gaz et la surface d'un corps solide s'effectue par convection. Les phénomènes de convection interviennent dans la transmission de la chaleur. Ceci se produit chaque fois qu'un fluide se déplace par rapport à des éléments fixes : murs, plaques, parois de tubes, etc... [2,4].

Lorsqu'un solide est baigné par un fluide en mouvement, de la chaleur est échangée par convection thermique entre le solide et les particules de fluide se trouvant à son contact. De même, à l'intérieur du fluide, la chaleur se transmet par conduction entre deux particules voisines, mais celles-ci se renouvellent en permanence et reviennent au contact de particules différentes [5].

Le taux de transfert de chaleur est généralement exprimé comme suit :



$$\phi = h.S(T_1 - T_2) \quad (2.6)$$

$\phi$  : flux de chaleur échangé en Watts ,  
 $S$  : surface d'échange en mètre carré ,  
 $T_1$  : température ambiante en °C ,  
 $T_2$  : température de surface du solide en °C ,  
 $h$  : Coefficient de convection en  $W/m^2\check{C}$ .

**Rayonnement** : Tous les corps solides, liquides ou gazeux, émettent un rayonnement de nature électromagnétique. Il s'agit d'un flux de chaleur. Cette émission d'énergie s'effectue au détriment de leur énergie interne. Ce rayonnement n'est pas monochromatique ; Il est composé de radiations de longueurs d'ondes différentes (0,3  $\mu\text{m}$  à 100  $\mu\text{m}$ ). Son intensité dépend de la température du corps. La transmission de la chaleur par rayonnement, entre les surfaces de deux solides, obéit à la loi de **Boltzmann**. Son exactitude et son accord avec les faits surpassent celles des autres lois de transmission de la chaleur. Cette loi s'exprime par une relation de la forme [5] :

$$\phi = \varepsilon.F.\sigma.S(T_1^4 - T_2^4) \quad (2.7)$$

$\phi$  : Flux de chaleur transmis en watts,  
 $T_1$  : Température de la surface émettrice en °K,  
 $T_2$  : Température de la surface réceptrice en °K,  
 $S$  : Aire de la surface émettrice,  
 $\sigma$  : Constante de Boltzmann égale à  $5,73.10^{-8} W/m^2.K$ ,  
 $\varepsilon$  : Coefficient mutuel de rayonnement,  
 $F$  : facteur d'angle de la surface réceptrice par rapport à la surface émettrice.

Ces modes peuvent se produire simultanément. En particulier, la convection est toujours accompagnée de conduction et on définit dans ce cas, le coefficient sans dimension  $\beta$ , appelé nombre de Biot par [6] :

$$\beta = \frac{hL}{\lambda} \quad (2.8)$$

avec :

$h$  : coefficient d'échange superficiel ( $W/(m^2K)$ ),  
 $\lambda$  : conductivité thermique du matériau ( $W/mK$ ),  
 $L$  : dimension de la pièce, caractéristique de la direction du flux de chaleur.

Le nombre de Biot est une caractéristique de la sévérité du choc thermique (Tableau 2.1).

TABLE 2.1 – Sévérité du choc thermique

| $\beta$       | Transfert de la chaleur |         | Gradient thermique | Sévérité du choc    | Milieu de la trempe        |
|---------------|-------------------------|---------|--------------------|---------------------|----------------------------|
|               | En surface              | En cœur | Surface- cœur      |                     |                            |
| <b>Grand</b>  | rapide                  | lent    | élevé              | Dur<br>(sévère)     | Milieu aqueux              |
| <b>Faible</b> | lent                    | lent    | faible             | Mou<br>(peu sévère) | Refroidissement<br>à l'air |

Dans le cas d'un refroidissement rapide d'une pièce (choc thermique descendant), la surface refroidie tend à se contracter, alors que le cœur encore chaud, reste dilaté et s'oppose à cette contraction. Il résulte des contraintes de tension (traction) en surface et des contraintes de compression à cœur. Le processus est inversé lorsque la température finale est supérieure à la température initiale du matériau (choc ascendant). Dans ce cas, la surface est soumise à des contraintes de compression alors que le cœur est en tension [6].

## 2.1 Résistance aux chocs thermiques

La résistance aux chocs thermiques est la capacité d'un matériau à résister aux changements brutaux de température, généralement importants et rapides. Ces changements de température sont à l'origine de l'apparition de contraintes thermiques dans les matériaux fragiles, notamment les matériaux céramiques. Ces efforts thermiques provoquent la propagation de microfissures qui endommagent le matériau.

Trois approches ont longtemps dominé dans l'analyse théorique de la résistance au choc thermique des matériaux céramique : l'approche thermoélastique de Kingery, l'approche énergétique de Hasselman et l'approche en termes de facteur d'intensité de contrainte d'Evan.

## 2.2 Paramètres de choc thermique (paramètres R)

### 2.2.1 Approche thermoélastique

Développée par **Kingery** dans les années cinquante [7], cette approche en termes de contraintes suppose un matériau homogène, isotrope et de comportement mécanique linéaire élastique parfaitement fragile.

La pièce initialement à la température  $T_i$  est brutalement placée dans un milieu dont

la température est  $T_f$ . La surface est donc soumise à une contrainte dont l'expression est donnée par la loi de Hooke :

$$\sigma_{th} = E \cdot \varepsilon \cdot f(\nu) \quad (2.9)$$

$E$  : Module de Young du matériau,

$f(\nu)$  : Facteur géométrique dépendant du coefficient de poisson. Il vaut respectivement 1,  $1/1 - \nu$ ,  $1/1 - 2\nu$  pour des contraintes uniaxiales, biaxiales, triaxiales.

$\varepsilon = \alpha(T_i - T_f)$  : Déformation de la surface sous l'effet de la contribution du cœur  $\sigma_{th} = \sigma_R$  avec  $\alpha$  : coefficient de dilatation thermique linéaire.

Un endommagement du matériau survient lorsque la contrainte thermique atteint, localement, la valeur de la résistance à la rupture du matériau ( $\sigma_{th} = \sigma_R$ ). L'écart de température appliqué est alors dit critique et est donné par :

$$\Delta T_c = \frac{\sigma_R}{f(\nu) E \alpha} \quad (2.10)$$

Cette expression correspond au cas idéal où les échanges thermique en surface sont instantanés. Afin de tenir compte de la vitesse finie de ces échanges. Un coefficient de réduction de contraintes  $\psi$ , fonction du nombre de Biot ( $\beta$ ), est introduit dans l'expression (2.10) qui devient :

$$\Delta T_c = \frac{1}{\psi(\beta)} \frac{\sigma_R}{f(\nu) E \alpha} \quad (2.11)$$

Le coefficient  $\psi$ , est compris entre (0 et 1) et permet de distinguer un choc dur d'un choc mou selon la valeur de  $\beta$ . Pour une plaque infinie, il est donné par Galandus  $\psi^{-1} = 1.5 + 3.25/\beta - 0.5 \exp(-16/\beta)$  [8].

Si  $\beta$  est très élevé (cas d'un choc dur idéal),  $\psi$  est voisin de 1 et l'écart critique de température est donné par la relation (2.12). On définit alors un premier paramètre de résistance au choc thermique, ( $R$ ), par (cas d'une sollicitation biaxiale) :

$$R = \Delta T_c = \frac{\sigma_R(1 - \nu)}{E \alpha} \quad (2.12)$$

Un matériau est d'autant plus résistant à un choc thermique sévère que  $R$  est important.

Pour de faibles valeurs de  $\beta$  (chocs mous),  $\psi$  tend vers zéro et est proportionnel à  $\beta$  ( $\psi = M\beta$  où  $M$  est une constante). On a alors en remplaçant  $\beta$  par son expression ( $hL/k$ ) :

$$\Delta T_c = \frac{1}{ML} \frac{1}{h} \lambda \frac{\sigma_R(1 - \nu)}{E \alpha} \quad (2.13)$$

Pour des chocs mous, le phénomène de conduction est prédominant devant la convec-

tion en surface. On définit dans ce cas un deuxième paramètre de résistance au choc thermique  $R'$ , qui fait intervenir la conductivité  $\lambda$  :

$$R' = \lambda \frac{\sigma_R(1 - \nu)}{E\alpha} = \lambda.R \quad (2.14)$$

### 2.2.2 Approche énergétique

Cette approche a été développée par **D.P.H. Hasselmann** [9,10] qui a basé son analyse sur les hypothèses suivantes :

- les défauts sont supposés circulaires, de même taille et de taille uniforme (densités volumiques  $N$ ),
- le matériau est parfaitement fragile,
- contraintes mécaniques triaxiales (la plupart du temps défavorables),
- la propagation des fissures est purement radiale,
- absence d'interaction entre les différents défauts.
- La propagation des fissures lors du choc thermique se produit en l'absence de contraintes externes.

Il a découvert que la propagation des fissures provenait de l'énergie élastique stockée dans le solide au moment de la rupture. L'énergie totale ( $w_t$ ) d'un système élastique fissuré est égale à la somme de l'énergie totale de surface ( $w_s$ ) associée aux fissures et de l'énergie élastique ( $w_{el}$ ) de déformation.

Selon cette analyse, les fissures sont instables si une augmentation de leur taille entraîne une diminution de l'énergie totale du système fissuré. Ainsi, les valeurs négatives de  $(\partial\omega_t/\partial a)$  caractérisent les fissures instables,  $a$  étant la taille de la fissure, et inversement les valeurs  $(\partial\omega_t/\partial a > 0)$  sont traduites comme la condition de stabilité des fissures. L'énergie totale de surface est donnée par :

$$\omega_s = 2\pi N a^2 \gamma \quad (2.15)$$

avec :  $(\gamma, a)$  sont l'énergie superficielle et le rayon des fissures.

L'énergie élastique volumique d'un solide isotrope a pour expression :

$$w_{el} = \frac{3(\alpha\Delta T)^2 E_0}{2(1 - 2\nu_0)} \left[ 1 + \frac{16(1 - \nu_0^2) N a^3}{9(1 - 2\nu_0)} \right]^{-1} \quad (2.16)$$

Où  $E_0$  et  $\nu_0$  sont le module d'Young et le coefficient de Poisson du matériau non fissuré. En partant des relations (2.15) et (2.16) Hasselmann a montré que la différence de température critique  $\Delta T_c$  responsable de l'instabilité des fissures est donnée par l'équation [11] :

$$\Delta T_c = \frac{(1 - 2\nu_0)}{\alpha} \left[ \frac{\pi\gamma}{2E(1 - 2\nu_0^2)} \right]^{\frac{1}{2}} \left[ 1 + \frac{16(1 - \nu_0^2)Na^3}{9(1 - 2\nu_0)} \right] a^{-\frac{1}{2}} \quad (2.17)$$

Pour des fissures de petites dimensions l'expression (2.17) peut être remplacée par :

$$\Delta T_c = \frac{(1 - 2\nu_0)}{\alpha} \left[ \frac{\pi\gamma}{2E(1 - 2\nu_0^2)} \right]^{\frac{1}{2}} \quad (2.18)$$

Pour des fissures de grandes dimensions la relation (2.17) se simplifie comme suit :

$$\Delta T_c = \frac{16N}{9\alpha} \left[ \frac{\pi\gamma(1 - 2\nu_0^2)}{2E} \right] a^{\frac{5}{2}} \quad (2.19)$$

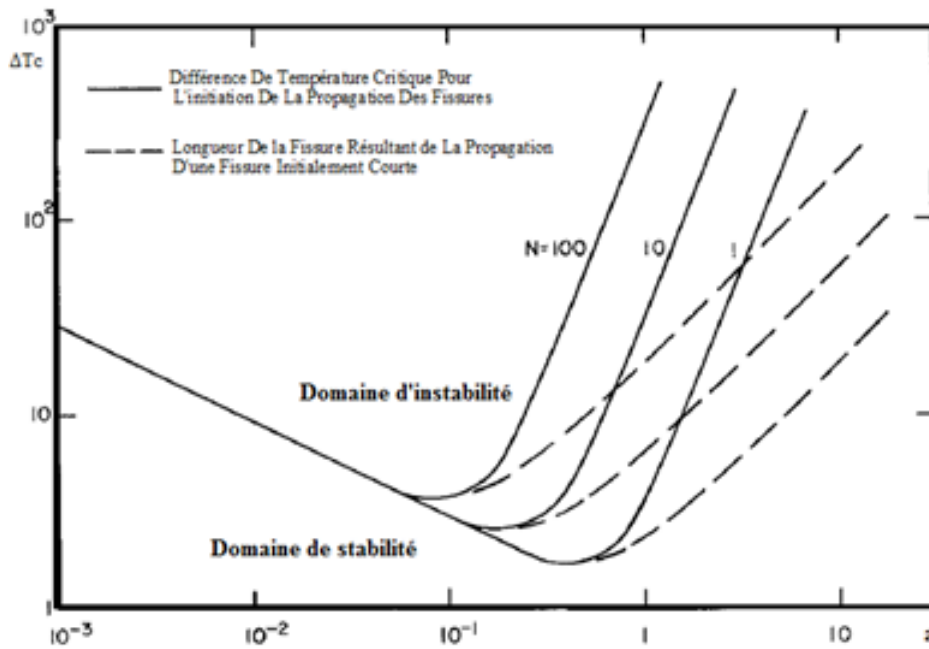


FIGURE 2.1 – Variation de la différence de température critique  $\Delta T_c$  responsable de la propagation des fissures. Selon le modèle de Hasselman en fonction de la longueur  $a$  et de la densité volumique des fissures  $N$ . ( $\mu_0 = 0.25$ ) [10] .

La courbe de variation de  $\Delta T_c$  en fonction de  $a$  par conséquent, un minimum pour une valeur  $a_0$  de la longueur de fissure. La courbe, schématisée sur la figure 2.1, délimite un domaine d'instabilité et un domaine de stabilité des fissures.

Lorsqu'une fissure de taille  $a_i$ , inférieure à  $a_0$ , est activée, elle se propage de manière instable jusqu'à une valeur ( $\hat{a}$ ), qui correspond à un nouvel état stable. La propagation se poursuit jusqu'à ce que l'excédent d'énergie cinétique, soit compensé par la création de nouvelles surfaces fissurées [6] .

Cette deuxième approche, nous présente deux autres paramètres de résistance aux chocs thermiques  $R'''$  et  $R''''$  donnés par les relations suivantes :

$$R''' = \frac{E}{\sigma_R^2(1 - \nu)} \quad (2.20)$$

$$R'''' = \frac{\gamma E}{\sigma_R^2(1 - \nu)} \quad (2.21)$$

Les paramètres de résistance aux chocs thermiques (les paramètres TSR sont appelés  $R$ ,  $R'$ ,  $R''$ ,  $R'''$ ) définis dans les paragraphes précédents et habituellement retrouvés dans la littérature reposent sur des modèles très simplifiés, négligeant ou simplifiant l'influence de certaines propriétés des matériaux, la géométrie des composants et les conditions de transfert de chaleur. Bien que les considérations théoriques sous-jacentes à sa dérivation soient indiscutablement précieuses et cruciales pour comprendre le problème de la contrainte thermique, sa pertinence pour prédire la TSR dans les applications industrielles nécessite une extrême prudence [12].

### 2.2.3 Approche en termes de FIC

Une analyse plus fine, permettant une meilleure compréhension des processus ayant lieu lors d'un choc thermique, a été développée par **Evans, Emery, Sato et Schneider** [13-16]. Cette analyse, basée sur le facteur d'intensité de contrainte (FIC), utilise les concepts de base de la thermoélasticité et de la mécanique de la rupture. Elle permet de tenir compte du caractère transitoire du choc thermique en déterminant à chaque instant :

- le profil des températures,
- le champ des contraintes qui en résulte,
- le facteur d'intensité de contrainte (FIC) en fonction de la taille de fissures.

Cette approche se base sur la solution de l'équation de la chaleur (2.4), la détermination du profil des températures induit lors d'un choc thermique nécessite généralement l'utilisation de méthodes numériques.

## 3 Essai de Choc Thermique

### 3.1 Procédure Expérimentale

Les essais de choc thermique ont été réalisés sur des éprouvettes de dimensions ( $3 \times 4 \times 40 \text{ mm}^3$ ), sur un dispositif (figure 2.2), dont le principe est schématisé sur la figure 2.3. Le dispositif piloté par un micro-ordinateur, comprend :

- Un four qui permet d'atteindre des températures allant jusqu'à  $1400^\circ\text{C}$ .

- Un système de deux souffleries qui assurent le refroidissement de l'échantillon par envoi d'un jet d'air à la température ambiante ; un système de régulation en pression et en débit permet d'avoir des conditions de refroidissement reproductibles.
- Un vérin porte échantillon qui permet de positionner l'échantillon à l'intérieur du four (position haute) ou devant les souffleries d'air (position basse).




FIGURE 2.2 – Dispositif de choc thermique




FIGURE 2.3 – Un schéma simplifié de l'appareil

L'échantillon est chauffé dans le four et maintenu pendant 10 minutes à la température initiale choisie afin de d'homogénéiser sa température. Il est ensuite amené à l'aide du vérin devant les deux souffleries qui réalisent un refroidissement rapide. Le refroidissement est réalisé de manière symétrique sur les faces de plus grandes dimensions de l'échantillon, orientées perpendiculairement à la direction du jet d'air. Ces faces ont été préalablement polies.

Afin de détecter l'endommagement éventuel de l'échantillon lors du choc thermique, son émission acoustique (E.A) a été enregistrée durant le refroidissement. Pour cela, un capteur piézo-électrique est relié à l'échantillon par l'intermédiaire d'un guide d'onde.

L'activité acoustique est enregistrée après amplification, pendant les 6 premières secondes du refroidissement, temps au-delà duquel aucun endommagement n'a été observé pour les matériaux étudiés.

Les chocs thermiques ont été réalisés en portant des échantillons polis ( $3 \times 4 \times 40 \text{ mm}^3$ ) d'alumine ( $\alpha - \text{Al}_2\text{O}_3$ ), à des températures entre 600 et  $900^\circ\text{C}$ . Le polissage a été réalisé sur des feutres avec des suspensions diamantées (6, 3 et  $1\mu\text{m}$ ). Pour diminuer la dispersion des mesures lors du choc thermique, la méthode du défaut contrôlé a été utilisée [17], Comme le montre la figure (2.4) :




FIGURE 2.4 – Une indentation Vickers sur un échantillon

### 3.2 Écart de température critique

Le tableau 2.2 regroupe les valeurs d'écart de température critique. Un exemple du spectre d'émission acoustique enregistré pendant un choc thermique, pour un échantillon fritté par SPS figure 2.5.



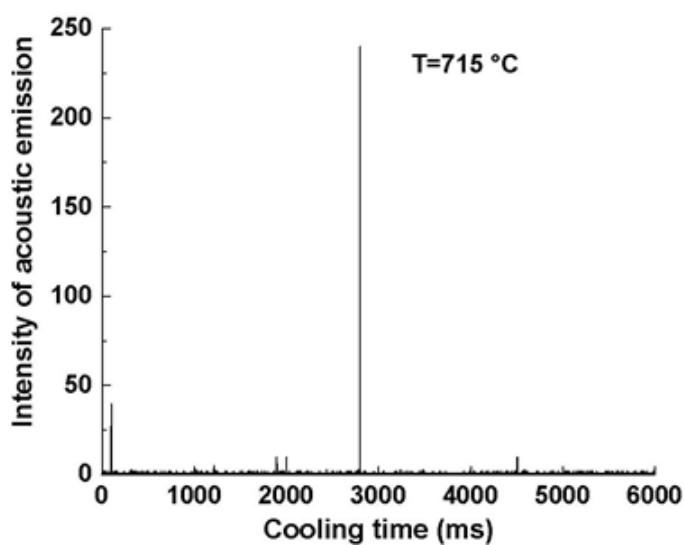
FIGURE 2.5 – Spectre d’EA obtenu pour l’alumine ( $\alpha - Al_2O_3$ ) à  $\Delta T = 1000^\circ C$ 

TABLE 2.2 – Valeurs d’écart de température critiques

| Température | Temps de maintien | Pression de frittage | Ecart de température critique $\Delta T_c$ |
|-------------|-------------------|----------------------|--|
| 1150        | 10                | 50                   | 715  |
| 1200        | 10                | 50                   | 782  |
| 1300        | 3                 | 25                   | 699  |
| 1300        | 10                | 50                   | 740  |
| 1150        | 3                 | 25                   | 694  |
| 1350        | 10                | 50                   | 681  |
| 1300        | 3                 | 50                   | 745  |
| 1200        | 3                 | 25                   | 658  |
| 1200        | 10                | 25                   | 641  |
| 1350        | 3                 | 25                   | 735  |
| 1150        | 10                | 25                   | 633  |
| 1250        | 3                 | 50                   | 642  |
| 1250        | 10                | 25                   | 775  |
| 1150        | 3                 | 50                   | 659  |
| 1350        | 10                | 25                   | 664  |
| 1250        | 3                 | 25                   | 709  |
| 1200        | 3                 | 50                   | 633  |
| 1300        | 10                | 25                   | 789  |
| 1350        | 3                 | 50                   | 668  |
| 1250        | 10                | 50                   | 724  |

## 4 Conclusion

Dans ce chapitre, nous avons détaillé les différents paramètres utilisés pour étudier la résistance aux chocs thermiques. Dans un premier temps, nous avons présenté les trois approches de base qui sont l'approche thermoélastique, l'approche énergétique et l'approche en termes de FIC. Enfin, nous avons présenté le travail expérimental réalisé pour obtenir le premier paramètre de la résistance au choc thermique.

## Références du Chapitre 2

[1] Baudín, C. (2020). Thermal Shock Behavior of Ceramics : Fundamentals and Thermal Shock Resistance Parameters. Reference Module in Materials Science and Materials Engineering. doi :10.1016/b978-0-12-803581-8.

[2] Léontiev, A. (1985). Théorie des échanges de chaleur et de masse, traduction française, édition MIR.

[3] Orfeuil. M., Robin. A. (1981). Electrothermie industrielle : Fours et équipements thermiques électriques industriels, Editions Dunod, 150 p.

[4] Chaussin, C., Hilly, G., & Barralis, J. (1969). Chaleur et thermodynamique (Vol. 2). Dunod.

[5] Malou, Z. (2018). Etude de la rupture du verre sous des contraintes thermiques (Thèse de doctorat).

[6] M. Saadaoui. (1996). Contribution à l'étude du comportement thermomécanique des matériaux céramiques à effet de courbe R : Choc et fatigue thermiques (Thèse de doctorat, L'école Mohammadia d'ingénieurs et l'INSA de Lyon, France).

[7] Kingery, W. D. (1955). Factors affecting thermal stress resistance of ceramic materials. Journal of the American Ceramic Society, 38(1), 3-15.

[8] J. C. Glandus. (1981) Rupture fragile et résistance aux chocs thermiques de céramiques à usages mécaniques (Thèse de doctorat d'état, université de Limoges).

[9] Hasselman, D. P. H. (1969). Unified theory of thermal shock fracture initiation and crack propagation in brittle ceramics. Journal of the American Ceramic society, 52(11), 600-604.

[10] Hasselman, D.P.H. (1970). Thermal stress resistance parameters for brittle refractory ceramics : A compendium. Amer. Ceram. Soc. Bull. 49(12), 1033-37.

[11] Khan, A. A. (1995). Elaboration et caractérisation d'un cermet AlN-Mo, utilisable comme anode de tube à R. X de puissance (Thèse de doctorat, Limoges).

[12] Brochen, E., Pötschke, J., & Aneziris, C. G. (2014). Improved thermal stress

resistance parameters considering temperature gradients for bricks in refractory linings. *International Journal of Applied Ceramic Technology*, 11(2), 371-383.

[13] A. G. Evans. (1975). thermal fracture in ceramic materials, *Proc. Br. Ceram. Soc*, 25, 217-235.

[14] Emery, A. F. (1980). Thermal stress fracture in elastic-brittle materials. In *Thermal Stresses in Severe Environments* (pp. 95-121). Springer, Boston, MA.

[15] Sato, S., Awaji, H., & Akuzawa, H. (1978). Evaluation of the thermal shock fracture toughness of reactor graphites by arc discharge heating. *Carbon*, 16(2), 103-109.

[16] Schneider, G. A. (1991). Thermal shock criteria for ceramics. *Ceramics international*, 17(6), 325-333.

[17] Belghalem, H. (2014). Etude de la résistance au choc thermique d'un matériau fragile : cas d'une céramique type alumine (Thèse de doctorat).

# Chapitre 3

## Réseaux de neurones

### Objectifs

Dans ce chapitre, nous introduisons la définition des méthodes d'intelligence artificielle et nous présentons les méthodes les plus courantes, ainsi que leurs domaines d'application dans la modélisation prédictive.

### Sommaire

---

|   |  |    |
|---|--|----|
| 1 | Introduction . . . . .                                 | 58 |
| 2 | Du neurone biologique au neurone formel . . . . .      | 60 |
| 3 | Classes de réseaux de neurones . . . . .               | 63 |
|   | 3.1 Réseau de neurones non bouclé . . . . .            | 63 |
|   | 3.2 Réseau de neurones bouclé (ou récurrent) . . . . . | 64 |
| 4 | Types de réseaux de neurones . . . . .                 | 64 |
| 5 | Fonctionnement d'un réseau . . . . .                   | 66 |
| 6 | L'apprentissage . . . . .                              | 67 |
|   | 6.1 L'apprentissage supervisé . . . . .                | 67 |
|   | 6.2 L'apprentissage non-supervisé . . . . .            | 67 |
|   | 6.3 L'apprentissage par renforcement . . . . .         | 68 |
|   | 6.4 Règles d'apprentissage . . . . .                   | 68 |
| 7 | Configuration optimale du réseau neuronal . . . . .    | 74 |
| 8 | Avantage des réseaux neuronaux . . . . .               | 74 |

---

## 1 Introduction

Les réseaux de neurones artificiels sont l'une des méthodes modernes par lesquels les chercheurs et les scientifiques sont fascinés par la complexité du cerveau humain dans le traitement des informations. Grâce aux progrès de la connaissance de certains modes de fonctionnement du cerveau humain, les scientifiques ont tenté et tentent encore de simuler le cerveau humain.

Ces derniers temps, les réseaux de neurones artificiels (ANNs) sont devenus des modèles utilisés et utiles pour la classification, la reconnaissance des formes et la prédiction dans de nombreuses disciplines. Les ANN sont un type de modèle pour l'apprentissage automatique (ML) et sont devenus relativement compétitifs par rapport aux modèles de régression et statistiques conventionnels en termes d'utilité.

Actuellement, l'intelligence artificielle (apprentissage automatique, réseau de neurones, apprentissage profond, robotique), la sécurité de l'information, le "big data", l'informatique en nuage, l'internet et la criminalistique sont tous des points chauds et des sujets passionnants des technologies de l'information et de la technologie des informations et des télécommunications (TIC). Toutes les applications des ANN peuvent être évaluées en fonction de facteurs d'analyse des données tels que la précision, la vitesse de traitement, la latence, les performances, la tolérance aux pannes, le volume, l'évolutivité et la convergence [1].

Grâce au traitement parallèle de l'information et à ses mécanismes inspirés de la compréhension du fonctionnement des neurones humains, les scientifiques ont déduit des propriétés émergentes qui permettent de résoudre des problèmes qualifiés de complexes.

Les travaux dans le domaine des réseaux neuronaux artificiels ont touché de nombreux domaines, notamment le social, l'économie et l'ingénierie, et continuent de se développer grâce aux progrès des logiciels modernes, des ordinateurs et de la science en général.

Un glossaire des applications des réseaux neuronaux artificiels dans un article **d'Olu-dare. I. A et al.(2018)** est présenté dans le tableau 3.1 et la figure 3.1. La liste donnée est basée sur l'application réussie des ANN à des problèmes du monde réel.

TABLE 3.1 – Résultats résumés de l'application des ANNs concernant la prédiction, la reconnaissance des formes et la classification [1].

| Exemples<br>de domaines<br>d'applications<br>des ANNs | Prédiction | Reconnaissance<br>de formes | Classification | Total |
|---|------------|-----------------------------|----------------|-------|
| Sécurité  | 20         | 18                          | 2              | 40    |
| Science   | 25         | 25                          | 2              | 52    |
| Ingénierie  | 22         | 7                           | 2              | 31    |
| Science médicale                                      | 10         | 5                           | 2              | 17    |
| Agriculture   | 3          | 3                           | 2              | 7     |
| Finance   | 10         | 15                          | 2              | 27    |
| Banque  | 5          | 15                          | 2              | 22    |
| Météo et climat                                       | 2          | 15                          | 2              | 19    |
| Education   | 30         | 15                          | 2              | 47    |
| Environnement   | 10         | 15                          | 2              | 27    |
| Énergie   | 5          | 15                          | 2              | 22    |
| Mines   | 2          | 15                          | 2              | 19    |
| Politique   | 2          | 2                           | 2              | 6     |
| Assurance   | 5          | 4                           | 2              | 11    |
| Marketing   | 5          | 5                           | 2              | 12    |
| Gestion   | 40         | 2                           | 2              | 44    |
| Fabrication   | 12         | 15                          | 5              | 32    |
| Autres domaines                                       | 52         | 11                          | 10             | 71    |

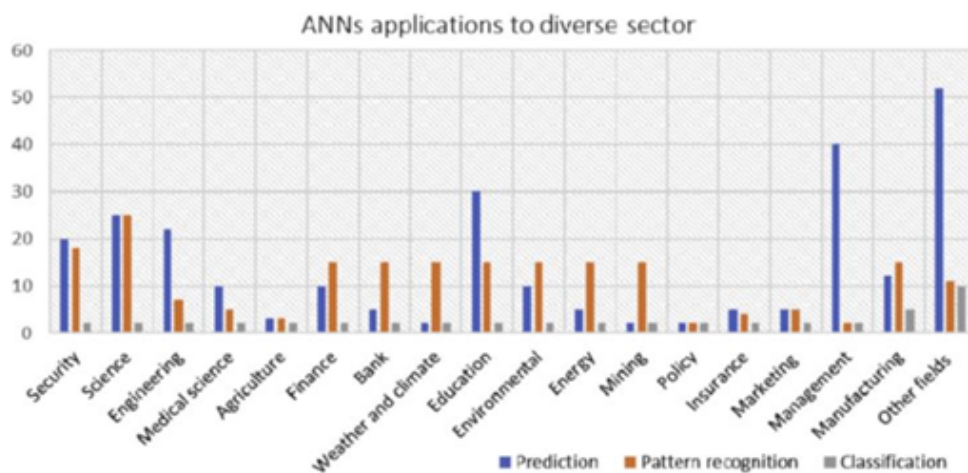


FIGURE 3.1 – Le cadre de la recherche réalisée en appliquant les réseaux de neurones artificiels dans de nombreux domaines [1].

## 2 Du neurone biologique au neurone formel

Le système nerveux humain est constitué de milliards de neurones de divers types et de longueurs utiles à leur emplacement dans le corps. Les cellules nerveuses, appelées neurones, sont les éléments de base du système nerveux central.

Un neurone biologique est une cellule vivante dédiée au traitement de l'information, constituée d'un corps cellulaire et d'un noyau. Le corps cellulaire se ramifie pour former ce qu'on appelle des dendrites. À travers les dendrites, les informations sont transférées de l'extérieur vers le corps du neurone (soma).

Les informations traitées par le neurone cheminent ensuite le long de l'axone (singulier) pour être transmises aux autres neurones. La transmission entre deux neurones n'est pas directe. En effet, il existe un espace intercellulaire de quelques dizaines d'Angströms ( $10^{-9} m$ ) entre l'axone d'un neurone afférent et les dendrites (dendrites) des neurones efférents. La jonction entre deux neurones s'appelle une synapse (Fig. 3.2(a)) [2].

La figure 3.2 (b) montre la structure d'un modèle général du neurone artificiel. Le neurone reçoit un nombre variable d'entrées ( $x_i$ ) en provenance de neurones amont. A chacune de ces entrées est associé un poids ( $w$ ) représentatif de la force de la connexion. Chaque processeur élémentaire (neurone) est doté d'une sortie unique qui se ramifie ensuite pour alimenter un nombre variable de neurones aval. A chaque connexion est associé un poids.

Les paramètres ( $x_i, w_{ij}, g(\cdot), \sum, Y$ ) représentés sur la Figure 3.2 (a) sont :

- $x_i$  est l'entrée  $i$  ;
- $w_{ij}$  est la valeur du poids synaptique qui relie l'entrée  $i$  au neurone  $j$  ;
- $\sum$  est la somme pondérée des entrées  $x_i$  ;
- $g(\cdot)$  est la fonction de transfert ;
- $Y$  est la sortie du neurone.

La sortie du neurone est déterminé par l'activation (ou transfert) en fonction du neurone. Le but de la fonction d'activation est d'introduire une non-linéarité dans le réseau. Cette non-linéarité associée aux interconnexions des neurones accomplit une cartographie des données propre à partir de signaux d'entrée pour les activités de sortie correspondants [3].

La fonction de transfert peut être aussi simple comme la fonction binaire appelé aussi



limiteur dur ou la fonction par étage. Le signal de sortie dépend du fait que le produit est positif ou négatif. La sortie est à '1' pour un produit positif et '0' pour un produit négatif. La sortie peut également être bipolaire entre [-1, +1]. Les principales fonctions de transfert sont présentées dans le tableau 3.2 ci-dessous [4].

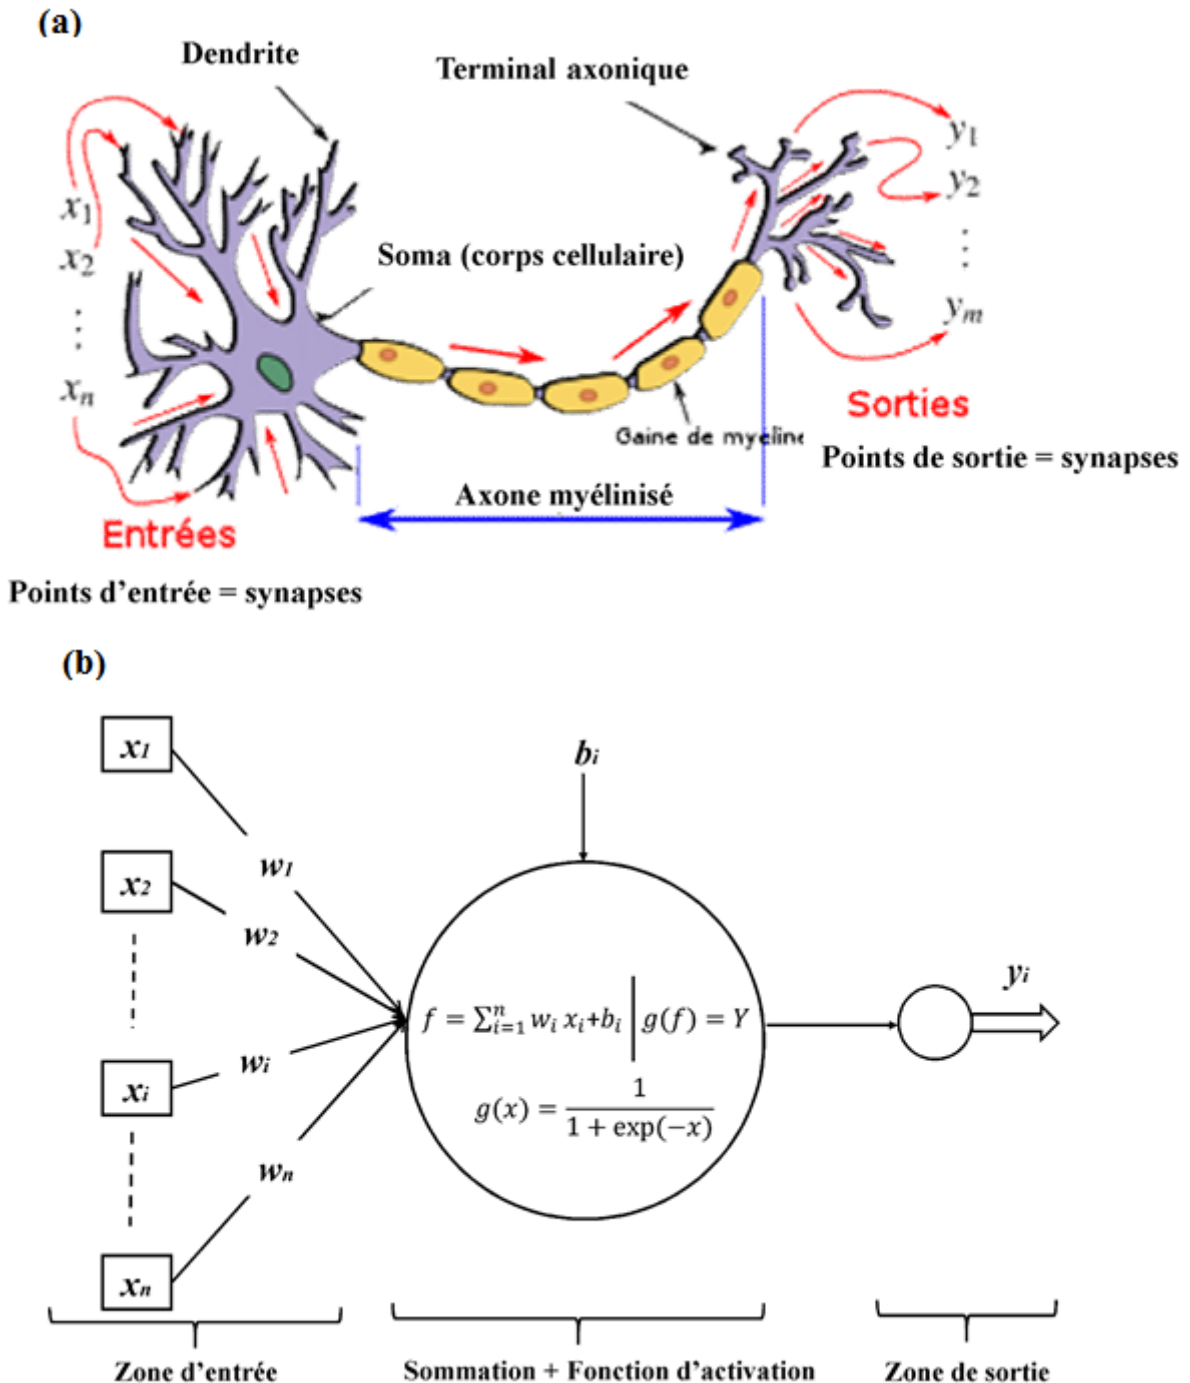
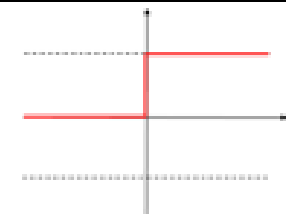

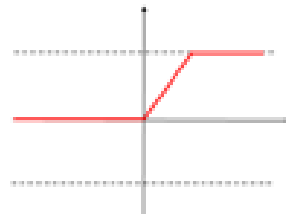
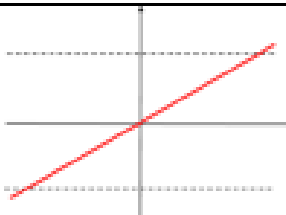
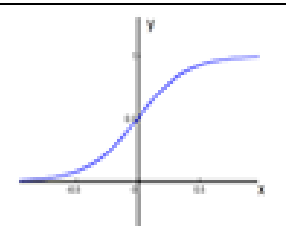
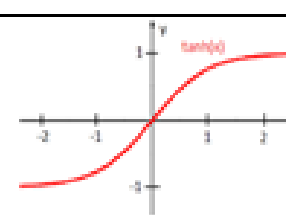


FIGURE 3.2 – Mise en correspondance entre : a) neurone biologique et b) neurone artificiel.

TABLE 3.2 – Les principales fonctions de transfert

| Fonction              | Equation   | Représentation  |
|-----------------------|--|---|
| Seuil                 | $f(x) = \begin{cases} 0 & \text{pour } x \leq 0 \\ x & \text{pour } x > 0 \end{cases}$                         |    |
| Seuil symétrique      | $f(x) = \begin{cases} -1 & \text{pour } x < 0 \\ 0 & \text{pour } x = 0 \\ 1 & \text{pour } x > 0 \end{cases}$ |    |
| Linéaire saturé       | $f(x) = \begin{cases} 0 & \text{pour } x < 0 \\ x & \text{pour } x \geq 0 \end{cases}$                         |   |
| Linéaire              | $f(x) = a.x$   |  |
| Sigmoïde              | $f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$  |  |
| Tangente hyperbolique | $f(x) = \tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$  |  |

Il y a également d'autres fonctions d'activation moins utilisées comme la fonction li-

néaire saturée symétrique (satlins), la fonction linéaire positive (poslin) et la fonction softmax [5].

La réussite ou l'échec du processus d'apprentissage dépend de la différenciation ou non de la fonction d'activation. Compte tenu de cette contrainte, la fonction non linéaire la plus utilisée en couche cachée est la fonction sigmoïde, car elle est facile de calculer les dérivées [6]. Les fonctions non linéaires les plus utilisées sont la fonction logistique et la fonction tangente hyperbolique [7].

### 3 Classes de réseaux de neurones

On distingue deux classes de réseaux de neurones : les réseaux non bouclés et les réseaux bouclés.

#### 3.1 Réseau de neurones non bouclé

Un réseau de neurones artificiels direct est un réseau neuronal artificiel où des connexions entre les unités ne forment pas un cycle dirigé. Le réseau neuronal direct a été le premier et le plus simple type de réseau de neurones artificiels imaginés. Dans ce réseau, l'information se déplace dans une seule direction, vers l'avant, à partir des nœuds d'entrée, par l'intermédiaire des nœuds cachés et de nœuds de sortie. Il n'y a pas de cycles ou des boucles dans le réseau [8]. Avec ce comportement, on les appelle des réseaux neuronaux à action directe (feedforward neural network (FFNN)) [8]. Des exemples de FFNN sont la perception à couche unique et le perceptron multicouche.

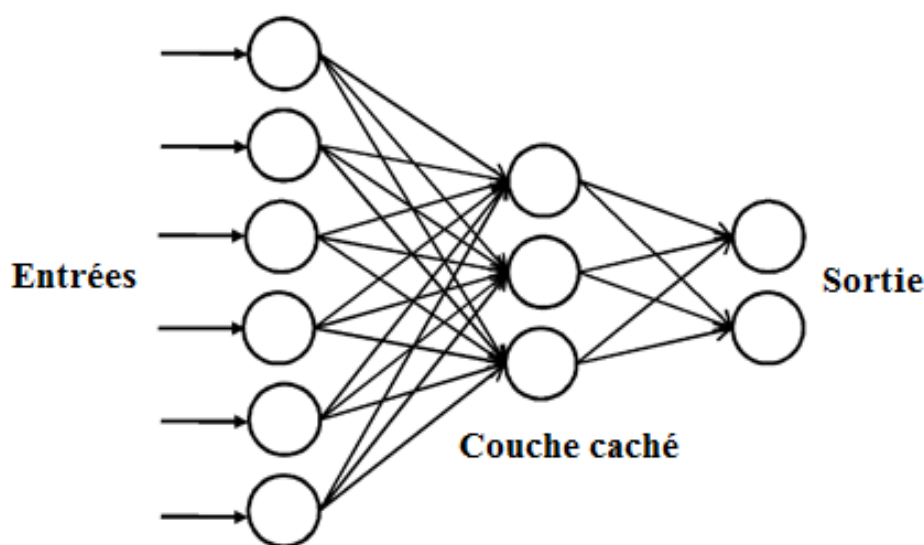


FIGURE 3.3 – Un réseau de neurone non bouclé.

### 3.2 Réseau de neurones bouclé (ou récurrent)

Un réseau de neurones artificiels récurrent est schématisé par un graphe des connexions qui est cyclique. Lorsqu'on se déplace dans le réseau en suivant le sens des connexions, il est possible de trouver au moins un chemin qui revient à son point de départ (un tel chemin est désigné sous le terme de "cycle") [1]. Ceci crée un état interne du réseau qui lui permet un comportement temporel dynamique. Contrairement aux réseaux de neurones directs (feed-forward), les RNAR peuvent utiliser leur mémoire interne pour traiter les séquences arbitraires d'intrants. Cela les rend applicable à des tâches telles que la reconnaissance de l'écriture manuscrite connecté non segmenté, où ils ont obtenu les meilleurs résultats connus [9].

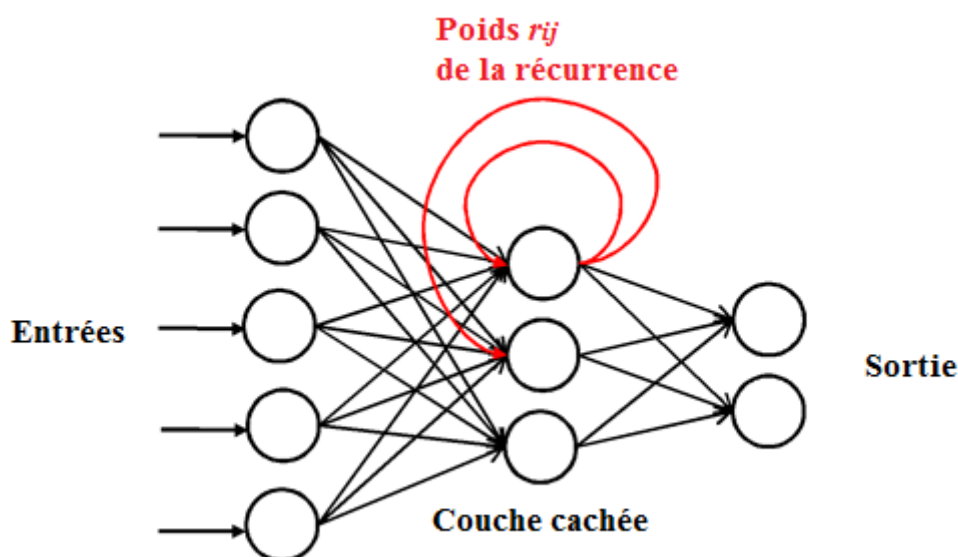


FIGURE 3.4 – Un Structure d'un réseau de neurone récurrent (bouclé).

## 4 Types de réseaux de neurones

Les types de réseaux neuronaux artificiels sont nombreux en raison de la multiplicité et de la nature différente des problèmes étudiés, et ne peuvent donc pas être limités à des paragraphes ou à un chapitre. Dans les paragraphes suivants, nous aborderons les plus importants et les plus célèbres d'entre eux et nous nous concentrerons sur ceux qui sont liés à l'objet de notre étude.

Il existe plusieurs modèles de réseau de neurones artificiels (Tableau 3.3). Chaque modèle est caractérisé par son architecture, son traitement et sa règle d'apprentissage.

TABLE 3.3 – Types de réseaux neuronaux et leurs applications.

| Types de réseaux neuronaux  | Applications   |
|---|--|
| Perceptron  | <b>P</b><br>- Classification.<br>- Codage de la base de données.<br>- Contrôler l'accès aux données.   |
| Réseau de neurones feed forward<br>(feed forward neural network)                        | <b>FFNN</b><br>- Compression des données.<br>- Reconnaissance des formes.<br>- Vision par ordinateur.<br>- Reconnaissance de cibles par sonar.<br>- Reconnaissance de la parole.<br>- reconnaissance de caractères manuscrits. |
| Réseau de neurones à fonction de base radiale<br>(Radial basis function neural network) | <b>RBFNN</b><br>- Approximation des fonctions.<br>- Prédiction de séries temporelles.<br>- Classification.<br>- Contrôle des systèmes.   |
| Deep Feed-forward   | <b>MLP</b><br>- Compression des données.<br>- Reconnaissance des formes.<br>- Vision par ordinateur.<br>- Prédiction financière.   |
| Réseau neuronal récurrent<br>(Recurrent Neural Network)                                 | <b>RNN</b><br>- Traduction automatique.<br>- Contrôle des robots.<br>- Prédiction de séries temporelles.<br>- Reconnaissance de la parole.<br>- Apprentissage des rythmes.<br>- Composition musicale.                          |
| Réseaux de neurones convolutifs<br>(Convolutional Neural networks)                      | <b>CNN</b><br>- Identifier les visages, les panneaux de signalisation, ...<br>- Reconnaissance d'image.<br>- Analyse vidéo.<br>- Prédiction des séries temporelles   |
| Machine d'apprentissage extrême<br>(Extreme Learning Machine)                           | <b>ELM</b><br>- Classification, Régression.<br>- Apprentissage des caractéristiques.   |
| Machine à vecteurs de support<br>(Support Vector Machine)                               | <b>SVM</b><br>- Détection des visages.<br>- Classification.<br>- Bio-informatique.<br>- Reconnaissance de l'écriture manuscrite.   |

Pour choisir le modèle le plus adapté à une application définie, il faut prendre en compte différents paramètres, parmi lesquels nous citons :

- La fonction désirée (classification, prédiction, diagnostic ou reconnaissance),
- La nature des données à traiter. Ces données peuvent être de nature dynamique, statique ou aléatoire et peuvent avoir différentes formes,
- Ressources matérielles et/ou logicielles disponibles pour l'implémentation du réseau,
- Contraintes temporelles généralement liées à des applications temps réel,
- Les efforts de préparation de la base d'apprentissage ainsi que de la base de tests et validation en cas de besoin,
- Délais d'apprentissage correspondant au temps nécessaire avant de considérer le réseau comme expert et commencer la décision.

## 5 Fonctionnement d'un réseau

Les réseaux neuronaux artificiels (ANN) sont constitués de différentes couches de neurones artificiels, comprenant une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Chaque neurone artificiel, connecté à un autre, est associé à un poids et à un seuil. Si la sortie d'un neurone est supérieure à la valeur seuil spécifiée, ce nœud est alors activé et envoie des données à la couche suivante du réseau. Dans le cas inverse, aucune donnée n'est transmise à la couche suivante du réseau.

Comme mentionné précédemment, un neurone est l'unité de calcul de base d'un réseau neuronal. Son rôle est de renvoyer des informations de sortie à partir de plusieurs informations d'entrée. Les informations entrantes peuvent, par exemple, provenir des informations sortantes d'autres neurones dans le cadre d'un réseau. Plus précisément, nous désignons par  $x_1, \dots, x_n \in \mathbb{R}$  les informations entrantes et, pour chaque  $i \in \{1, 2, \dots, n\}$ , nous attribuons un poids  $w_i \in \mathbb{R}$  à  $x_i$ . Nous introduisons également un poids  $b_0 \in \mathbb{R}$ , appelé coefficient de biais.




FIGURE 3.5 – Un neurone artificiel.

Le rôle du neurone est de fournir une réponse généralement comprise entre 0 et 1 de  $y$ . Pour cette fonction, nous utilisons  $g : \mathbb{R} \rightarrow [0, 1]$ , appelée fonction d'activation (un exemple est la fonction sigmoïde). Lorsque la réponse est proche de 1, on dira que le neurone est actif et pour une réponse proche de 0, le neurone sera dit inactif. On a donc la sortie du neurone définie par l'équation (3.2) :

$$s = \sum_{i=1}^n w_i x_i + b_0 \quad (3.1)$$

$$y = g(s) = g\left(\sum_{i=1}^n w_i x_i + b_0\right) \quad (3.2)$$

avec  $g(s) = \frac{1}{1 + \exp(-s)}$ .

## 6 L'apprentissage

Il existe trois types d'apprentissage, l'apprentissage supervisé, l'apprentissage non-supervisé et l'apprentissage par renforcement.

### 6.1 L'apprentissage supervisé

L'apprentissage supervisé pour les réseaux de neurones artificiels consiste à imposer une certaine fonction au réseau en imposant les exemples utilisés pendant l'apprentissage, en ajustant les poids du réseau, où le réseau agit comme un filtre pour modifier ses poids à partir des paires d'entrée/sortie qui lui sont fournies. De sorte que la sortie du réseau soit très proche de la sortie souhaitée. Ils peuvent être la classe d'appartenance de [8] :

- La forme que l'on veut classer,
- La valeur de la fonction que l'on veut approcher,
- La sortie du processus que l'on veut modéliser,
- La sortie souhaitée du processus à commander.

### 6.2 L'apprentissage non-supervisé

Contrairement à l'apprentissage supervisée, dans l'apprentissage non-supervisé, nous avons des entrées ( $x_i$ ) sans les valeurs de sortie ( $y_i$ ), et le réseau apprend à reconnaître les structures dans les données ( $x_i$ ) qu'on lui montre au moyen de lois locales qui régissent l'évolution des poids synaptiques. Avec l'apprentissage non supervisé, nous pouvons regrouper les données en clusters, détecter les anomalies, ou même réduire la dimension des données en compilant les dimensions ensemble.

### 6.3 L'apprentissage par renforcement

La catégorie de l'apprentissage par renforcement (RL) permet à un système ou à un agent d'apprendre à partir des expériences précédentes acquises dans l'environnement par l'interaction et l'observation des résultats de ces interactions. L'interaction permet d'imiter ou de reproduire le modèle de base dans lequel les humains et les animaux apprennent. Un agent de RL peut agir, et chaque acte influence la condition future de l'agent, un signal de récompense scalaire mesure le succès de RL. Le but de RL est de choisir des actions qui maximisent le gain futur. En bref, la RL est un cadre général pour la prise de décision. Un cadre qui présente l'apprentissage d'un objectif donné à partir d'entrées brutes en appliquant une connaissance minimale du domaine. Par exemple, la RL contourne complètement le problème de l'apprentissage des règles dans une tâche. L'agent d'apprentissage apprend en participant à l'activité donnée.

Le jeu d'échecs est un exemple. Pour déterminer le meilleur coup à jouer, les joueurs doivent réfléchir à diverses possibilités et stratégies. La quantité de possibilités est potentiellement grande qu'il n'est pas possible d'effectuer une recherche par force brute. Cependant, si une machine doit être construite pour jouer à un tel jeu en utilisant des techniques traditionnelles, il sera nécessaire de spécifier de nombreuses règles pour couvrir toutes ces possibilités. L'apprentissage par renforcement permet de contourner complètement ce problème. Parmi les exemples d'apprentissage par renforcement, citons l'apprentissage profond basé sur les valeurs, l'apprentissage profond basé sur les modèles et l'apprentissage profond [1].

### 6.4 Règles d'apprentissage

Plusieurs règles d'apprentissage ont été mises en œuvre ; à savoir : la règle de Hebb, la règle d'apprentissage du Perceptron, la règle de Widrow-Hoff ou la règle Delta ou la règle LMS (Least Mean Square), la rétro-propagation du gradient ou la règle Delta généralisée. Le premier algorithme qui a résolu le problème d'apprentissage des PMC est celui de rétro-propagation du gradient, publié par Rumelhart et al. en 1986. La découverte d'une méthode générale d'apprentissage supervisé des PMC a joué un rôle majeur dans leur reconnaissance comme outil de résolution de nombreux problèmes [9].

Les modèles de type, sigmoïdaux, ReLU, LeakyReLU, linéaires, softmax sont bien adaptés aux algorithmes d'apprentissage impliquant une rétro-propagation du gradient car leur fonction d'activation est différentiable ; ce sont les plus utilisés.

Dans les paragraphes suivants, nous étudions l'entraînement des réseaux de neurones que nous utiliserons pour construire le modèle prédictif basé sur l'algorithme de rétro-



propagation.

### a-Règle d'apprentissage du perceptron :

Considérons le perceptron figure (3.3), la sortie est donnée par :

$$y = \varphi\left(\sum_{i=0}^n w_i x_i\right) \quad (3.3)$$

La somme est définie par :

$$s(x_i, w_i) = \sum_{i=0}^n w_i x_i \quad (3.4)$$

En combinant les équations (3.3) et (3.4), nous obtenons :

$$y_i = \varphi\left(\sum_{i=0}^n w_i x_i\right) = \varphi(s(x_i, w_i)) \quad (3.5)$$

L'erreur de sortie que l'on souhaite minimiser est donnée par :

$$E = \frac{1}{2}(y_d - y_i)^2 \quad (3.6)$$

Où :

$E$  : est l'erreur de sortie,

$y_i$  : est la sortie désiré,

$y_p$  : est la sortie du réseau.

L'algorithme de descente de gradient utilisé pour entrainer le réseau est donné par :

$$\Delta w_i = -\eta \frac{dE}{dw_i} \quad (3.7)$$

avec :

$\eta$  : est le taux d'apprentissage (Learning rate), varie entre 0 et 1. dérivons l'erreur :

$$\frac{dE}{dw_i} = \frac{1}{2} \frac{d(y_d - y_i)^2}{dw_i} \quad (3.8)$$

$$\frac{dE}{dw_i} = -(y_d - y_i) \frac{dy_i}{dw_i} \quad (3.9)$$

$$\begin{aligned}
 \frac{dy_i}{dw_i} &= \frac{d\varphi(s_i)}{dw_i} \\
 &= \frac{d\varphi(s_i)}{ds_i} \frac{ds_i}{dw_i} \\
 &= x_i \frac{d\varphi(s_i)}{ds_i}
 \end{aligned}
 \tag{3.10}$$

Finalement la dérivée de l'erreur devient :

$$\frac{dE}{dw_i} = -x_i(y_d - y_i) \frac{d\varphi(s_i)}{ds_i}
 \tag{3.11}$$

En combinant les équations (3.7) et (3.11), La formule de mise à jour des poids devient :

$$\Delta w_i = -\eta \frac{dE}{dw_i} = \eta x_i(y_d - y_i) \frac{d\varphi(s_i)}{ds_i}
 \tag{3.12}$$

### b- Règles d'apprentissage de neurones multicouches :

Les neurones sont liés entre eux par des connexions pondérées, qui régissent le fonctionnement du réseau en appliquant un algorithme d'apprentissage de l'espace d'entrée à l'espace de sortie à l'aide d'une transformation non linéaire. L'apprentissage peut se faire, par l'algorithme dit de rétro-propagation. L'algorithme de rétro-propagation permet de préféré entre les poids nouveaux et précédents. Il montre également l'effet de l'augmentation ou de la diminution des poids sur l'erreur de prédiction. Lors de l'entraînement d'un réseau neuronal, il y a deux voies à suivre (figure 3.6) : en avant (forward) et en arrière (backward).

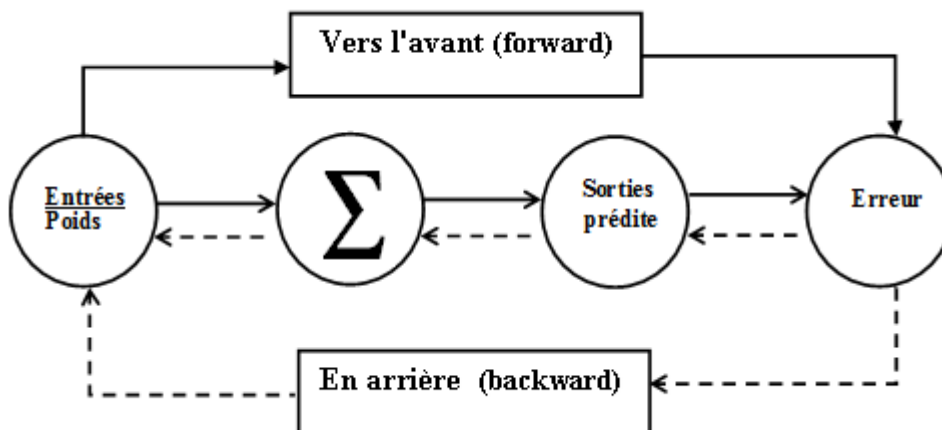


FIGURE 3.6 – Un Organigramme d'Apprentissage.

Soit le couple  $(x_i, y_i)$  désignant la  $n^{\text{ème}}$  donnée d'entraînement du réseau où :

$$x_i = [x_i, \dots, x_p] \text{ } p \text{ entrées}$$

$$d_i = [d_1, \dots, d_q] \text{ } q \text{ sorties désirées}$$

L'algorithme de rétro-propagation consiste à mesurer l'erreur entre les sorties désirées  $d_i$  et les sorties obtenues par le modèle  $y_i$  et à rétro-propager cette erreur à travers les couches des réseaux en allant des sorties vers les entrées :

$$y_i = [y_1, \dots, y_q] \quad (3.13)$$

- **Cas d'une couche cachée de sortie** : L'algorithme de rétro-propagation procède à l'adaptation des poids neurone par neurone en commençant par la couche de sortie (figure 3.7). Soit l'erreur observée  $e_j$  pour le neurone de sortie  $j$  :

$$e_j = d_j - y_j \quad (3.14)$$

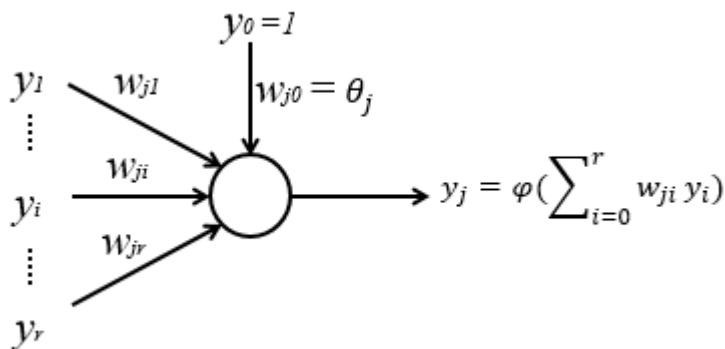


FIGURE 3.7 – Un Neurone artificiel.

Soit  $E$  La somme des erreurs quadratiques sur l'ensemble  $C$  des neurones de sortie :

$$E = \frac{1}{2} \sum_{j \in C} e_j^2 \quad (3.15)$$

La sortie  $y_i$  du neurone  $j$  est définie par :

$$\begin{aligned} y_i &= \varphi [s_j] \\ &= \varphi \left[ \sum_{i=0}^r w_{ij} x_j \right] \end{aligned} \quad (3.16)$$

Où  $\varphi [.]$  est la fonction d'activation du neurone,  $s_j$  est la somme pondérée des entrées du neurone  $j$  .

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial e_j} \frac{\partial e_j}{\partial y_j} \frac{\partial y_i}{\partial s_j} \frac{\partial s_j}{\partial w_{ji}} \quad (3.17)$$

et on exprime la variation de poids sous la forme suivante :

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} \text{ avec } 0 \leq \eta \leq 1 \quad (3.18)$$

$$\begin{aligned} \frac{\partial E}{\partial e_j} &= \frac{\partial [(1/2) \sum_{k \in C} e_k^2]}{\partial e_j} \\ &= \frac{1}{2} \frac{\partial e_j^2}{\partial e_j} \end{aligned} \quad (3.19)$$

$$\begin{aligned} \frac{\partial e_j}{\partial y_j} &= \frac{\partial (y_j - \widehat{y}_j)}{\partial y_j} \\ &= -1 \end{aligned} \quad (3.20)$$

$$\begin{aligned} \frac{\partial y_i}{\partial s_j} &= \frac{\partial (1/1 + e^{-s_j})}{\partial s_j} \\ &= y_i [1 - y_i] \end{aligned} \quad (3.21)$$

Et finalement :

$$\begin{aligned} \frac{\partial s_j}{\partial w_{ij}} &= \frac{\partial (\sum_{i=0}^r w_{ji} y_i)}{\partial w_{ji}} \\ &= y_i \end{aligned} \quad (3.22)$$

Nous obtenons donc :

$$\frac{\partial E}{\partial w_{ji}} = -e_j y_j (1 - y_i) y_i \quad (3.23)$$

et la règle du "delta" pour la couche de sortie s'exprime par :

$$\begin{aligned} \Delta w_{ji} &= -\eta \frac{\partial E}{\partial w_{ji}} \\ &= -\eta \delta_j y_i \end{aligned} \quad (3.24)$$

Avec :  $\delta_j = e_j y_j (1 - y_j)$ , qui correspond à ce qu'on appelle le "gradient local".

Jusqu'ici, nous avons traité seulement le cas de la couche de sortie ! Il reste maintenant à faire l'adaptation des poids sur les couches cachées.

- **Cas d'une couche cachée** : Considérons maintenant le cas des neurones sur la dernière couche cachée (le cas des autres couches cachées est semblable).

- La variable  $n$  désignera toujours la donnée d'entraînement c'est-à-dire un couple de vecteurs d'entrées et de sorties désirées.
- L'objectif sera toujours d'adapter les poids de la couche courante en minimisant la somme des erreurs sur les neurones de la couche de sortie.
- Les indices  $i$  et  $j$  désigneront respectivement (comme précédemment) un neurone sur la couche précédente et un neurone sur la couche courante.
- L'indice  $k$  servira maintenant à désigner un neurone sur la couche suivante.

Reprenons l'expression de la dérivée partielle de l'erreur totale  $E$  par rapport à  $w_{ij}$  mais en ne dérivant plus par rapport à l'erreur  $e_j$  car celle-ci est maintenant inconnue :

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial s_j} \frac{\partial s_j}{\partial w_{ij}} \quad (3.25)$$

Par rapport aux résultats obtenus pour la couche de sortie, les deux derniers termes de cette équation restent inchangés, seul le premier terme requiert d'être évalué :

$$\frac{\partial E}{\partial y_j} = \frac{\partial(\frac{1}{2} \sum_{k \in C} e_k^2)}{\partial y_j} \quad (3.26)$$

Notre problème ici, contrairement au cas des neurones de la couche de sortie, est que tous les dans la somme ci-dessus dépendent de  $y_j$ , nous pouvons écrire :

$$\begin{aligned} \frac{\partial E}{\partial y_j} &= \sum_{k \in C} e_k \frac{\partial e_k}{\partial y_j} \\ &= \sum_{k \in C} e_k \frac{\partial e_k}{\partial s_k} \frac{\partial s_k}{\partial y_j} \\ &= \sum_{k \in C} \left( e_k \frac{\partial (y_k - \varphi(s_k))}{\partial s_k} \frac{\partial (\sum_l w_{lk} y_l)}{\partial x} \right) \\ &= \sum_{k \in C} e_k (-y_k (1 - y_k)) w_{kj} \end{aligned} \quad (3.27)$$

Et en substituant l'équation (3.10) on obtient :

$$\frac{\partial E}{\partial y_j} = - \sum_{k \in C} (\delta_k w_{kj}) \quad (3.28)$$

En substituant l'équation (3.28) dans l'équation (3.27), on obtient :

$$\frac{\partial E}{\partial w_{ij}} = -y(1 - y_j) \left( \sum_{k \in C} \delta_k w_{kj} \right) y_i \quad (3.29)$$

Et :

$$\begin{aligned}\Delta w_{ji} &= -\eta \frac{\partial E}{\partial w_{ji}} \\ &= \eta \delta_j y_i\end{aligned}\tag{3.30}$$

Avec :

$$\delta_j = y_j(1 - y_j) \sum_{k \in C} \delta_k w_{kj}\tag{3.31}$$

Les équations (3.30) et (3.31) sont valables pour toutes les couches cachées. Dans le cas de la première couche cachée de réseaux, puisqu'il n'y a pas de couche précédente de neurones, il faut substituer la variable  $y_i$  par l'entrée  $x_i$ .

## 7 Configuration optimale du réseau neuronal

La recherche d'une configuration optimale du réseau est l'un des problèmes les plus importants de la conception d'un réseau neuronal artificiel. Les paramètres suivants du réseau neuronal doivent être sélectionnés [4] :

- le nombre de couches cachées ;
- le nombre de neurones dans chaque couche cachée ;
- le type de fonction d'activation, qui peut varier au sein d'une même couche.

A cause du manque d'information sur les paramètres représentés dans la couche cachée, les chercheurs considèrent ces paramètres comme un modèle "boîte noire". Il est donc nécessaire de choisir ces paramètres avec soin pour éviter le sur-apprentissage et le sous-apprentissage [10-12] .

Il est inutile de disposer d'un simple réseau neuronal artificiel pour faire l'approximation des fonctions, car de nombreux algorithmes peuvent effectuer la mémorisation d'un ensemble de données de manière plus efficace.

En général, les RNA doivent être capables de généraliser avec précision à de nouvelles données. La généralisation peut être définie comme la capacité d'un réseau à faire des réponses à des entrées qu'il n'a jamais vues auparavant et de faire une réponse raisonnable [13] .

## 8 Avantage des réseaux neuronaux

Les réseaux de neurones artificiels présentent plusieurs avantages qui les qualifient pour être utilisés dans la résolution de nombreux problèmes complexes. Parmi ces caractéristiques, citons les suivantes :

- 1) Les modèles de réseaux neuronaux nécessitent moins de formation statistique formelle pour être développés.
- 2) Les modèles de réseaux neuronaux peuvent détecter implicitement des relations non linéaires complexes entre les variables indépendantes et dépendantes.
- 3) Les modèles de réseaux neuronaux ont la capacité de détecter toutes les interactions possibles entre les variables prédictives.
- 4) Les réseaux neuronaux peuvent être développés à l'aide de plusieurs algorithmes de formation différents.
- 5) Capacité à généraliser, avec une conception soignée, un RNA peut être formé pour donner la bonne réponse à des données qu'il n'a pas préalablement rencontrées [14] .
- 6) Efficacité de calcul : la formation d'un RNA pour un calcul intensif peuvent être modeste [14] , mais les exigences de calcul d'un RNA entièrement formés peuvent être amélioré pour des problèmes plus importants, grâce à un traitement parallèle [15] .

## Références du Chapitre 3

- [1] Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., & Arshad, H. (2018). State-of-the-art in artificial neural network applications : A survey. *Heliyon*, 4(11), e00938.
- [2] Touzet, C. (1992). Les réseaux de neurones artificiels, introduction au connexionnisme. Ec2.
- [3] Zupan, J., & Gasteiger, J. (1993). Neural networks for chemists ; an introduction. VCH publishers.
- [4] Djeddou, M. (2014). Préviation du taux d'échec avec les réseaux neurones artificiels dans une station de traitement des eaux résiduaires (Thèse de doctorat, Université Mohamed Khider Biskra).
- [5] Burton M. (2006), "Neural Networks, Course Notes", Rhodes University, RAS, 64 pages.
- [6] Rustum, R. (2009). Modelling activated sludge wastewater treatment plants using artificial intelligence techniques (fuzzy logic and neural networks) (Thèse de doctorat, Heriot-Watt University).
- [7] Demuth H., Beale M., Hagan M. (2013). Neural Network Toolbox for Use with MATLAB, Users Guid, R2013, 430 pages.
- [8] Hertz, J., Krogh, A., & Palmer, R. G. (2018). Introduction to the theory of neural computation. CRC Press.
- [9] Chamekh, A. (2008). Optimisation des procédés de mise en forme par les réseaux de neurones artificiels (Thèse de doctorat, Université d'Angers).
- [10] Khan, R et Ondrůšek Č. (2000), "Peak electric load forecasting using an artificial neural network", submitted for publishing in Engineering Mechanics International Journal of Theoretical and Applied Mechanics, Technical University of Brno, Czech Republic.
- [11] Olden, J. D., & Jackson, D. A. (2002). Illuminating the "black box" : a randomization approach for understanding variable contributions in artificial neural networks. *Ecological modelling*, 154(1-2), 135-150.



[12] Hu, J. (1997). Research on hybrid black-box modeling for nonlinear systems and its applications. PhD thesis, Kyushu Institute of Technology.

[13] Park. M. H. (1996), "Neural Network Control of a Chlorine Basin", University of California, USA, 20-52.

[14] Tarassenko, L. (1998). Guide to neural computing applications. Elsevier.

[15] Haykin S. (2004), Neural Networks A Comprehensive Foundation, Second Edition, Pearson Education, Inc., India.

# Chapitre 4

## Résultats et discussion

### Objectifs

Dans ce chapitre, les résultats de la modélisation prédictive du premier paramètre de la résistance au choc thermique ( $R \cong \Delta T_c$ ) à l'aide de méthodes d'intelligence artificielle sont présentés. L'efficacité des modèles prédictifs ont été évalués en utilisant la base de données expérimentale.

### Sommaire

|       |   |     |
|-------|---|-----|
| 1     | Introduction . . . . .  | 80  |
| 1     | Base de données . . . . .   | 82  |
| 1.1   | La densité . . . . .  | 82  |
| 1.2   | Le module de Young . . . . .  | 82  |
| 1.3   | La contrainte à la rupture . . . . .                                | 83  |
| 1.4   | La ténacité . . . . .   | 83  |
| 2     | Modélisation des paramètres mécaniques . . . . .                    | 84  |
| 2.1   | Méthodes utilisées . . . . .  | 84  |
| 2.1.1 | Régression linéaire multiple . . . . .                              | 84  |
| 2.1.2 | Réseau de neurones à fonction de base radiale (RBFNN) . . . . .     | 84  |
| 2.2   | Résultats et discussion . . . . .                                   | 85  |
| 2.2.1 | Résultats de la régression . . . . .                                | 85  |
| 2.2.2 | Résultats RBFNN . . . . .   | 88  |
| 2.2.3 | Comparaison des Résultats Prédits et Expérimentaux . . . . .        | 91  |
| 2.2.4 | Conclusions . . . . .   | 93  |
| 3     | Modélisation du paramètre de résistance au choc thermique . . . . . | 94  |
| 3.1   | Méthodes utilisées . . . . .  | 94  |
| 3.1.1 | Théorie de l'entropie de Shannon . . . . .                          | 96  |
| 3.1.2 | Réseau neuronal à régression généralisée (GRNN) . . . . .           | 97  |
| 3.1.3 | Machines d'apprentissage extrême (ELM) . . . . .                    | 99  |
| 3.2   | Évaluation des performances . . . . .                               | 100 |
| 3.3   | Résultats et discussions . . . . .                                  | 100 |
| 3.3.1 | Modèle M1 (6 entrées) . . . . .                                     | 102 |

---

|       |                                 |     |
|-------|---------------------------------|-----|
| 3.3.2 | Modèle M2 (4 entrées) . . . . . | 104 |
| 3.4   | Conclusion . . . . .            | 110 |

---

## 1 Introduction

Pour obtenir un modèle mathématique proche de la réalité pour les paramètres mécaniques et thermiques des matériaux fragiles et notamment des matériaux céramiques, il est nécessaire de prendre en compte la diversité de tous les paramètres influents. La modélisation de tels paramètres, à partir de travaux expérimentaux, serait très coûteuse et prendrait beaucoup de temps. De plus, les résultats ne permettent pas de construire des modèles bien définis, mais donnent plutôt des tendances générales pour la variation des paramètres mécaniques et thermiques en fonction des propriétés physiques et des paramètres de construction.

Plusieurs études ont été menées [1-5], parmi lesquelles des modèles prédictifs des propriétés thermomécaniques des matériaux céramiques ont été proposés sur la base de données expérimentale. Cependant, les matériaux céramiques contiennent de nombreuses variables qui se chevauchent, telles que les méthodes de préparation des échantillons, les propriétés physiques, la nature des fissures dans les échantillons, etc.

Il est donc difficile de prédire leurs paramètres thermomécaniques à l'aide de modèles mathématiques analytiques traditionnels. Ceci est dû au chevauchement des propriétés physiques et à leur multiplicité dans l'influence de ces paramètres.

Pour clarifier ce qui précède, il ressort clairement des courbes de la figure 4.1 (a-d) que l'évolution des paramètres mécaniques et thermiques en fonction des propriétés physiques (densité, taille des grains) n'exprime pas un modèle mathématique clair, mais met plutôt en évidence la direction de l'évolution uniquement. Il s'agit de l'effet de ces propriétés sur l'augmentation ou la diminution des paramètres.

Il devient très nécessaire de développer des modèles non conventionnels qui permettent de prendre en compte tous les paramètres impliqués dans le processus de construction de ces modèles prédictifs. Dans ce contexte, les techniques d'analyse statistique et les réseaux de neurones artificiels peuvent apporter une solution au problème de la prédiction des propriétés mécaniques et thermiques des matériaux céramiques.

Dans ce chapitre, nous nous intéressons à la modélisation prédictive des paramètres mécaniques et du paramètre de résistance aux chocs thermiques. Quant aux modèles prédictifs des paramètres mécaniques, ils ont été construits à l'aide de réseaux de neurones artificiels et de modèles de régression linéaire multiple, tandis que le modèle prédictif du paramètre de choc thermique a été construit à l'aide de différentes méthodes de réseaux de neurones artificiels. Les modèles ont été créés en utilisant des paramètres physiques et des

paramètres de conception comme entrées (Fig. 4.2). L'efficacité des modèles développés a été testée à l'aide de critères d'efficacité statistique, et les résultats des modèles prédictifs obtenus ont été comparés aux résultats expérimentaux.

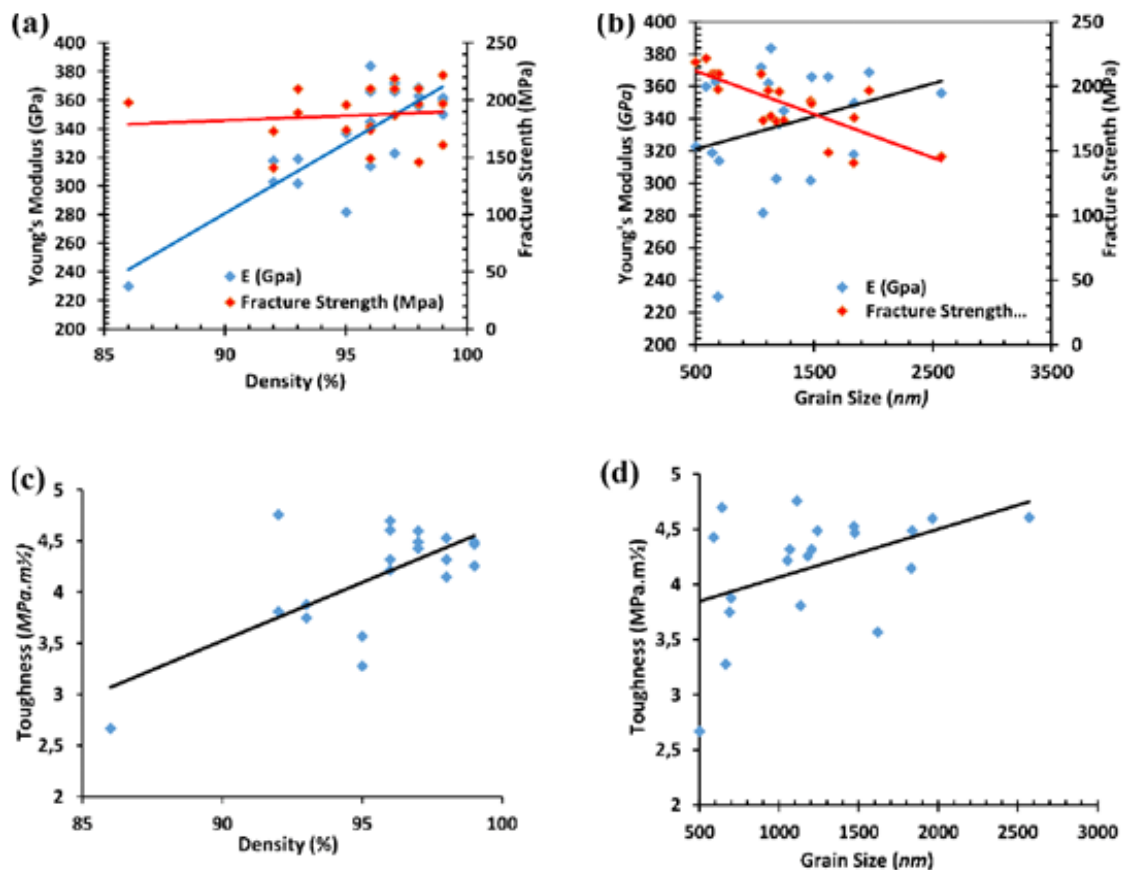


FIGURE 4.1 – Variation des paramètres mécaniques en fonction des propriétés physiques (densité et granulométrie)

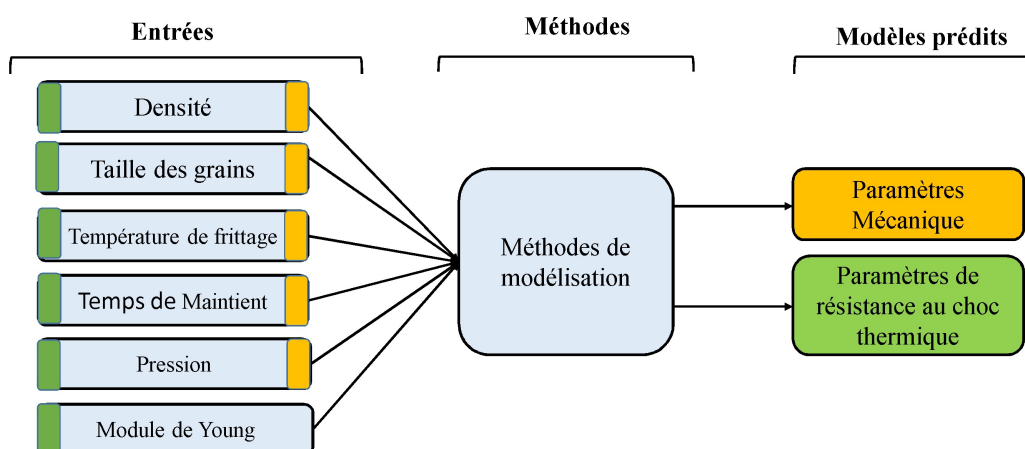


FIGURE 4.2 – Schéma illustratif des entrées et sorties utilisées pour construire les modèles

## 1 Base de données

La température de frittage ( $T$ ), la pression de frittage ( $P$ ), le temps de maintien ( $t$ ), la densité relative ( $D$ ), la taille des grains ( $Gs$ ) et le module de Young ( $E$ ) ont été utilisés comme paramètres d'entrée pour déterminer le paramètre de résistance au choc thermique ( $\Delta T_c$ ) de l'alumine frittée par le processus SPS. Quant aux paramètres mécaniques (module de Young ( $E$ ), contrainte à la rupture ( $\sigma_R$ ) et la ténacité ( $K_{1c}$ ), les entrées précédemment citées ont été utilisées à l'exception du module d'Young.

### 1.1 La densité

La densité apparente des échantillons frittés a été déterminée selon le principe d'Archimède par immersion dans l'eau distillée. Elle est calculée selon l'équation (4.1).

$$d_h = \frac{m}{m_{ima} - m_{ime}} d_{eau} \quad (4.1)$$

Où :

$m$  : la masse de l'échantillon non imprégné dans l'air,

$m_{ima}$  : la masse de l'échantillon imprégné dans l'air,

$m_{ime}$  : la masse de l'échantillon imprégné dans l'eau,

$d_{eau}$  : la densité de l'eau distillée utilisée lors de la mesure.

### 1.2 Le module de Young

Le module d'Young, a été mesuré par une méthode dynamique et non destructive, à partir de la fréquence de vibration transversale (figure 4.3) d'un échantillon, selon l'équation (4.2) (Grindo-Sonic) [6].



FIGURE 4.3 – Mesure du module de Young (méthode dynamique).

$$E = 0.94642 \times 10^{-9} \left(\frac{m}{B}\right) \left(\frac{L}{W}\right)^3 f^2 T(v) \quad (4.2)$$

Où  $m$  est la masse,  $W$ ,  $B$ , et  $L$  sont respectivement la hauteur, la largeur et la longueur de l'éprouvette,  $f$  la fréquence de résonance,  $T(v)$  facteur de correction.

### 1.3 La contrainte à la rupture

L'essai le plus usuel pour caractériser la résistance mécanique (contrainte à la rupture) des céramiques est l'essai de flexion (flexion 3 ou 4 points). Dans notre étude, la contrainte à la rupture a été déterminée à l'aide de l'essai de flexion 4 points (figure 4.4). Cette méthode, consiste à appliquer une charge croissante ( $P$ ) jusqu'à la rupture de l'éprouvette. La vitesse de mise en charge a été fixée à  $0,5\text{mm}/\text{min}$ . La contrainte à la rupture  $\sigma_R$  est donnée par l'expression suivante :

$$\sigma_R = \frac{3 P(L - l)}{2 b h^2} \quad (4.3)$$

Où :

$P$  : la charge appliquée (en N),

$L$  : distance entre appuis inférieur (en mm),

$l$  : distance entre appuis supérieur (en mm),

$(b, h)$  : la largeur et l'épaisseur de l'éprouvette (en mm).




FIGURE 4.4 – Montage de flexion 4 points.

### 1.4 La ténacité

La ténacité est une propriété intrinsèque du matériau. Elle caractérise l'aptitude du matériau à résister à la propagation brutale d'une fissure. La ténacité est calculée par la relation (4.4) d'Anstis [2] :

$$K_{1c} = 0.016 \left(\frac{E}{H}\right)^{1/2} \left(\frac{P}{C^{3/2}}\right) \quad (4.4)$$

$E$  : le module d'élasticité du matériau,

$P$  : charge d'indentation,



$C$  : la longueur de la fissure mesurée à partir du centre de l'empreinte.

## 2 Modélisation des paramètres mécaniques

### 2.1 Méthodes utilisées

Pour modéliser les paramètres mécaniques, nous avons utilisé la méthode de régression linéaire multiple (MLR), et le réseau neuronal à fonction de base radiale (RBFNN).

#### 2.1.1 Régression linéaire multiple

L'analyse de régression est un outil statistique largement appliqué dans plusieurs domaines de l'ingénierie pour modéliser la relation entre une variable de réponse et une ou plusieurs variables indépendantes [7]. Le modèle MLR de base d'une variable dépendante (réponse)  $Y$  sur un ensemble de  $k$  variables indépendantes (prédicteurs)  $X_1, X_2, \dots, X_k$  peut être exprimé comme suit [8] :

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + e_i \quad \text{pour } i = 1, 2, \dots, n \quad (4.5)$$

où  $y_i$  est la valeur de la variable dépendante  $Y$  pour le  $i^{\text{ème}}$  cas,  $x_{ij}$  est la valeur de la  $j^{\text{ème}}$  variable indépendante pour le  $i^{\text{ème}}$  cas,  $\beta_0$  est l'ordonnée à l'origine de la surface de régression, chaque  $\beta_j$  est la pente de la surface de régression et  $e_i$  est la composante d'erreur aléatoire pour le  $i^{\text{ème}}$  cas.

#### 2.1.2 Réseau de neurones à fonction de base radiale (RBFNN)

Les réseaux neuronaux à fonction de base radiale sont largement utilisés pour la modélisation prédictive dans divers domaines de l'ingénierie [9-12]. Comme le montre la figure 4.5, le RBFNN est illustré par une architecture à trois couches. La première est la couche d'entrée qui reçoit les entrées. La deuxième est la couche intermédiaire, appelée couche cachée, qui contient une fonction d'activation RBF non linéaire. La troisième couche est la couche de sortie qui effectue la prédiction.




FIGURE 4.5 – Modèle de structure de réseau neuronal à fonction de base radiale (RBFNN).



La formulation de la sortie d'un RBFNN est la suivante :

$$y_i(x) = \sum_{j=1}^k w_{ij} \phi(\|x - c_j\|) \quad (4.6)$$

Où :

$(x, y_i, k, c_j, w_{ij},)$  sont respectivement le vecteur d'entrée, la sortie du  $i^{\text{ème}}$  réseau, le nombre de neurones de la couche cachée, le centre du  $j^{\text{ème}}$  neurone caché, le poids de liaison du  $j^{\text{ème}}$  neurone de la couche cachée au  $i^{\text{ème}}$  neurone de la couche de sortie, et la norme euclidienne.  $\varphi$  est la fonction de base radiale utilisée dans les neurones de la couche cachée. Ce paramètre est une fonction de base radiale multidimensionnelle qui décrit la différence entre le vecteur d'entrée et le vecteur central spécifique. La fonction gaussienne est la fonction de base radiale la plus couramment utilisée, définie comme suit :

$$\phi(\|x - c_j\|) = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma_j^2}\right) \quad (4.7)$$

Où  $\sigma_j$  est la largeur du  $j^{\text{ème}}$  neurone caché, pour construire et entraîner le RBFNN les poids qui connectent les neurones cachés aux sorties, les centres et la largeur sont considérés comme des clés essentielles. La dimension et la distribution des modèles d'entrée affectent le nombre de neurones cachés. Plus la dimension diminue, plus le nombre de neurones cachés diminue [13] .

Parmi les avantages du RBFNN figure son architecture simple et compacte, ce qui signifie qu'il y a moins de paramètres à optimiser. Le RBFNN a une grande tolérance au bruit dans l'ensemble de données et une grande efficacité d'apprentissage [14-16] .

## 2.2 Résultats et discussion

### 2.2.1 Résultats de la régression

La première étape a consisté à découvrir la relation entre le module de Young ( $E$ ), la résistance à la rupture ( $\sigma_R$ ), la ténacité ( $K_{1c}$ ) et les paramètres physiques tels que la densité ( $D$ ) et la température ( $T$ ) dans certaines conditions expérimentales de pression ( $P$ ) et de temps ( $t$ ). Des modèles  $MLR$  ont été utilisés dans lesquels les paramètres physiques et de traitement ( $P, t, T$  étaient considérés comme des variables explicatives et le module de Young ( $E$ ), la résistance à la rupture ( $\sigma_R$ ) et la ténacité ( $K_{1c}$ ) étaient considérés comme des variables dépendantes.

#### a) Module de Young ( $E$ )

Les résultats du modèle de régression ont montré qu'il existe une relation statistiquement significative entre  $E$  et les variables explicatives. Les variables explicatives expliquent

84,5% des variations de  $E$  ( $R^2 = 0,845$ ), ce qui montre que la force de la relation entre  $E$  et les variables explicatives est bonne. En se référant à la valeur de  $F$  et à sa valeur significative (Tableau 4.1), nous avons conclu que le modèle était valide et qu'il y avait une corrélation entre  $E$  et les variables explicatives.

TABLE 4.1 – Résultats de l'ANOVA pour le module de Young

| Modèle | R     | $R^2$ | Variation de F | Valeur de P |
|--------|-------|-------|----------------|-------------|
|        | 0.919 | 0.845 | 15.234         | 0.000       |

Ainsi, les résultats obtenus donnent le modèle suivant montré dans l'équation (4.8) :

$$E = 21 \times 10^{-3}T - 2.06t - 154 \times 10^{-3}P + 24 \times 10^{-3}g + 9.05D - 565.59 \quad (4.8)$$

Un test de multicollinéarité a été effectué pour vérifier la relation mentionnée. Les résultats ont montré les coefficients de corrélation de Pearson entre les variables explicatives et  $E$ , où le coefficient de corrélation était positif entre  $E$ ,  $T$ ,  $t$ ,  $g$ , et  $D$ . La corrélation la plus forte était pour la densité (0,829), suivie par la taille du grain (0,682) et la température (0,610), est statistiquement significative, au niveau de signification de 0,05.

Les coefficients de corrélation avec la pression et le temps de maintien étaient faibles, 0,146 et 0,223, respectivement. Les coefficients pour le temps de maintien et la pression n'étaient pas statistiquement significatifs.

### b) Contrainte à la rupture $\sigma_R$

Selon le modèle mathématique obtenu pour la résistance à la rupture, comme indiqué dans l'équation (9), les paramètres explicatifs ont exprimé 65% des variations de ( $\sigma_R$ ) (Tableau 4. 2) ; ainsi, le modèle numérique a été considéré comme statistiquement acceptable.

$$\sigma_R = 53 \times 10^{-3}T - 177 \times 10^{-3}t - 376 \times 10^{-3}P - 37 \times 10^{-3}g + 182.641 \quad (4.9)$$

TABLE 4.2 – Résultats de l'ANOVA pour  $\sigma_R$ .

| Modèle | R     | $R^2$ | Variation de F | Valeur de P |
|--------|-------|-------|----------------|-------------|
|        | 0,807 | 0,651 | 5,230          | 0,006       |

Les coefficients de corrélation de Pearson entre les variables explicatives et la résistance à la rupture étaient statistiquement significatifs au niveau de signification de 0,05, sauf pour la pression et le temps de maintien (Tableau 4. 3).

TABLE 4.3 – Coefficients de corrélation de Pearson entre les variables explicatives et  $\sigma_R$

| Variables explicatives | Coef. de corrélation | Sig. statistique |
|------------------------|----------------------|------------------|
| Température (T)        | -0,375               | 0,052            |
| Temps (t)              | -0,144               | 0,272            |
| Pression (P)           | -0,265               | 0,129            |
| Grains (g)             | -0,768               | 0,000            |
| Densité (D)            | -0,362               | 0,059            |

### c) Ténacité ( $K_{1c}$ )

Les résultats du modèle de régression entre la ténacité ( $K_{1c}$ ) et les variables explicatives ont donné le modèle suivant Eq. (10) :

$$K_{1c} = 10^{-3}T + 6 \times 10^{-3}t + 6 \times 10^{-3}P + 4 \times 10^{-4}P - 5.840 \quad (4.10)$$

Les résultats du modèle de régression ont montré une relation modérément forte entre  $K_{1c}$  et les variables explicatives de l'ANOVA. L'analyse a montré que les variables explicatives expliquent 50,5% (Tableau 4. 4) des variations de ( $K_{1c}$ ) ( $R^2 = 50,6\%$ ).

TABLE 4.4 – Résultats de l'ANOVA pour  $K_{1c}$ .

| Modèle | R     | $R^2$ | Variation de F | Valeur de P |
|--------|-------|-------|----------------|-------------|
|        | 0,712 | 0,506 | 2,871          | 0,055       |

De plus, les coefficients de corrélation de Pearson étaient faibles entre ( $K_{1c}$ ) et les variables explicatives et qu'il n'y avait pas de signification statistique pour les variables pression et temps de maintien (Tableau 4. 5).

TABLE 4.5 – Coefficients de corrélation de Pearson entre les variables explicatives et ( $K_{1c}$ ).

| Variables explicatives | Coef. de corrélation | Sig. statistique |
|------------------------|----------------------|------------------|
| Température (T)        | 0.450                | 0.023            |
| Temps (t)              | 0.314                | 0.089            |
| Pression (P)           | 0.223                | 0.172            |
| Grains (g)             | 0.446                | 0.024            |
| Densité (D)            | 0.682                | 0.000            |

### 2.2.2 Résultats RBFNN

#### a) Module de Young ( $E$ )

Le modèle a été testé avec différentes combinaisons de neurones dans la couche cachée. Le modèle (5 – 17 – 1) a donné une meilleure valeur pour le  $MAPE$ , le  $RMSE$  et le coefficient de corrélation  $R^2$  (Tableau 4. 6).

Les données expérimentales ont été regroupées en données de formation et en données de test. Sur la base de la prédiction utilisant le modèle RBFNN, la comparaison entre les résultats prédits et les résultats expérimentaux est présentée dans les figures 4.6 et 4.7. Cette comparaison a révélé que le modèle RBFNN avait un avantage en termes de précision de prédiction et de précision de l'ajustement de prédiction (99,6%).

La figure 4.7 utilise un graphique linéaire pour montrer la comparaison directe des résultats prédits avec les résultats expérimentaux. La comparaison montre que les résultats du modèle RBF ont une grande précision de prédiction.

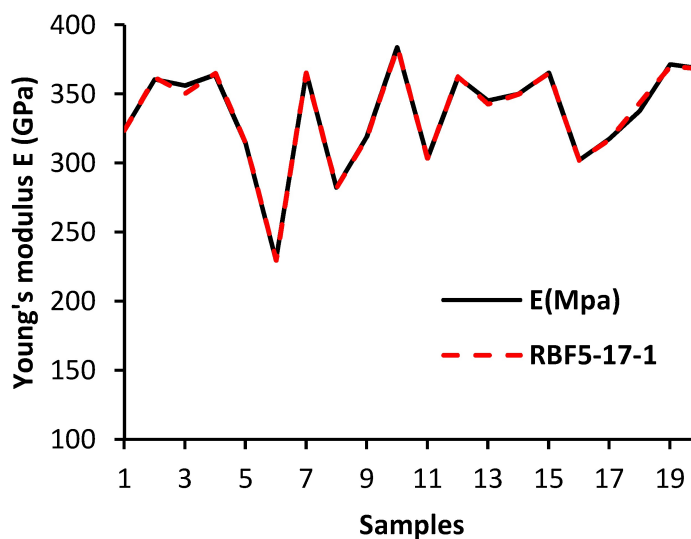


FIGURE 4.6 – Comparaison entre les résultats prédits et expérimentaux pour le module de Young.




FIGURE 4.7 – Valeurs expérimentales et prédites du module de Young avec le coefficient de corrélation.

### b) Contrainte à la rupture ( $\sigma_R$ )

La combinaison (5 – 17 – 1) a donné les meilleures valeurs pour les critères de performance  $MAPE$  (%),  $RMSE$  et ( $R^2$ ), où les résultats étaient les suivants : 1,45, 4,1454 et 0,79, respectivement. Les résultats obtenus sont présentés dans le Tableau 4. 6 et les figures 4.8 et 4.9.

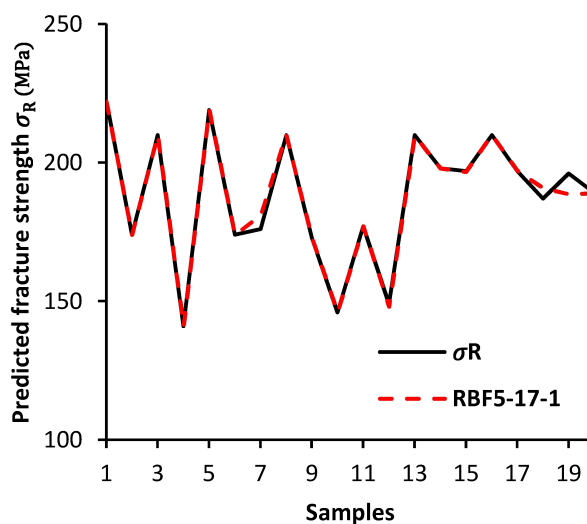


FIGURE 4.8 – Comparaison entre les résultats prédits et expérimentaux pour la résistance à la rupture.

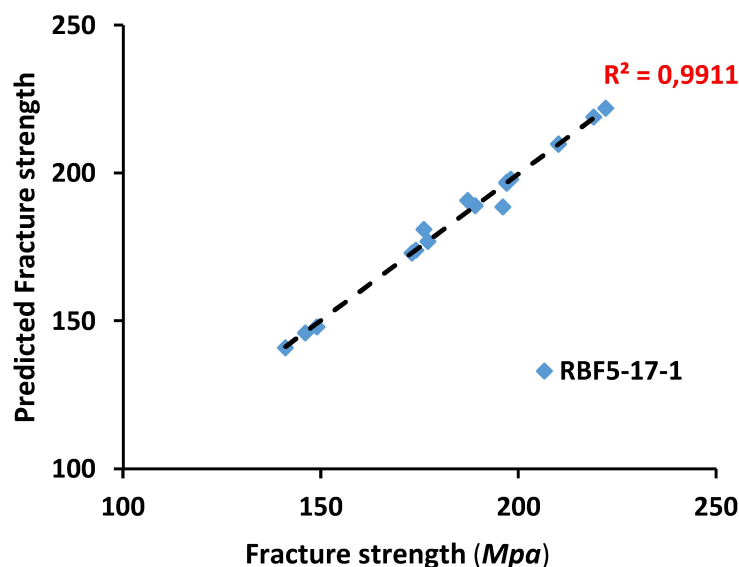


FIGURE 4.9 – Valeurs expérimentales et prédites de la résistance à la rupture avec le coefficient de corrélation.

TABLE 4.6 – Paramètres de performance

|         | Predicted YOUNG'S Modulus |       |       | Predicted Fracture Toughness |       |       | Predicted Fracture Strength |       |       |
|---------|---------------------------|-------|-------|------------------------------|-------|-------|-----------------------------|-------|-------|
|         | Train                     | Test  | ALL   | Train                        | Test  | ALL   | Train                       | Test  | ALL   |
| RMSE    | 1.609                     | 3.305 | 2.063 | 0.031                        | 0.009 | 0.028 | 1.297                       | 4.145 | 2.187 |
| MAPE(%) | 0.197                     | 0.589 | 0.276 | 0.434                        | 0.223 | 0.392 | 0.238                       | 1.451 | 0.480 |
| $R^2$   | 0.999                     | 0.988 | 0.998 | 0.999                        | 0.999 | 0.997 | 0.999                       | 0.789 | 0.998 |

### c) Ténacité ( $K1c$ )

Selon la même méthodologie utilisée précédemment pour construire le modèle approprié et les mêmes critères d'évaluation, le meilleur modèle pour prédire la ténacité consistait en une combinaison de 5 entrées, 17 neurones dans la couche cachée et une sortie (5 – 17 – 1). Ce modèle a donné un MAPE (%) de 0,2235, un  $R^2$  de 0,9995 et un RMSE de 0,0095, soit de bons résultats.

Les résultats obtenus à partir de l'étude prédictive en comparaison avec les résultats expérimentaux sont présentés à la Fig. 4.10. Les valeurs MAPE (%) et RMSE ont montré que la prédiction de la ténacité par le modèle RBF était précise (Tableau 4. 6).

La figure 4.11 montre une analyse de régression du modèle RBF spécifié.




FIGURE 4.10 – Valeurs expérimentales et prédites de la résistance à la rupture avec le coefficient de corrélation.

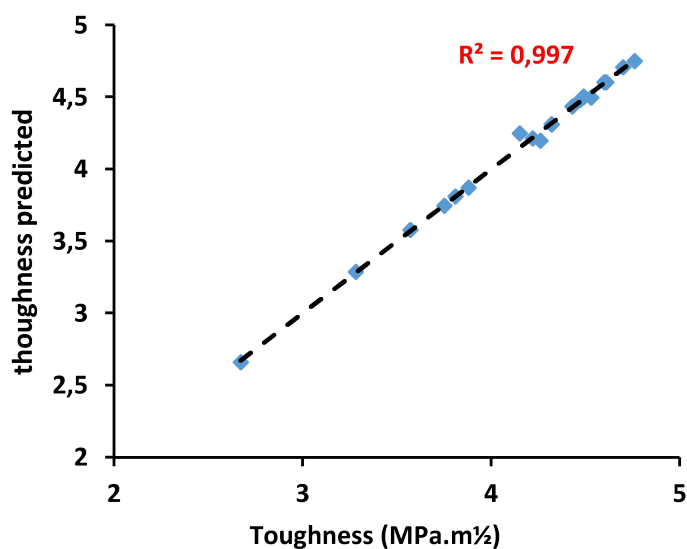


FIGURE 4.11 – Valeurs expérimentales et prédites de la résistance à la rupture avec le coefficient de corrélation.

### 2.2.3 Comparaison des Résultats Prédits et Expérimentaux

Les prédictions des modèles MLR et RBFNN ont été comparées aux résultats expérimentaux pour le module d'Young, la résistance à la rupture et la ténacité dans les figures (4.12, 4.13 et 4.14).

La figure 4.12 montre la comparaison entre les mesures expérimentales de E et les valeurs prédites par les modèles MLR et RBFNN. Les valeurs mesurées de E étaient clairement bien corrélées avec les valeurs prédites par le RBFNN et étaient acceptables par

rapport aux valeurs prédites par le modèle MLR.

Pour le modèle prédictif de la résistance à la rupture, la figure 4.13 montre que les valeurs du modèle MLR étaient divergentes par rapport aux valeurs expérimentales, tandis que les résultats du modèle RBFNN étaient presque identiques aux valeurs expérimentales.

La figure 4.14 compare graphiquement les prédictions de ténacité par les modèles MLR et RBFNN aux données expérimentales. Le modèle RBFNN est plus performant que le modèle MLR pour prédire la ténacité.

Les modèles RBFNN étaient clairement adaptés pour prédire les propriétés mécaniques des matériaux fragiles dans des plages d'erreur très acceptables.

Les modèles MLR n'ont pas fourni de prédictions acceptables. Les prédictions des modèles RBFNN proposés étaient plus proches des valeurs expérimentales des propriétés mécaniques que celles des modèles MLR.

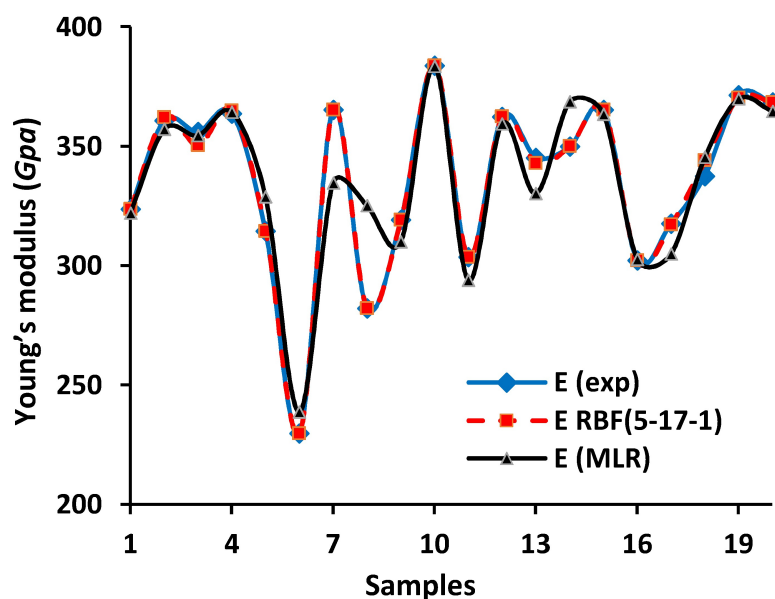


FIGURE 4.12 – Valeurs expérimentales et prédites de la résistance à la rupture avec le coefficient de corrélation.



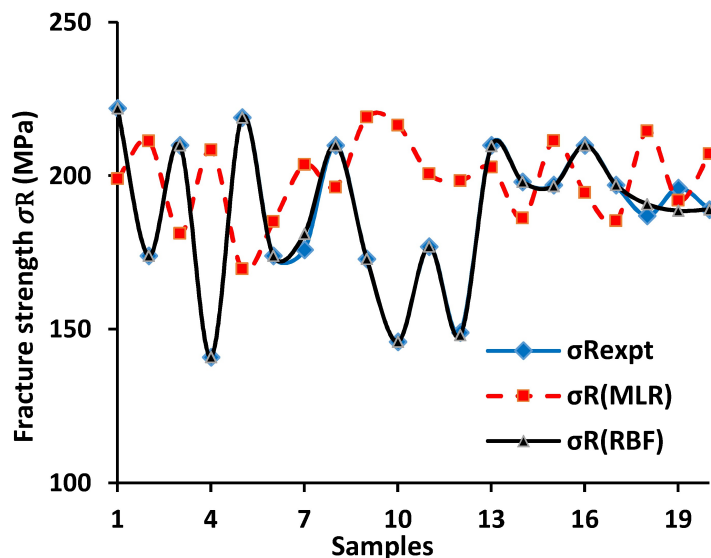


FIGURE 4.13 – Valeurs expérimentales et prédites de la résistance à la rupture avec le coefficient de corrélation.




FIGURE 4.14 – Valeurs expérimentales et prédites de la résistance à la rupture avec le coefficient de corrélation.

## 2.2.4 Conclusions

Une comparaison entre deux méthodes de prédiction, la régression linéaire multiple et les réseaux neuronaux à fonction de base radiale, a été réalisée. La comparaison était basée sur l'utilisation de critères de performance ( $R^2$ ,  $MAPE$  et  $RMSE$ ) pour prédire les propriétés mécaniques.

L'étude a abouti aux résultats suivants :

- 1 - Les résultats prédictifs des modèles MLR étaient modestes,
- 2- Les résultats prédictifs des modèles RBFNN étaient en bon accord avec les résultats expérimentaux,
- 3- L'architecture du réseau neuronal (RBFNN) qui a donné les meilleurs résultats est (5-17-1),
- 4- Il est possible de s'appuyer sur le RBFNN pour prédire les propriétés mécaniques des matériaux céramiques à partir de données expérimentales.

### 3 Modélisation du paramètre de résistance au choc thermique

Le premier paramètre de la résistance au choc thermique  $R \cong \Delta T_c$ , qui a été étudié dans le deuxième chapitre, nous trouvons dans ce qui suit les détails de la construction de modèles prédictifs en utilisant des méthodes d'intelligence artificielle et en choisissant le meilleur modèle.

#### 3.1 Méthodes utilisées

Dans la deuxième partie de ce chapitre, des modèles prédictifs pour le paramètre de résistance au choc thermique  $\Delta T_c$  sont construits. Deux modèles ont été utilisés, le premier est un modèle construit à l'aide de réseaux neuronaux artificiels simples, et le second est un modèle hybride construit à l'aide de réseaux neuronaux artificiels combinés à la méthode de l'entropie de Shannon (pour réduire les dimensions).

Dans le premier modèle (M1), les paramètres d'élaboration, physiques et mécaniques ont été exploités pour construire trois ANN, à savoir la régression linéaire généralisée (M1-GLRNN), la machine Learning extrême (M1-ELM) et le réseau de neurones à base radiale (M1-RBFNN). Le deuxième modèle (M2) a été construit par les trois modèles mentionnés ci-dessus incorporés par la méthode de l'entropie de Shannon ( $SE$ ).

Pour comparer les performances de tous les modèles développés, le coefficient de corrélation ( $R$ ), l'erreur quadratique moyenne ( $RMSE$ ), le pourcentage d'erreur absolue moyenne ( $MAPE$ ) et le coefficient d'efficacité de Nash-Sutcliffe ( $NSE$ ) ont été considérés. En outre, les résultats prédits ont été comparés aux résultats expérimentaux.

La figure 4.15 résume les entrées et les méthodes utilisées pour construire les modèles.

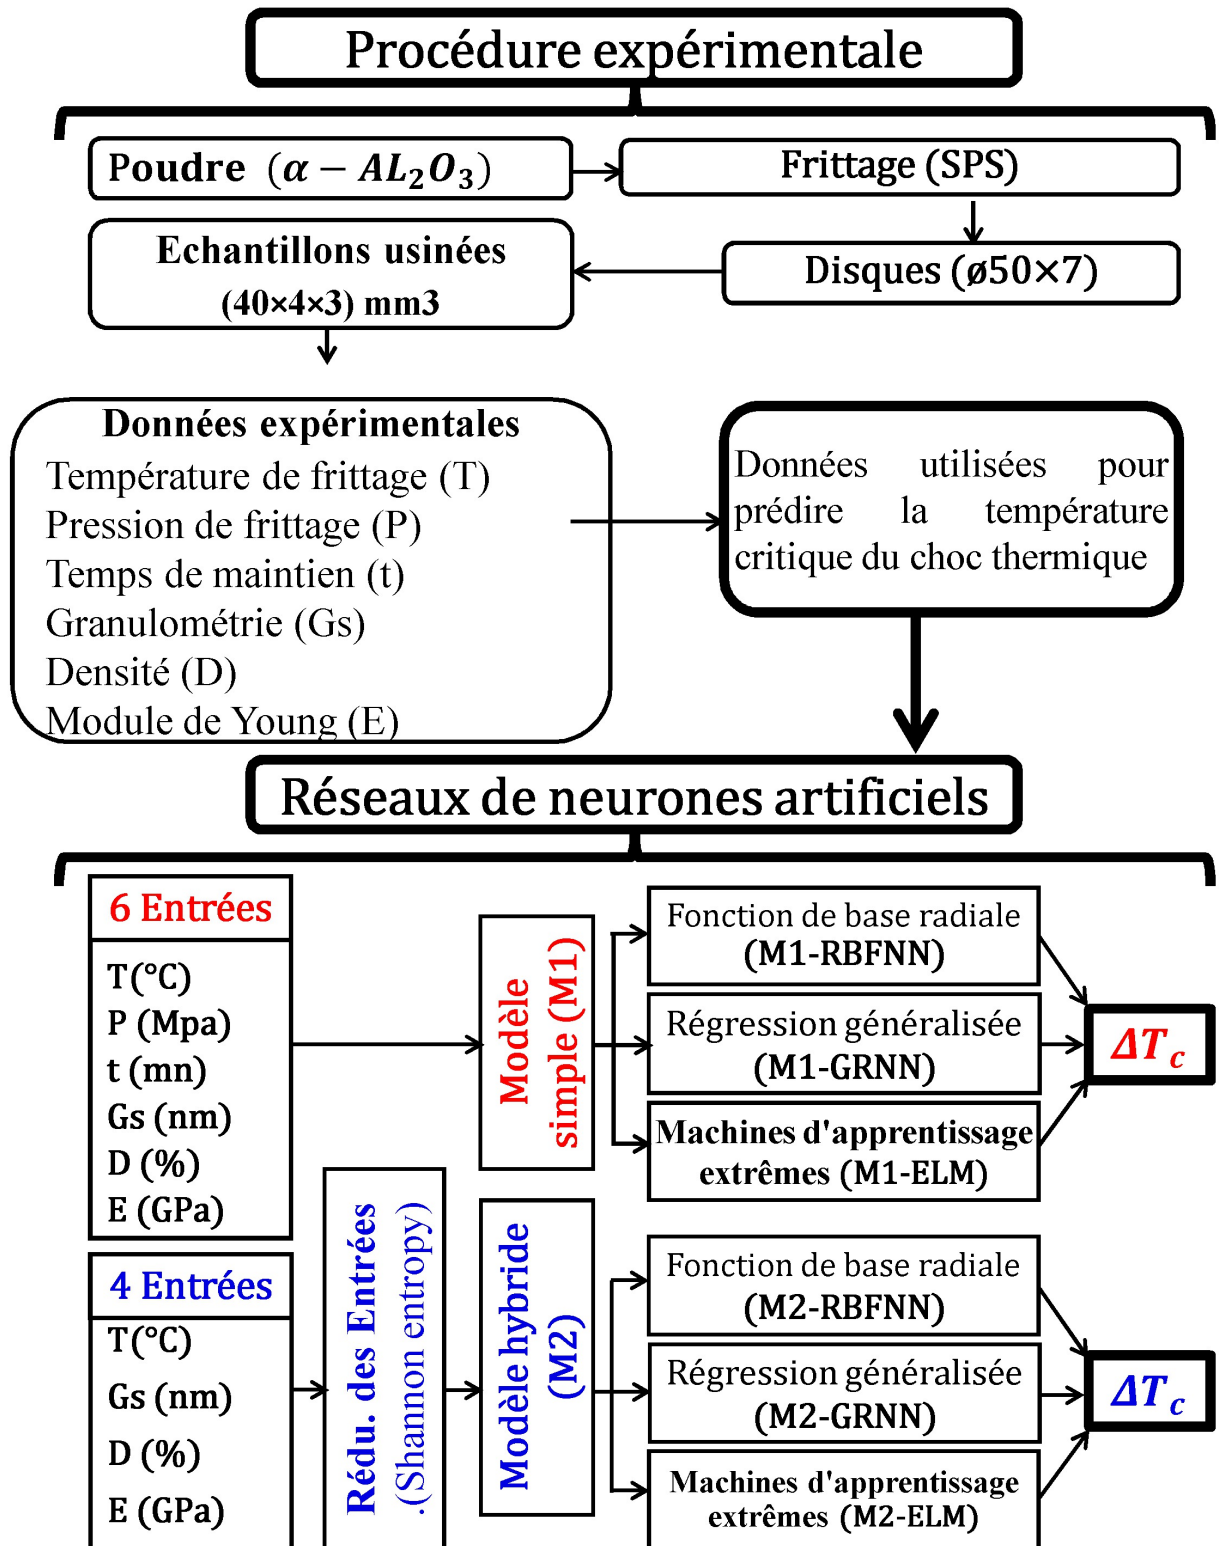


FIGURE 4.15 – Organigramme de procédure pour les analyses numériques utilisées dans la prédiction de la température critique de choc thermique de l'alumine.

### 3.1.1 Théorie de l'entropie de Shannon

**Shannon (1948)** a démontré que les événements dont la probabilité d'occurrence est élevée fournissent une information réduite [17]. Inversement, si la probabilité d'une occurrence est plus faible, l'information obtenue est plus grande. De cette façon, l'incertitude et l'information des paramètres sont liées. La théorie de l'entropie a été utilisée comme un indicateur important pour quantifier les éléments pertinents. Si un nombre ( $i = 1, 2, \dots, m$ ) d'échantillons est fourni pour l'évaluation et que chaque échantillon a  $n$  paramètres ( $1, 2, \dots, n$ ),  $x_{ij}$  est la donnée observée du  $j^{\text{ème}}$  paramètre de l'échantillon, la matrice de données  $Y$  pour les échantillons est :

$$Y = \begin{bmatrix} a_{11} & a_{12} & \vdots & a_{1n} \\ a_{21} & a_{22} & \vdots & a_{2n} \\ \dots & \dots & \ddots & \dots \\ a_{m1} & a_{m2} & \vdots & a_{mn} \end{bmatrix} \quad (4.11)$$

Comme les paramètres d'entrée ont la même dimension, les données sont généralement préparées par une normalisation *Min – Max*. Après normalisation, la matrice des données brutes sera :

$$X = \begin{bmatrix} x_{11} & x_{12} & \vdots & x_{1n} \\ x_{21} & x_{22} & \vdots & x_{2n} \\ \dots & \dots & \ddots & \dots \\ x_{m1} & x_{m2} & \vdots & x_{mn} \end{bmatrix} \quad (4.12)$$

Où  $x_{mn}$  est l'ensemble de données normalisé. La valeur de l'indice du paramètre  $j$  dans le  $i^{\text{ème}}$  échantillon est calculée comme suit :

$$P_{ij} = x_{ij} / \sum_{i=1}^m x_{ij} \quad (4.13)$$

Où  $P$  est une probabilité d'occurrence commune  $i$  et  $j$ . Par conséquent, la probabilité de  $P$  peut être nulle, et le fait de fixer ce paramètre à zéro dans les équations suivantes entraînera des problèmes mathématiques. Par conséquent, la correction de la relation précédente est nécessaire et est donnée comme suit :

$$P_{ij} = (x_{ij} + 0.0001) / \sum_{i=1}^m (x_{ij} + 0.0001) \quad (4.14)$$

Ensuite, l'information entropique peut être calculée comme suit :

$$e_{ij} = (-1/\ln(m)) / \left[ \sum_{i=1}^m (P_{ij} \ln(P_{ij})) \right] \quad (4.15)$$

Le diagramme de la Figure (4.16), présente le résumé de la théorie de l'entropie de Shannon.

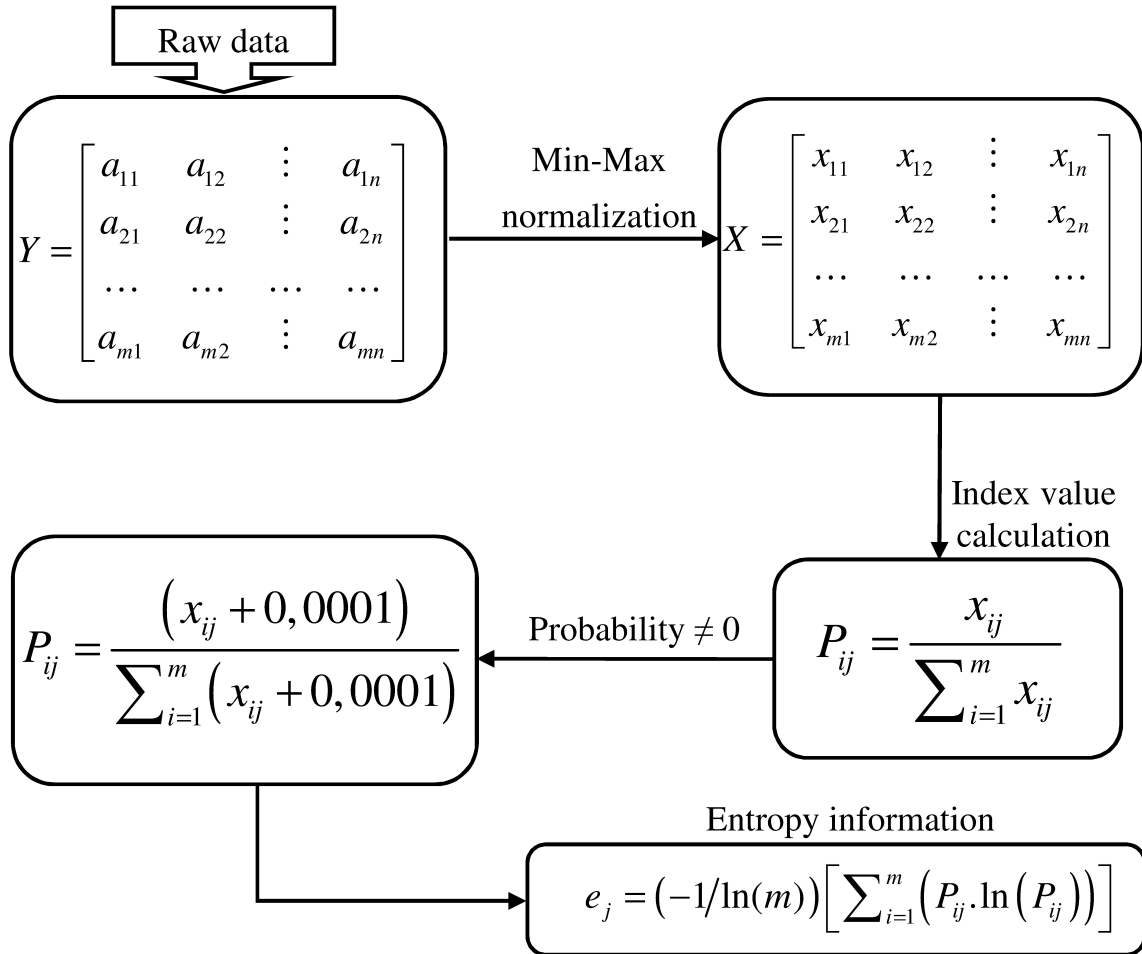


FIGURE 4.16 – Diagramme explicatif de la théorie de l'entropie de Shannon.

### 3.1.2 Réseau neuronal à régression généralisée (GRNN)

**Specht (1991)** a proposé des réseaux neuronaux à régression généralisée (GRNN). Un GRNN est une variété de réseaux neuronaux à base radiale, qui est basée sur la régression à noyau [18,19]. L'un des avantages de ce réseau est sa cohérence, l'erreur d'estimation s'approche de zéro avec seulement de légères restrictions sur la fonction lorsque la taille de l'ensemble d'apprentissage est grande. Les détails du GRNN sont donnés par Specht (1991), et un diagramme de l'architecture du GRNN est présenté à la Fig.4.17. Le GRNN n'a pas besoin d'un processus d'apprentissage itératif comme les réseaux de rétro-propagation. Il approxime toute fonction arbitraire entre les vecteurs d'entrée et de sortie, en tirant directement l'estimation de la fonction à partir des données d'apprentissage [19].

$b = H^{\text{mp}}Y$  Où,  $H^{\text{mp}}$  est l'inverse généralisé de **Moore-Penrose** de la matrice  $H$ . Plus de détails sur l'algorithme ELM peuvent être trouvés dans l'article original [22].

### 3.2 Évaluation des performances

L'erreur quadratique moyenne (RMSE), le pourcentage d'erreur absolu moyen (MAPE), le critère de Nash-Sutcliffe (NSE) et le coefficient de corrélation de Pearson ( $R$ ), qui ont été appliqués dans cette étude, sont calculés respectivement comme suit :

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\Delta T_{c_i}^{\text{Measured}} - \Delta T_{c_i}^{\text{Predicted}})^2}{N - 1}} \quad (4.22)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{(\Delta T_{c_i}^{\text{Measured}} - \Delta T_{c_i}^{\text{Predicted}})}{\Delta T_{c_i}^{\text{Measured}}} \right| \times 100 \quad (4.23)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (\Delta T_{c_i}^{\text{Measured}} - \Delta T_{c_i}^{\text{Predicted}})^2}{\sum_{i=1}^N (\Delta T_{c_i}^{\text{Measured}} - \overline{\Delta T_{c_i}^{\text{Measured}}})^2} \quad (4.24)$$

$$R = \frac{\sum_{i=1}^N (\Delta T_{c_i}^{\text{Measured}} - \overline{\Delta T_{c_i}^{\text{Measured}}})(\Delta T_{c_i}^{\text{Predicted}} - \overline{\Delta T_{c_i}^{\text{Predicted}}})}{\sqrt{\sum_{i=1}^N (\Delta T_{c_i}^{\text{Measured}} - \overline{\Delta T_{c_i}^{\text{Measured}}})^2 \sum_{i=1}^N (\Delta T_{c_i}^{\text{Predicted}} - \overline{\Delta T_{c_i}^{\text{Predicted}}})^2}} \quad (4.25)$$

### 3.3 Résultats et discussions

Deux modèles différents ont été créés pour prédire  $\Delta T_c$ , comme le montre le Tableau(4.7). Le premier modèle (M1) a été développé en utilisant les six entrées expérimentales, et pour la construction du deuxième modèle (M2), les dimensions ont été réduites et les variables d'entrée appropriées ont été choisies en utilisant la méthode de l'entropie de Shannon. Le modèle M2 a été considéré avec seulement 4 variables d'entrée avec la valeur d'entropie la plus élevée pour les modèles proposés (M2-RBFNN, M2-GRNN, et M2-ELM).

L'entropie de Shannon de chaque paramètre d'entrée a été déterminée. La valeur  $e_j$  de chaque donnée d'entrée a été déterminée selon l'équation (4.15), et présentée à la figure 4.18. Les entrées ayant une entropie plus élevée sont plus efficaces dans la modélisation que les autres entrées. Par conséquent, la combinaison des 4 entrées sélectionnées (température, granulométrie, densité et module d'Young) a été choisie pour construire les modèles de réseaux de neurones artificiels (RBFNN, GRNN et ELM).

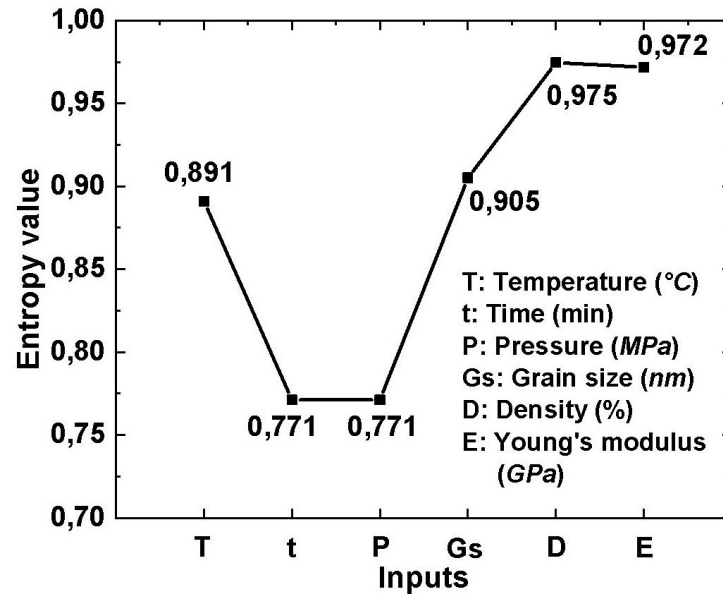


FIGURE 4.18 – Diagramme explicatif de la théorie de l'entropie de Shannon.

Il convient de noter que pour développer le meilleur modèle en concevant un type différent de *RNA*, il faut déterminer le nombre maximal de neurones cachés, la fonction de transfert appropriée, les itérations et la meilleure structure, car ils sont essentiels pour construire et concevoir de nouveaux modèles [23]. Tous les modèles sont construits sur l'environnement **Matlab 2019b**.

TABLE 4.7 – Combinaison des entrées des deux modèles développés

| Nom du modèle                    | Modèles   | Entrées   | Sortie                       |
|----------------------------------|-----------|---|------------------------------|
| <b>RBFNN, GRNN, ELM</b>          | <b>M1</b> | Température, temps, pression, taille des grains, densité et module d'Young. | Température critique de choc |
| <b>SE-RBFNN, SE-GRNN, SE-ELM</b> | <b>M2</b> | Température, temps, pression, taille des grains, densité et module d'Young. | thermique $\Delta T_c$ .     |

Les résultats obtenus des deux modèles (M1) et (M2) utilisant les modèles RBFNN, GRNN et ELM pour la prédiction de  $\Delta T_c$  sont présentés dans le Tableau (4. 8). Compte tenu des valeurs *NSE* supérieures à 0,80 dans la formation et le test, il est clair, d'après la comparaison globale, que toutes les combinaisons de modèles étudiées ont montré des performances acceptables dans l'horizon de modélisation, sauf pour les modèles ELM.

TABLE 4.8 – Résultats des performances des modèles RBFNN, GRNN et ELM.

| Modèle  | Entraînement |        |        |        | Test    |        |        |        |
|---------|--------------|--------|--------|--------|---------|--------|--------|--------|
|         | RMSE         | MAPE   | NSE    | R      | RMSE    | MAPE   | NSE    | R      |
| M1-BFNN | 5.0791       | 0.3129 | 0.9878 | 0.9939 | 2.7209  | 0.2496 | 0.9979 | 0.9989 |
| M1-GRNN | 6.6238       | 0.6213 | 0.9793 | 0.9896 | 8.1436  | 1.0029 | 0.9810 | 0.9905 |
| M1-ELM  | 30.8775      | 3.1904 | 0.5504 | 0.7419 | 73.7147 | 9.5556 | 0.5569 | 0.0927 |
| M2-BFNN | 4.3751       | 0.3133 | 0.9910 | 0.9955 | 4.2613  | 2.9955 | 0.9948 | 0.9974 |
| M2-GRNN | 31.0358      | 2.9419 | 0.5458 | 0.7388 | 23.2261 | 2.5616 | 0.8454 | 0.9195 |
| M2-ELM  | 36.8946      | 3.9150 | 0.3581 | 0.5984 | 50.5822 | 6.5242 | 0.2669 | 0.5167 |

### 3.3.1 Modèle M1 (6 entrées)

Le Tableau 4. 8 montre que M1 avec 6 variables d'entrée a généré la précision de prédiction la plus élevée pour les modèles M1-RBFNN et M1-GRNN en termes de  $RMSE$ ,  $MAPE$ ,  $NSE$  et  $R$  de prédiction pour  $\Delta T_c$ . Parmi les modèles,  $M1 - RBFNN$  avec les valeurs  $RMSE(5.0791)$ ,  $MAPE(0.3129)$ ,  $NSE(0.9878)$  et  $R(0.9939)$  dans la phase de formation, a eu le plus haut degré de précision comparé à M1-GRNN et M1-ELM. L'ajustement entre le  $\Delta T_c$  mesuré et le  $\Delta T_c$  prédit est illustré à la figure 4.19. On voit clairement que la performance globale de M1-RBFNN est supérieure à celle des combinaisons M1-GRNN et M1-ELM.




FIGURE 4.19 – Tendances des tracés  $\Delta T_c$  prédits pour le  $M1 - RBFNN$ , le  $M1 - GRNN$  et le  $M1 - ELM$  en phase de formation.

De plus, les tendances des valeurs prédites montrent de meilleurs accords avec les



valeurs mesurées que les deux autres modèles. En termes de pourcentage de précision globale, M1-RBFNN surpasse et augmente la performance prédictive de 0,86% et 79,47% pour les modèles M1-GRNN et M1-ELM, respectivement.

Dans la phase de test, le modèle M1-RBFNN surpasse M1-GRNN et M1-ELM en diminuant les erreurs  $RMSE$  (2.7209),  $MAPE$  (0.2496), et en augmentant les paramètres de performance  $NSE$  (0.9979) et  $R$  (0.9989) respectivement. La figure 4.20 représente l'ajustement entre le  $\Delta T_c$  mesuré et prédit. Les combinaisons de modèles M1-RBFNN surpassent clairement les combinaisons de modèles M1-GRNN et M1-ELM en termes de généralisation.




FIGURE 4.20 – Tendances des tracés  $\Delta T_c$  prédits pour le  $M1 - RBFNN$ , le  $M1 - GRNN$  et le  $M1 - ELM$  en phase de test.

Les  $\Delta T_c$  prédits à l'aide de M1-RBFNN sont très proches des valeurs mesurées, comme le montre la figure 4.21(a) puisque leur coefficient de détermination  $R^2$  est très proche de l'unité.

La faible performance prédictive de M1-ELM peut être attribuée au fait que la base de données utilisée est très courte, ce qui limite l'identification aléatoire des biais cachés, des poids d'entrée et peut conduire à un problème d'overfitting dans la phase de formation, et le modèle ELM nécessite une grande base de données. Malheureusement, cela conduit à des paramètres de performance médiocres dans la phase de test.

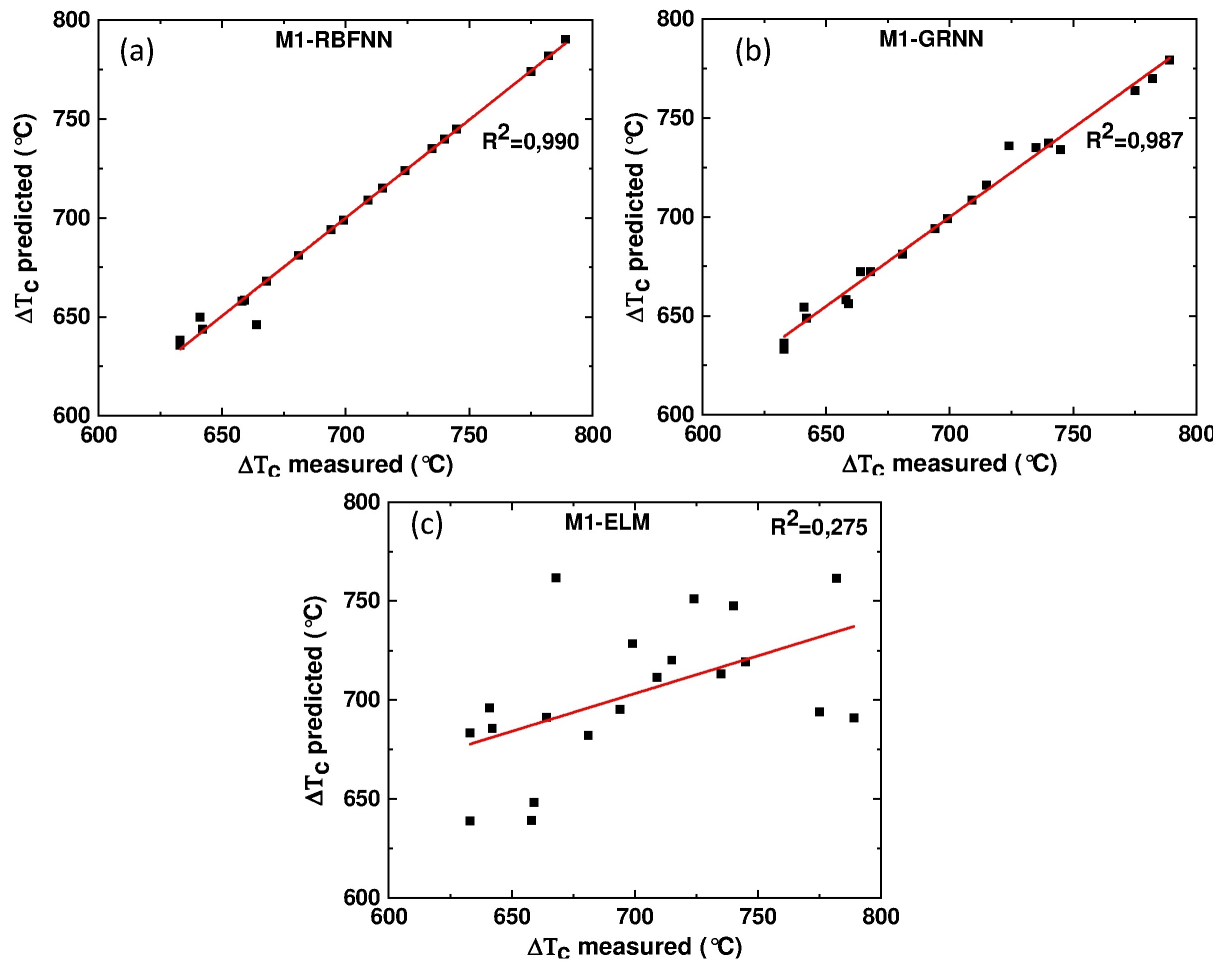


FIGURE 4.21 –  $\Delta T_c$  mesuré et  $\Delta T_c$  prédit avec : (a)  $M1 - RBFNN$ , (b)  $M1 - GRNN$ , et (c)  $M1 - ELM$ .

### 3.3.2 Modèle M2 (4 entrées)

L'utilisation de la méthode de l'entropie de Shannon ( $SE$ ) pour la réduction des caractéristiques avec quatre combinaisons d'entrées a produit les meilleurs résultats de performance dans la prédiction de  $\Delta T_c$ .

En outre, une explication des résultats a révélé que pour la prédiction des valeurs  $\Delta T_c$ , le modèle M2-RBFNN avec  $RMSE$  (4,3751),  $MAPE$  (0,3133),  $NSE$  (0,9910) et  $R$  (0,9955) dans la phase de formation, a démontré le mérite par rapport à M2-GRNN et M2-ELM et il est donc apparu comme un modèle fiable. Le modèle M1-RBFNN peut également être utilisé efficacement pour la prévision, bien qu'il soit surpassé par les modèles M2-RBFNN.

Dans le même ordre d'idées, il est assez intéressant de remarquer qu'il y a une légère augmentation de la performance de prévision de M2-RBFNN par rapport au modèle M1-

RBFNN et une augmentation d'environ 0,32% pour le modèle M1-RBFNN. Les valeurs prédites pour le meilleur modèle dans la phase de formation sont présentées dans la Fig. 4.22 et la Fig. 4.24(a).

Les résultats de la prédiction globale montrent qu'avec la diminution du nombre de variables d'entrée, la précision de la performance s'est améliorée dans la prédiction de  $\Delta T_c$ .

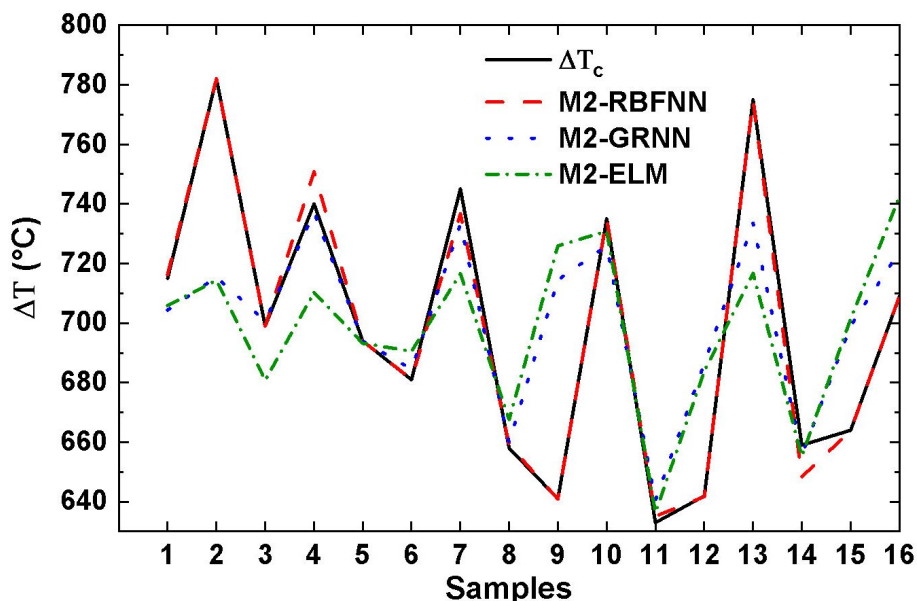


FIGURE 4.22 – Tendances des tracés  $\Delta T_c$  prédit pour le  $M2 - RBFNN$ ,  $M2 - GRNN$  et  $M2 - ELM$  en phase de formation.

De plus, les modèles de valeurs prédites montrent un meilleur accord avec les valeurs mesurées que les deux autres modèles. En pourcentage de la précision globale, M2-RBFNN surpasse et gagne en efficacité prédictive jusqu'à 15.01% et 73.17% par rapport aux modèles M2-GRNN et M2-ELM, respectivement.

L'ajustement entre le  $\Delta T_c$  mesuré et prédit est montré dans la Fig. 4.22. On peut clairement voir que les combinaisons M2-RBFNN montrent des capacités de généralisation supérieures aux combinaisons de modèles M2-GRNN et M2-ELM.

Dans la phase de test, le modèle M2-RBFNN surpasse M2-GRNN et M2-ELM par la diminution des erreurs  $RMSE$  (2.7209),  $MAPE$  (0.2496), et l'augmentation des paramètres de performance  $NSE$  (0.9979) et  $R$  (0.9989) respectivement.

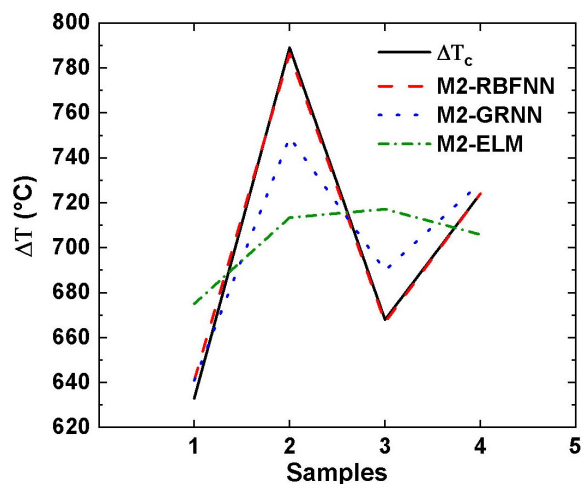


FIGURE 4.23 – Tendances des tracés  $\Delta T_c$  prédit pour le  $M2 - RBFNN$ ,  $M2 - GRNN$  et  $M2 - ELM$  en phase de formation.

D'après la Fig. 4.24(a), toutes les valeurs  $\Delta T_c$  prédites en utilisant  $M2-RBFNN$  sont assez proches de la ligne droite, avec un coefficient de détermination ( $R^2$ ) très proche de 1.

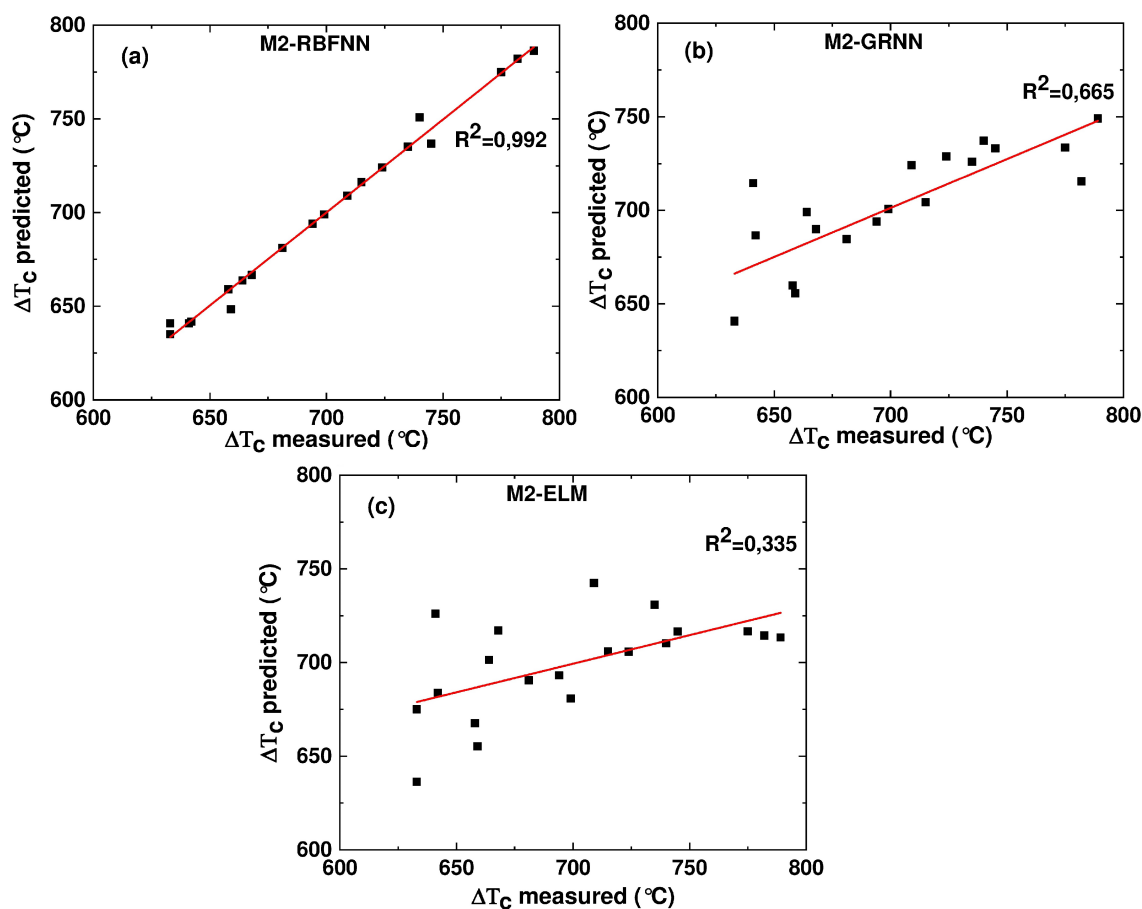


FIGURE 4.24 –  $\Delta T_c$  mesuré et prédit avec : (a)  $M2 - RBFNN$ , (b)  $M2 - GRNN$  et (c)  $M2 - ELM$ .

Selon la référence [24], qui montre que les plus petites valeurs de  $MAPE$  prouvent que la performance du modèle est élevée, l'étude montrant que tous les modèles ont été jugés efficaces selon cette échelle avec une plage de 0-5 %, sauf pour le modèle ELM. En outre, la précision de la performance dans la prédiction de  $\Delta T_c$  a augmenté lorsque le nombre de variables d'entrée a diminué.

D'après la Fig. 4.25, les erreurs maximales de la modélisation prédictive de  $\Delta T_c$  utilisant M2-RBFNN diminuent de 39,48% par rapport au modèle M1-RBFNN. Tous les critères de performance ont montré que le modèle M2-RBFNN était supérieur au M1-RBFNN et au M1-GRNN, et les résultats ont également montré que le modèle M2-RBFNN avec quatre combinaisons d'entrées était le meilleur modèle pour prédire  $\Delta T_c$ .




FIGURE 4.25 – Différences d'erreurs entre les valeurs  $\Delta T_c$  mesurées et prédites sur la base des modèles  $M2 - RBFNN$  et  $M1 - RBFNN$ .

Une approche bidimensionnelle montrant comment les modèles proposés correspondent aux valeurs mesurées et prédites correspondantes de  $\Delta T_c$  a été utilisée pour capturer les détails de performance des modèles prédictifs M1 et M2 proposés en utilisant différentes configurations ANN (RBFNN, GRNN et ELM).

Dans les figures 4.26 et 4.27, le diagramme de **Taylor** [25,26] a été créé pour visualiser les informations reçues. Le diagramme de Taylor est le plus souvent utilisé pour comparer la précision en raison de la nature utile de plusieurs mesures de performance statistique en comparant la similarité entre les valeurs prédites et mesurées dans un seul diagramme [22,27,28].

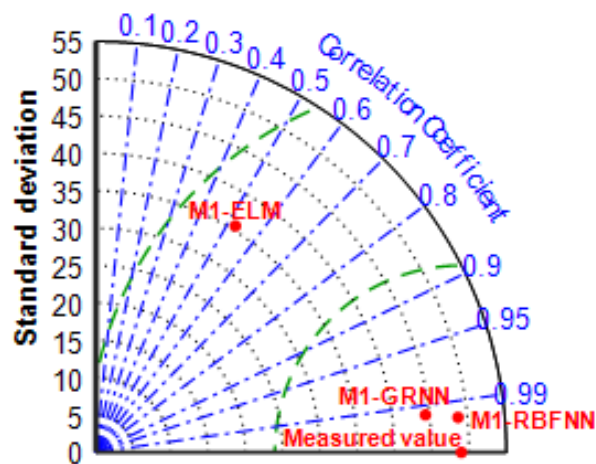


FIGURE 4.26 – Diagramme de Taylor qui démontre la meilleure performance pour la modélisation prédictive de  $\Delta T_c$  En utilisant les modèles M1 (6 entrées) .

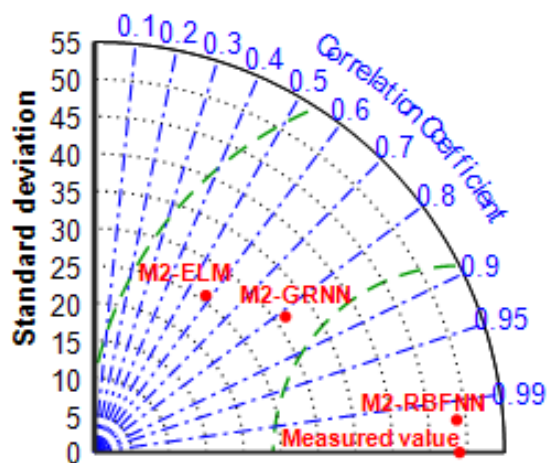


FIGURE 4.27 – Diagramme de Taylor qui démontre la meilleure performance pour la modélisation prédictive de  $\Delta T_c$  En utilisant les modèles M2 (4 entrées) .

D'après l'interprétation graphique visuelle obtenue à partir de la Fig. 4.26, le modèle M1-RBFNN (avec 6 entrées) comparé aux deux autres modèles (M1-GRNN et M1-ELM) était le plus proche des valeurs mesurées cibles.

La même observation est faite pour les modèles M2 proposés (M2-RBFNN, M2-GRNN, et M2-ELM) construits avec 4 entrées. En regardant la valeur de corrélation ( $R$ ) plus élevée qui est attribuée à M2-RBFNN et M1-RBFNN respectivement, les résultats prédictifs peuvent également être démontrés.

En général, l'analyse de l'écart-type ( $SD$ ) des valeurs prédites par rapport au ( $SD$ ) des valeurs mesurées permet d'évaluer la tendance du modèle proposé. Si l'écart-type ( $SD$ ) des valeurs prédites dépasse l'écart-type ( $SD$ ) des valeurs mesurées. Alors le modèle proposé

a tendance à fournir des valeurs surestimées et inversement. Il est clair dans le Tableau 4.9 que le modèle ( $SD$ ) de M2-RBFNN est beaucoup plus proche du  $SD$  de la valeur mesurée.

TABLE 4.9 – Écart-type des valeurs mesurées et prédites de  $\Delta T_c$ .

| $\Delta T_c$ | Modèles M1 |        |        | Modèles M2 |        |        |        |
|--------------|------------|--------|--------|------------|--------|--------|--------|
|              | mesurées   | RBFNN  | GRNN   | ELM        | RBFNN  | GRNN   | ELM    |
| Écart-type   | 48.979     | 48.752 | 44.445 | 35.601     | 48.785 | 31.411 | 25.785 |

Les réseaux neuronaux à fonction de base radiale ont démontré des capacités prometteuses en matière de modélisation non linéaire, ce qui n'est pas surprenant puisque le RBFNN a montré des performances exceptionnelles en modélisation d'ingénierie. Enfin, une étude comparative est présentée dans la Fig. 4.28, en termes de valeurs prédites de  $\Delta T_c$  en utilisant M2-RBFNN et M1-RBFNN.

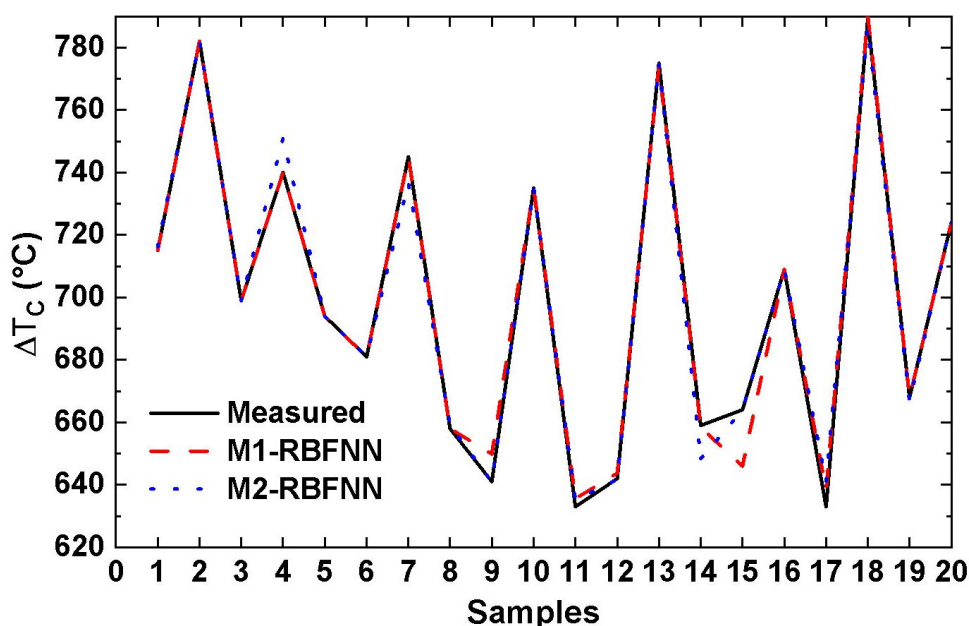


FIGURE 4.28 – Comparaison entre les valeurs mesurées et prédites de  $\Delta T_c$  en utilisant le modèle  $M1 - RBFNN$  et  $M2 - RBFNN$ .

Pour conclure la section de discussion, les réseaux neuronaux à fonction de base radiale (RBFNN) proposés couplés à la méthode de l'entropie de Shannon comme techniques de réduction des caractéristiques (4 entrées) se sont avérés avoir de bonnes capacités de prédiction de la température critique de choc thermique  $\Delta T_c$  par rapport aux modèles de réseaux neuronaux artificiels simples utilisant toutes les entrées (6 entrées). Le principal avantage du modèle M2-RBFNN est un excellent modèle de prédiction en raison de son efficacité prometteuse pour surmonter l'effet que la base de données est très courte.

### 3.4 Conclusion

Dans cette étude, la combinaison de réseaux neuronaux artificiels et de la méthode de l'entropie de Shannon dans la température critique de choc thermique  $\Delta T_c$  ont été appliquées. Cet article démontre la première utilisation des modèles SE-RBFNN pour prédire  $\Delta T_c$ .

La méthode de l'entropie de Shannon a été utilisée dans cette étude comme réduction des caractéristiques, et les entrées optimales ont été utilisées comme entrées pour différents modèles de réseaux neuronaux artificiels (RBFNN, GRNN et ELM).

Les principaux avantages de la méthode de l'entropie de Shannon sont le gain de temps et l'amélioration de la précision des modèles dans la modélisation prédictive.

Pour chacun des modèles proposés (RBFNN, GRNN et ELM), deux modèles différents ont été créés, le premier est un modèle unique (M1-RBFNN, M1-GRNN et M1-ELM) et le second est un modèle combiné utilisant la méthode de l'entropie de Shannon (M2-RBFNN, M2-GRNN et M2-ELM). Les résultats prédictifs ont montré que le modèle M2-RBFNN a un niveau de précision élevé par rapport aux modèles simples pour toutes les variables étudiées.

Les résultats ont également montré que les modèles M2-RBFNN et M1-RBFNN ont un pouvoir prédictif et peuvent être considérés comme des modèles précis. Les résultats de cette analyse peuvent contribuer à la modélisation de la température critique du choc thermique  $\Delta T_c$ .

Le modèle proposé M2-RBFNN fournit un point de référence pour la fabrication et la gestion expérimentale de l'alpha-Alumine micro-structurée obtenue par frittage par étincelage de plasma (SPS).



## Références du Chapitre 4

- [1] Mignard, F., Olagnon, C., Fantozzi, G., Chantrenne, P., & Raynaud, M. (1996). Thermal shock behaviour of a coarse grain porous alumina. *Journal of materials science*, 31(8), 2131-2138.
- [2] Anstis, G. R., Chantikul, P., Lawn, B. R., & Marshall, D. B. (1981). A critical evaluation of indentation techniques for measuring fracture toughness : I, direct crack measurements. *Journal of the American Ceramic Society*, 64(9), 533-538.
- [3] Evans, J. R. G., Stevens, R., & Tan, S. R. (1984). The thermal shock of  $\beta$ -alumina. *Journal of materials science*, 19(11), 3692-3701.
- [4] Gupta, T. K. (1975). Thermal damage of alumina in relation to the grain size. *Strength of Materials*, 7(5), 540-544.
- [5] Li, D., Pang, Y., Lu, T., Liu, Z., & Chen, S. (2022). Numerical analysis of thermal shock cracking behaviors of ceramics based on the force-heat equivalence energy density principle. *Frontiers in Materials*, 8, 641.
- [6] Belghalem, H., Hamidouche, M., Gremillard, L., Bonnefond, G., & Fantozzi, G. (2017). Effect of spark plasma sintering of alumina nanopowder on the mechanical properties. *Journal of the Australian Ceramic Society*, 53(1), 49-55.
- [7] Chakravarty, D., Bysakh, S., Muraleedharan, K., Rao, T. N., & Sundaresan, R. (2008). Spark plasma sintering of magnesia-doped alumina with high hardness and fracture toughness. *Journal of the American Ceramic Society*, 91(1), 203-208.
- [8] Huang, C. Z., Zhang, L., He, L., Sun, J., Fang, B., Zou, B., ... & Ai, X. (2002). A study on the prediction of the mechanical properties of a ceramic tool based on an artificial neural network. *Journal of Materials Processing Technology*, 129(1-3), 399-402.
- [9] Yibin, S., & Peijin, W. (2004). A predictive model based on RBF neural network. In *Proc Sixth IASTED Int Conf on Intelligent Systems and Control* (pp. 380-383).
- [10] Chaber, P., & Ławryńczuk, M. (2015, August). RBF neural networks for modelling and predictive control : An application to a neutralisation process. In *2015 20th International Conference on Methods and Models in Automation and Robotics (MMAR)* (pp. 776-781). IEEE.

[11] Kehe, W., Yue, Y., Bohao, C., & Jinshui, W. (2013, June). Research of wind power prediction model based on RBF neural network. In 2013 International Conference on Computational and Information Sciences (pp. 237-240). IEEE.

[12] Tahyudin, I. (2015). Time Series Prediction Using Radial Basis Function Neural Network. *International Journal of Electrical & Computer Engineering* (2088-8708), 5(4).

[13] Moody, J., Darken, C. J. (1989). Fast learning in networks of locally-tuned processing units. *Neural computation*, 1(2), 281-294.

[14] Hunter, D., Yu, H., Pukish III, M. S., Kolbusz, J., & Wilamowski, B. M. (2012). Selection of proper neural network sizes and architectures—A comparative study. *IEEE Transactions on Industrial Informatics*, 8(2), 228-240.

[15] Zhao, Z. Q., & Huang, D. S. (2007). A mended hybrid learning algorithm for radial basis function neural networks to improve generalization capability. *Applied Mathematical Modelling*, 31(7), 1271-1281.

[16] Yu, H., Xie, T., Paszczyński, S., & Wilamowski, B. M. (2011). Advantages of radial basis function networks for dynamic system design. *IEEE Transactions on Industrial Electronics*, 58(12), 5438-5450.

[17] Shannon, C. E. (1948). A mathematical theory of communication. *The Bell system technical journal*, 27(3), 379-423.

[18] Celikoglu, H. B., & Cigizoglu, H. K. (2007). Public transportation trip flow modeling with generalized regression neural networks. *Advances in Engineering Software*, 38(2), 71-79.

[19] Kim, B., Lee, D. W., Park, K. Y., Choi, S. R., & Choi, S. (2004). Prediction of plasma etching using a randomized generalized regression neural network. *Vacuum*, 76(1), 37-43.

[20] Tamura, S. I., & Tateishi, M. (1997). Capabilities of a four-layered feedforward neural network : four layers versus three. *IEEE Transactions on Neural Networks*, 8(2), 251-255.

[21] Huang, G. B. (2003). Learning capability and storage capacity of two-hidden-layer

feedforward networks. *IEEE transactions on neural networks*, 14(2), 274-281.

[22] Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine : theory and applications. *Neurocomputing*, 70(1-3), 489-501.

[23] Olyaie, E., Abyaneh, H. Z., & Mehr, A. D. (2017). A comparative analysis among computational intelligence techniques for dissolved oxygen prediction in Delaware River. *Geoscience Frontiers*, 8(3), 517-527.

[24] Gaya, M. S., Zango, M. U., Yusuf, L. A., Mustapha, M., Muhammad, B., Sani, A., ... & Khairi, M. T. M. (2017). Estimation of turbidity in water treatment plant using Hammerstein-Wiener and neural network technique. *Indonesian Journal of Electrical Engineering and Computer Science*, 5(3), 666-672.

[25] Wang, Q. (2012). Kernel principal component analysis and its applications in face recognition and active shape models. *arXiv preprint arXiv :1207.3538*.

[26] Adamowski, J., Fung Chan, H., Prasher, S. O., Ozga-Zielinski, B., & Sliusarieva, A. (2012). Comparison of multiple linear and nonlinear regression, autoregressive integrated moving average, artificial neural network, and wavelet artificial neural network methods for urban water demand forecasting in Montreal, Canada. *Water Resources Research*, 48(1).

[27] Zhou, T., Wang, F., & Yang, Z. (2017). Comparative analysis of ANN and SVM models combined with wavelet preprocess for groundwater depth prediction. *Water*, 9(10), 781.

[28] Elkiran, G., Nourani, V., & Abba, S. I. (2019). Multi-step ahead modelling of river water quality parameters using ensemble artificial intelligence-based approach. *Journal of Hydrology*, 577, 123962.

# Conclusion et perspectives

# Conclusion et perspectives

## 1 Conclusions de l'étude

Cette thèse porte sur l'intégration de méthodes d'intelligence artificielle pour la caractérisation mécanique et thermique des céramiques technique, notamment lorsqu'il est difficile d'obtenir un grand nombre d'échantillons. Le choix s'est logiquement porté sur la technique de machine Learning. Puisque cette technique convient aux petites tailles de données.

Ce travail a d'abord commencé par une étude bibliographique sur les applications des réseaux de neurones artificiels dans le domaine de la prédiction des paramètres mécaniques, thermiques et autres des matériaux et a présenté les matériaux céramiques en général et l'alumine en particulier, notamment les propriétés mécaniques et thermiques de ce matériau et ses méthodes de préparation. Ensuite, dans le chapitre suivant, nous avons présenté les différentes approches utilisées dans l'étude de la résistance aux chocs thermiques des matériaux et nous l'avons terminé en présentant les résultats expérimentaux de la résistance aux chocs thermiques (le premier paramètre R) de l'alpha-alumine, objet de notre étude.

Dans le troisième chapitre, nous nous sommes intéressés aux méthodes des réseaux de neurones artificiels, en particulier celles des problèmes de régression, pour prédire les paramètres mécaniques et le premier paramètre de résistance aux chocs thermiques. La technique des réseaux neuronaux artificiels a été appliquée dans le quatrième chapitre. Ils ont été appliqués avec succès aux paramètres étudiés. De plus, nous avons étudié l'effet des entrées sur la construction de modèles prédictifs et nous avons conservé les entrées à fort influence.

A terme, ces travaux ouvrent des perspectives intéressantes pour l'utilisation de la technique des réseaux de neurones artificiels pour la caractérisation mécanique et thermique d'un matériau céramique. Les avantages obtenus par rapport aux approches tra-

ditionnelles permettent d'envisager l'étude de matériaux nécessitant un temps important pour être réalisé en laboratoire et un grand nombre d'échantillons pour réaliser les essais. La précision prédictive de ces méthodes permet la création de pré-modèles pour travailler sur de nouveaux matériaux afin d'améliorer les propriétés mécaniques et thermiques, ce qui renforce l'intérêt de cette technique.

D'après les résultats trouvés dans ce travail tout au long de notre étude, nous avons constaté que le principal avantage de cette technique réside dans leur capacité à représenter des relations linéaires et non linéaires complexes et dans leur capacité à apprendre ces relations directement à partir de l'ensemble de données modélisées. Cette caractéristique fait des réseaux de neurones artificiels un bon candidat pour prendre des entrées dans un nouveau jeu de données et pour produire la sortie correspondante dans un temps de simulation très court, ce qui permet aux chercheurs et aux industriels d'économiser beaucoup de temps de calcul.

## 2 Perspectives

On peut envisager plusieurs perspectives de ce travail :

- Le développement d'un modèle ANN permettant de modéliser les comportements mécaniques, thermiques..., des matériaux fragiles et des matériaux émergents. Ceci permet en fait de passer à des modèles plus réalistes et plus précis, car il nous donne la possibilité de prendre en compte de nombreux paramètres en même temps qui sont difficiles à prendre en compte par les approches conventionnelles, ces dernières prenant beaucoup de temps. Pour cela, les réseaux de neurones artificiels peuvent être utilisés en raison de leur capacité à utiliser de nombreux paramètres complexes pour prédire le comportement attendu.

- Afin d'approfondir les études, ces techniques d'intelligence artificielle peuvent être introduites pour réduire les paramètres d'entrée. Ces techniques permettent de révéler les paramètres les plus influents dans un processus sans réaliser des expériences supplémentaires. Cela permet également de réduire la phase d'apprentissage du modèle ANN. Cette phase peut être développée avant la construction du modèle.

- Créer une grande base de données afin de pouvoir utiliser la technique d'apprentissage profond (deep Learning) en raison de son grand potentiel de prédiction.

- La possibilité de construire des modèles prédictifs basés sur des méthodes hybrides d'intelligence artificielle et d'obtenir une efficacité prédictive élevée.

- Il est possible de construire une préconception des paramètres de création des matériaux émergents et ainsi de se concentrer sur les caractéristiques et les paramètres influents, ce qui permet de gagner du temps et de l'argent.

# Liste des publications

## Articles

**B. Fissah**, H. Belghalem, M. Djeddou, B. Mamen. "*Critical thermal shock temperature prediction of alumina using improved hybrid models based on artificial neural networks and Shannon entropy models*". JOURNAL OF MECHANICAL ENGINEERING AND SCIENCES (JMES).

DOI: [10.15282/jmes.16.2.2022.07.0703](https://doi.org/10.15282/jmes.16.2.2022.07.0703)

## Conférences internationales

**B. Fissah**, H. Belghalem, B. Mamen, M.Hamidouche, G.Fantozzi. "*Effet des Propriété Mécaniques sur le choc thermique d'une alumine ( $\alpha$ -Al<sub>2</sub>O<sub>3</sub>)*". Université Echahid Hamma Lakhdar, El-Oued, 20-21/01/2020.

**B. Fissah**, H. Belghalem, M. Djeddou, B. Mamen. "*Predictive modeling of Young's modulus for alpha alumina using artificial neural networks and multiple linear regression*". Université Larbi Ben El M'hidi, Oum El Bouaghi, 8-9/12/2021.

**B. Fissah**, H. Belghalem, M. Djeddou, B. Mamen. "*Application of artificial neural network and regression analysis in prediction of Young's modulus of Alumina*". Université Larbi Ben El M'hidi, Oum El Bouaghi, 15-16/11/2021.

**B. Fissah**, H. Belghalem, M. Djeddou, B. Mamen. "*Predicting young's modulus of alumina using artificial neural networks*". Alwaha Scientific Publishing Services (ASPS), Biskra, <https://asps-journals.com>, 18-20/12/2021.



## RÉSUMÉ

---

Ce travail porte sur la modélisation de la résistance aux chocs thermiques d'un matériau fragile : les céramiques de type Alumine ( $Al_2O_3$ ) par des réseaux de neurones artificiels. Considérant que les méthodes classiques sont très coûteuses en termes de mise en œuvre expérimentale et nécessitent beaucoup de temps et en raison du chevauchement et de l'influence de nombreux paramètres qui doivent être contrôlés.

Notre contribution est de modéliser de manière prédictive la résistance aux chocs thermiques de l'alumine dans les meilleurs délais et avec une grande efficacité. Nous avons utilisé des modèles de réseaux de neurones simples et hybrides.

L'efficacité des réseaux utilisés a été testée à l'aide d'un ensemble de critères statistiques utilisés dans la littérature scientifique dans ce domaine, mais pour que les résultats prédictifs obtenus soient applicables, ils ont été comparés aux résultats expérimentaux. Il a été constaté dans cette étude que notre approche a un grand potentiel pour modéliser la relation entre le paramètre de résistance au choc thermique et les paramètres d'élaboration et physiques qui sont difficiles à modéliser à l'aide de modèles mathématiques. L'efficacité du modèle prédictif obtenu est convaincante.

Ces travaux ouvrent des perspectives prometteuses pour le contrôle des paramètres affectant la résistance aux chocs thermiques des matériaux céramiques. Elle peut être généralisée et exploitée sur d'autres matériaux fragiles ayant des propriétés physiques similaires à l'alumine.

## MOTS CLÉS

---

Modélisation, Réseaux de Neurones Artificiels, Choc Thermique, Alumine

## ABSTRACT

---

This work deals with the modeling of the thermal shock resistance of a brittle material: Alumina ( $Al_2O_3$ ) type ceramics by artificial neural networks. Considering that, classical methods are very expensive in terms of experimental implementation and require a lot of time because of the overlapping and influence of many parameters that must be controlled.

Our contribution is to predictively model the thermal shock resistance of alumina in the shortest possible time and with high efficiency. We have used simple and hybrid neural network models.

The effectiveness of the networks used was tested using a set of statistical criteria used in the scientific literature in this area, but for the predictive results obtained to be applicable, they were compared to experimental results. It was found in this study that our approach has great potential to model the relationship between the thermal shock resistance parameter and the processing and physical parameters that are difficult to model using mathematical models. The effectiveness of the resulting predictive model is convincing.

This work opens promising perspectives for the control of parameters affecting the thermal shock resistance of ceramic materials. It can be generalized and exploited on other brittle materials with physical properties similar to alumina.

## KEYWORDS

---

Modeling, Artificial Neural Networks, Thermal Shock, Alumina