

Ministère de l'enseignement Supérieur et de la recherche Scientifique

وزارة التعليم العالي والبحث العلمي

Université Badji Mokhtar – Annaba



جامعة باجي مختار – عنابــــــــة

Faculté de la technologie

كلية التكنولوجيا

Département électromécanique

قسم الكتروميكانيك

## Thèse

Présentée pour obtenir le diplôme de

### Doctorat LMD

Département : Electromécanique

Spécialité : Maintenance Industrielle

Filière : Sécurité Industrielle

Par :

**FENGHOUR Nadir**

Thème :

**Application de l'analyse en composantes principales pour l'évaluation des défauts et les risques d'une turbine à gaz**

# *Dédicaces*

*Je dédie cet humble travail à :*

*A mes parents. Il n'y a pas d'hommage comme cet amour*

*Ils me remplissent tout le temps.*

*Que Dieu les bénisse avec la santé et la longévité.*

*À ceux que j'aime profondément et qui m'ont soutenu tout au long de ce projet :*

*Ma femme et bien sûr mes frères et sœurs.*

*A toute ma famille, et mes amis.*

*Des gens qui m'ont souvent aidé et encouragé, qui ont toujours été à mes côtés,*

*Ceux qui m'accompagnent dans mon parcours vers l'enseignement supérieur,*

*Mes bons amis et camarades de classe*

*A tous ceux qui ont participé à rendre ce projet possible,*

*Je dis merci.*

# Remerciements

*Nous commençons par remercier Allah Tout-Puissant pour la force, la santé et la persévérance qu'Il nous a accordées pendant ces longues années.*

*Ici, nous tenons aussi à exprimer nos intenses remerciements À notre mentor Monsieur HADJADJ A E, qui nous a apporté une assistance inestimable. Nous le remercions pour sa disponibilité, sa compréhension et ses encouragements...*

*Je tiens à remercier Monsieur Bouakkaz Massaoud pour son aide tout au long du déroulement de ma thèse, pour sa disponibilité et ses guides avisés. Ses remarques m'ont été très précieuses dans l'avancement de mon travail.*

*Nous tenons également à remercier tous les enseignants qui ont contribué à notre formation, et tous les membres du jury qui ont accepté de juger notre travail.*

*Enfin, nous tenons à gratifier tous nos amis et collègues, en particulier Gégadair Amar, pour leur soutien moral et matériel.*

## Table des matières

|   |            |
|---|------------|
| Dédicace.....   | <i>i</i>   |
| Remerciements.....  | <i>ii</i>  |
| Table des matières.....   | <i>iii</i> |
| Liste des figures.....  | <i>iv</i>  |
| Notation.....   | <i>v</i>   |
| Résumé.....   | <i>vi</i>  |
| Introduction générale.....  | 1          |
| <b>Chapitre I : Les méthodologies de diagnostic</b>                         |            |
| <b>1. Introduction.....</b>   | <b>3</b>   |
| <b>2. Terminologie.....</b>   | <b>3</b>   |
| <b>3. Les concepts fondamentaux du diagnostic.....</b>                      | <b>5</b>   |
| 3.1.La détection d'un défaut.....   | 6          |
| 3.2.La localisation de défauts.....   | 7          |
| 3.3.La reconfiguration du système.....                                      | 7          |
| <b>4. Les exigences liées au diagnostic.....</b>                            | <b>7</b>   |
| 4.1.Exigences fonctionnelles.....   | 7          |
| 4.2.Exigences non fonctionnelles.....                                       | 8          |
| <b>5. Les différentes méthodes de diagnostic.....</b>                       | <b>9</b>   |
| 5.1.Les méthodes de diagnostic à base de modèles.....                       | 9          |
| 5.1.1. Le diagnostic à base de modèles quantitatifs.....                    | 9          |
| 5.1.2. Le diagnostic à base de modèles qualitatifs.....                     | 10         |
| 5.2.Les méthodes de diagnostic à base de données.....                       | 11         |
| 5.2.1. Méthodes basées sur des données qualitatives.....                    | 12         |
| 5.2.2. Méthodes basées sur des données quantitatives.....                   | 12         |
| <b>6. Conclusion.....</b>   | <b>15</b>  |
| <b>Chapitre II : Principe de l'analyse en composantes principales (ACP)</b> |            |
| <b>1. Introduction.....</b>   | <b>16</b>  |
| <b>2. Notions de base .....</b>   | <b>17</b>  |
| 2.1.Tableau de données .....  | 17         |
| 2.2.Variable .....  | 17         |

|  |           |
|--|-----------|
| 2.3.Observation .....  | 17        |
| 2.4.Moyenne .....  | 18        |
| 2.5.Variance .....   | 18        |
| <b>3. Principes de l'analyse en composantes principales (ACP) .....</b>                                    | <b>19</b> |
| <b>4. Modélisation par l'ACP Linéaire .....</b>  | <b>23</b> |
| 4.1.Traitement des données (normalisation de la matrice de données).....                                   | 23        |
| 4.2.Estimation des paramètres du modèle .....  | 26        |
| 4.3.Détermination de la structure du modèle .....  | 26        |
| 4.3.1. Pourcentage cumulé de la variance totale (PCV).....   | 27        |
| 4.3.2. Moyenne des valeurs propres .....   | 29        |
| 4.3.3. Critère de validation croisée .....   | 29        |
| 4.3.4. Critère de la variance de l'erreur de reconstruction.....   | 30        |
| 4.3.4.1.Reconstruction linéaire .....  | 30        |
| 4.3.4.2.Reconstruction non linéaire.....   | 33        |
| <b>5. Analyse en composantes principales non linéaire.....</b>   | <b>35</b> |
| 5.1.Approche des Courbes Principales .....   | 38        |
| 5.1.1. Algorithme de calcul des courbes principales de Hastie .....  | 39        |
| 5.2.Les approches basées sur les réseaux de neurones artificiels .....                                     | 40        |
| 5.2.1. ACPNL par réseau neurone à cinq couches.....  | 40        |
| 5.2.1.1.le modèle séquentiel de L'ACPNL.....   | 42        |
| 5.2.1.2.le modèle parallèle de l'ACPNL .....   | 43        |
| 5.2.1.3.Apprentissage du réseau neurone à cinq couches .....   | 45        |
| 5.2.2. L'approche de l'ACPNL par optimisation des entrées du réseau neurone...46                           |           |
| 5.2.3. L'approche de réseau de neurones de type RBF.....   | 48        |
| 5.3.Approche combinant les réseaux de neurones et les courbes principales .....                            | 51        |
| 5.4.Analyse en composantes principales non linéaire .....  | 52        |
| <b>6. Conclusion.....</b>  | <b>56</b> |
| <b>Chapitre III : Détection et localisation des défauts par l'analyse en composantes principales (ACP)</b> |           |
| <b>1. Introduction .....</b>   | <b>57</b> |
| <b>2. Détection de défauts.....</b>  | <b>57</b> |
| 2.1. Indices statistiques pour la détection de défauts .....   | 58        |
| 2.1.1. Statistique SPE (Q-Statistic).....  | 58        |
| 2.1.2. Statistique T2 de Hotelling .....   | 60        |

|   |           |
|---|-----------|
| 2.1.3. Statistique SWE .....                                      | 61        |
| 2.1.4. Statistique combinée $\zeta$ .....                         | 61        |
| 2.2. Filtrage EWMA pour la détection .....                        | 62        |
| <b>3. Localisation de défauts .....</b>                           | <b>63</b> |
| 3.1. Méthodes sans optimisation des résidus aux défauts.....      | 64        |
| 3.1.1. Localisation par calcul des contributions .....            | 64        |
| 3.1.2. Localisation par ACP partielles .....                      | 66        |
| 3.1.3. Localisation par la méthode d'élimination .....            | 67        |
| 3.2. Méthodes à base d'optimisation des résidus aux défauts ..... | 68        |
| 3.2.1. Localisation basée sur la structuration des résidus.....   | 68        |
| 3.2.2. Localisation basée sur le principe de reconstruction.....  | 70        |
| <b>4. Conclusion .....</b>  | <b>72</b> |

## **Chapitre IV : Principe de fonctionnement d'une turbine à gaz**

|  |           |
|--|-----------|
| <b>1. Introduction.....</b>  | <b>73</b> |
| <b>2. Description générale de la centrale.....</b>                   | <b>73</b> |
| <b>3. Turbine à gaz.....</b>   | <b>76</b> |
| 3.1. Généralités sur le groupe thermique turbine à gaz.....          | 76        |
| 3.2. Principe de fonctionnement de la turbine à gaz.....             | 76        |
| 3.3. Description des principaux composants de la turbine à gaz.....  | 77        |
| 3.3.1. Section compresseur.....                                      | 79        |
| 3.3.2. Section chambres de combustion et tubes d'interconnexion..... | 80        |
| 3.3.3. Section turbine.....  | 80        |
| 3.3.4. Section cadre d'échappement et diffuseur .....                | 83        |
| 3.3.5. Paliers.....  | 84        |
| 3.3.6. Accouplements .....   | 85        |
| 3.3.7. Compartiments.....  | 86        |
| 3.3.8. Section aspiration et échappement.....                        | 87        |
| 3.4. Auxiliaires turbine à combustion.....                           | 89        |
| 3.4.1. Aubages à inclinaison variables.....                          | 89        |
| 3.4.2. Système de graissage.....                                     | 89        |
| 3.4.3. Éliminateur de brouillard d'huile .....                       | 90        |
| 3.4.4. Système hydraulique de commande et de sécurité .....          | 91        |
| 3.4.5. Mesure des vibrations .....                                   | 91        |
| 3.4.6. Alimentation combustible gaz.....                             | 92        |
| 3.4.7. Aspiration d'air.....   | 93        |
| 3.4.8. Circuit de réfrigération .....                                | 93        |

|  |            |
|--|------------|
| 3.4.9. Dispositif de lancement.....                              | 95         |
| 3.4.10. Convertisseur de couple et vireur hydraulique.....       | 95         |
| 3.4.11. Système d'air de refroidissement et d'étanchéité.....    | 96         |
| <b>3.5. Caractéristique et description de l'alternateur.....</b> | <b>97</b>  |
| 3.5.1. Stator.....   | 97         |
| 3.5.2. Rotor.....  | 97         |
| 3.5.3. Caractéristiques nominales de l'alternateur.....          | 98         |
| 3.5.4. Caractéristique et description de l'excitatrice.....      | 98         |
| <b>3.6. Démarrage de la turbine à gaz.....</b>                   | <b>99</b>  |
| 3.6.1. Mise en virage.....                                       | 99         |
| 3.6.2. Les séquences de démarrage.....                           | 100        |
| 3.6.3. Excitation de l'alternateur.....                          | 101        |
| 3.6.4. Couplage.....   | 101        |
| <b>3.7. Arrêt de la turbine à gaz.....</b>                       | <b>102</b> |
| 3.7.1. Séquences d'arrêt.....                                    | 102        |
| <b>4. Conclusion .....</b>                                       | <b>103</b> |

## **Chapitre V: Diagnostic de défauts par ACP linéaire et non linéaire d'une turbine à gaz**

|   |            |
|---|------------|
| <b>1. Introduction.....</b>   | <b>104</b> |
| <b>2. Travaux de recherche dans le domaine du diagnostic pour les TG.....</b>       | <b>104</b> |
| <b>3. Variables utilisées pour construire le modèle ACP.....</b>                    | <b>106</b> |
| 3.1. Prétraitement des données.....   | 107        |
| <b>4. Application de l'ACP linéaire.....</b>  | <b>108</b> |
| 4.1. Détermination le nombre optimale de composantes principales.....               | 108        |
| 4.2. L'évolution des mesures de variables et leurs modèles basées sur l'ACPL.....   | 109        |
| 4.3. L'évolution de l'indice de détection cas sans défaut.....                      | 111        |
| 4.4. Détection de défauts par ACP linéaire.....                                     | 112        |
| <b>5. Application de l'ACP non linéaire (ACP NL).....</b>                           | <b>114</b> |
| 5.1. L'évolution des mesures de variables et leurs modèles basées sur l'ACP NL..... | 114        |
| 5.2. L'évolution de l'indice de détection cas sans défaut (ACP NL).....             | 117        |
| 5.3. Détection de défauts par ACP non linéaire.....                                 | 119        |
| <b>6. Interprétation et discussion des résultats.....</b>                           | <b>124</b> |
| <b>7. Conclusion.....</b>   | <b>125</b> |
| <b>Conclusion générale.....</b>   | <b>126</b> |

## **Bibliographié**

## Liste des figures

|  |    |
|--|----|
| Figure.I.1 : Structure générale d'un système de diagnostic et surveillance.....  | 6  |
| Figure.II.1. Structure d'un tableau de données.....  | 17 |
| Figure.II.2. Représentation géométrique des observations.....  | 18 |
| Figure.II.3. Nuage des points dans le cas $m=3$ .....  | 18 |
| Figure.II.4. Décomposition du vecteur de mesures.....  | 22 |
| Figure.II.5. Algorithme de l'ACP.....  | 23 |
| Figure.II.6. Illustration graphique de l'effet du centrage d'une distribution bi-variable (a)<br>Distribution d'origine (b) Centrage de cette distribution.....  | 24 |
| Figure.II.7. Représentation d'observations et des parties modélisée et résiduelle de l'une<br>d'entre elles ( $x$ ) dans le cas de deux variables ( $m=2$ )..... | 25 |
| Figure.II.8. Exemple illustratif de la méthode variance cumulée en fonction des composantes<br>principales.....  | 28 |
| Figure.II.9. Évolution des valeurs propres en fonction des composantes principales.....  | 29 |
| Figure.II.10. Sélection du nombre de CPs par VER.....  | 33 |
| Figure.II.11. Différentes étapes pour la détermination du nombre de composantes (modèle<br>ACP) et des variables à surveiller.....                               | 35 |
| Figure.II.12. Présentation de l'ACPL et l'ACP NL.....  | 36 |
| Figure.II.13. Principe de la modélisation par l'analyse en composantes principales.....  | 37 |
| Figure.II.14. Indice de projection. Pour tout $i$ , $t_i$ désigne $t_{\mathcal{F}}(x_i)$ .....   | 38 |
| Figure.II.15. Réseau à cinq couches pour l'extraction d'une seule composante principale non<br>linéaire.....   | 40 |
| Figure.II.16. Le modèle séquentiel de l'ACP NL.....  | 43 |
| Figure.II.17. le modèle parallèle de l'ACP NL.....   | 44 |
| Figure.II.18. Le modèle d'optimisation des entrées par Tan.....  | 47 |
| Figure.II.19. Réseau RBF pour la compression des données (projection).....   | 49 |
| Figure. II.20. Réseau RBF pour la décompression des données (projection inverse).....  | 50 |
| Figure.II.21. Topologie des réseaux de neurones auto-associatifs.....  | 52 |

|   |     |
|---|-----|
| Figure.II.22.principe de l'analyse en composantes principales du noyau KPCA.....  | 54  |
| Figure.II.23.Extraction de fonctionnalités PCA du noyau pour une tâche OCR (point de test $x$ , vecteur propre $V$ ).....     | 55  |
| Figure.III.1. Procédure de localisation par ACP partielle structurée.....   | 67  |
| Figure.IV.1.principe de fonctionnement d'une turbine à gaz.....   | 77  |
| Figure.IV.2. Contrôle TG.....   | 79  |
| Figure.IV.3. Température de la turbine.....   | 83  |
| Figure.IV.4. Température d'échappement.....   | 84  |
| Figure.IV.5. Étanchéité des paliers.....  | 85  |
| Figure.IV.6. Réducteur de puissance.....  | 86  |
| Figure.IV.7. Turbocompresseur compartiment.....   | 87  |
| Figure.IV.8. Admission compresseur.....   | 88  |
| Figure .IV.9. Contrôle air d'admission compresseur.....   | 89  |
| Figure.IV.10. Système de graissage.....   | 90  |
| Figure.IV.11. Contrôle vibration.....   | 92  |
| Figure.IV.12. Système de combustion gaz.....  | 93  |
| Figure.IV.13. Système de refroidissement.....   | 94  |
| Figure.V.1 : Evolution de la variance non reconstruite en fonction de $\ell$ .....  | 109 |
| Figure.V.2 : Mesure et estimation de la température de l'air d'atomisations principales (AAT) par le modèle ACP linéaire..... | 110 |
| Figure.V.3 : Mesure et estimation du débit massique air admission compresseur (AFQ) par le modèle ACP linéaire.....           | 110 |
| Figure.V.4 : Mesure et estimation de la pression sortie compresseur (CPD) par le modèle ACP linéaire.....                     | 111 |
| Figure.V.5. Evolution de l'indice de détection SPE filtré "cas sans défaut".....  | 112 |
| Figure.V.6. Evolution de l'indice de détection SPE filtré par le défaut N°1.....  | 113 |
| Figure.V.7. Evolution de l'indice de détection SPE filtré par le défaut N°2.....  | 113 |
| Figure.V.8. Evolution de l'indice de détection SPE filtré par le défaut N°3.....  | 114 |

|  |     |
|--|-----|
| Figure.V.9 : Mesure et estimation de la température de l'air d'atomisations principales (AAT) par le modèle ACP non linéaire pour 7 CPs et 3 CPs respectivement..... | 115 |
| Figure.V.10 : Mesure et estimation du débit massique air admission compresseur (AFQ) par le modèle ACP non linéaire pour 7 CPs et 3 CPs respectivement.....          | 116 |
| Figure.V.11 : Mesure et estimation de la pression sortie compresseur (CPD) par le modèle ACP non linéaire pour 7 CPs et 3 CPs respectivement.....                    | 117 |
| Figure.V.12. Evolution de l'indice de détection SPE filtré "cas sans défaut" pour ACPNL à 3 CPs, m=78.....   | 118 |
| Figure.V.13. Evolution de l'indice de détection SPE filtré "cas sans défaut" pour ACPNL à 7 CPs, m=78.....   | 118 |
| Figure.V.14. Evolution de l'indice de détection SPE filtré "cas sans défaut" pour ACPNL à 7 CPs, m=28.....   | 119 |
| Figure.V.15.a. Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec CPs 3 (m=78) du défaut N°1.....   | 120 |
| Figure.V.15.b. Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec CPs 7 (m=78) du défaut N°1.....   | 120 |
| Figure.V.15.c. Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec CPs 7 (m =28) du défaut N°1.....  | 121 |
| Figure.V.16.a. Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec 3 CPs (m=78) du défaut N°2.....   | 121 |
| Figure.V.16.b. Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec 7 CPs (m=78) du défaut N°2.....   | 122 |
| Figure.V.16.c. Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec CPs 7 (m =28) du défaut N°2.....  | 122 |
| Figure.V.17.a. Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec 3 CPs (m=78) du défaut N°3.....   | 123 |
| Figure.V.17.b. Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec 7 CPs (m=78) du défaut N°3.....   | 123 |
| Figure.V.17.c. Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec CPs 7 (m =28) du défaut N°3.....  | 124 |

## Notation

|  |   |
|--|---|
| $X \in \mathfrak{R}^{m \times m}$      | Matrice de données.   |
| $n$                                    | Nombre d'échantillons mesurés.                                      |
| $m$                                    | Nombre de variables à surveiller.                                   |
| $\mathfrak{d}_{i=1,\dots,m}$           | Vecteurs observations (lignes de la matrice de données).            |
| $\mathfrak{v}_{i=1,\dots,m}$           | Vecteurs variables (colonnes de la matrice de données).             |
| $x_{ij}$                               | Échantillons du vecteur variable.                                   |
| $\bar{v}_j$                            | Moyenne de la $j^{eme}$ variable.                                   |
| $\sigma_j^2$                           | Variance de la $j^{eme}$ variable.                                  |
| $\Sigma \in \mathfrak{R}^{m \times m}$ | Matrice de covariance.  |
| $P \in \mathfrak{R}^{m \times \ell}$   | Matrice de vecteurs propres de la matrice de corrélation.           |
| $\lambda_i$                            | Valeurs propres de la matrice de corrélation.                       |
| $\Lambda$                              | Matrice diagonale des valeurs propres.                              |
| $t \in \mathfrak{R}^{n \times m}$      | Matrice de composantes principales.                                 |
| $\hat{P}$                              | $\ell$ premiers vecteurs propres.                                   |
| $\tilde{P}$                            | $m - \ell$ derniers vecteurs propres.                               |
| $\hat{t}$                              | $\ell$ premières composantes principales de $j^{eme}$ variable.     |
| $\tilde{t}$                            | $m - \ell$ dernières composantes principales $j^{eme}$ variable.    |
| $\hat{X}$                              | Matrice de données estimée par le modèle ACP.                       |
| $\tilde{X}$                            | Matrice de données résiduelles.                                     |
| $\hat{C}$                              | Matrice représente le modèle ACP.                                   |
| $z_j$                                  | Reconstruction de la $j^{eme}$ variable.                            |
| $\xi_j$                                | La $j^{eme}$ colonne de la matrice unitaire (direction de défauts). |
| $\chi_{\ell,\alpha}^2$                 | Seuil de confiance de l'indicateur d'Hotelling.                     |
| $\delta^2$                             | Seuil de confiance de l'indicateur SPE.                             |
| $\theta_j(\cdot)$                      | Fonction de réseau pour reconstruire.                               |
| $\phi_j(x)$                            | Fonction de base radiale (RBF).                                     |

|          |  |
|----------|--|
| $W$      | Vecteur de poids.                        |
| $\Phi$   | Vecteur des variables de transformation. |
| $\psi_j$ | Fonction noyau.                          |
| $V^T$    | Matrice de pondération.                  |
| $v_0$    | Terme de biais.                          |

## ملخص:

كشف الأعطال وعزلها لهما تداعيات عملية كبيرة في الأنظمة الصناعية. يُعد الكشف المبكر عن الفشل أمرًا ضروريًا لمنع الأضرار البيئية، وتدهور المنتجات، وانخفاض الأداء، وكذلك الضرر الجسيم للمعدات وسلامة الأفراد.

يعتمد أحد الأساليب التشخيصية الأساسية على استغلال زيادة المعلومات. يركز هذا النهج عمومًا على العلاقة الترابطية بين الحالة المقاسة للعملية (المحصل عليها عبر أجهزة الاستشعار) والحالة المتوقعة التي يوفرها نموذج رياضي للعملية. ومن ثم، يتطلب تقييم هذه الطرق الزائدة مراقبة مستمرة لنموذج النظام الذي يحتوي على العديد من المعلمات المفترض أن تكون معروفة في ظروف التشغيل الطبيعية. إن التقارب بين الحالة الفعلية للنظام والحالة المتوقعة، كما يقدرها النموذج، والذي يُستخدم لتقييم صحة النظام (residual) "يسمح بتحديد مؤشر يُعرف بالباقي.

لقد ثبت أن التقنيات الإحصائية متعددة المتغيرات تُعد الأكثر فعالية في التعامل مع توليد البواقي. ومن بين هذه التقنيات، فعالة بشكل خاص في إبراز العلاقات الترابطية المهمة (PCA) تُعتبر الأساليب المعتمدة على تحليل المكونات الرئيسية بين معلمات الآلية بوضوح، دون الحاجة إلى إنشاء نموذج نظام بشكل صريح. وبهذه الطريقة، يغطي نموذج تحليل المكونات الرئيسية كافة الترابطات بين المتغيرات المختلفة. تركز هذه الدراسة على تطبيق هذا النموذج التشخيصي على عملية صناعية تعتمد على توربين غازي، مما يمكّن من الكشف الدقيق عن أعطال المعدات أو الأنظمة الفرعية.

وفي هذا السياق، يهدف هذا العمل إلى تقييم كفاءة وأداء تقنيات الكشف عن العيوب القائمة على تحليل المكونات الرئيسية من خلال تطبيق هذه المناهج على البيانات المأخوذة من توربين غازي (PCA).

**المفاتيح:** التشخيص، المراقبة، كشف وتحديد مواقع الأعطاب، تحليل المركبات الأساسية الخطية.

## **Résumé :**

La détection et l'isolation des défauts ont des implications pratiques importantes dans les systèmes industriels. La détection précoce d'une défaillance est essentielle pour éviter les dommages environnementaux, la dégradation du produit, la dégradation des performances et les dommages importants à l'équipement et à la sécurité des personnes

Une des principales approches en diagnostic repose sur l'exploitation de la redondance des informations. Ce procédé s'appuie généralement sur la corrélation entre l'attitude mesurée du processus (obtenue via des capteurs) et celle prédite par un modèle mathématique du processus. Ainsi, l'évaluation de ces méthodes redondantes nécessite une surveillance continue du modèle du système, lequel comporte de nombreux paramètres supposés connus en conditions normales de fonctionnement. La correspondance entre l'attitude réelle du système et l'attitude attendue, telle qu'estimée par le modèle, permet de déterminer un indicateur appelé « résidu », qui sert à juger de l'état de santé du système.

Les techniques statistiques multivariées se révèlent être les plus performantes pour traiter la génération résiduelle. Parmi celles-ci, les méthodes basées sur l'analyse en composantes principales (ACP) s'avèrent particulièrement efficaces pour mettre en évidence de manière certaine les corrélations significatives entre les paramètres du mécanisme, sans nécessiter l'établissement explicite d'un modèle du système. Ainsi, le modèle ACP intègre l'ensemble des corrélations entre les différentes variables. Cette étude se focalise sur l'application de ce modèle de diagnostic à un processus industriel reposant sur une turbine à gaz, permettant ainsi la détection précise des défaillances d'équipements ou de sous-ensembles.

Pour cela, ce travail vise à évaluer l'efficacité et la performance des techniques de détection de défauts reposant sur l'analyse en composantes principales (ACP), en appliquant ces approches aux données issues d'une turbine à gaz.

**Mots-clés :** Diagnostic, Surveillance, Détection et localisation de défauts, Analyse en composantes principales linéaires.

**Abstract:**

Fault detection and isolation have significant practical implications in industrial systems. Early failure detection is essential to prevent environmental damage, product degradation, performance losses, and severe harm to equipment and personnel safety.

One of the primary diagnostic approaches is based on exploiting information redundancy. This method generally relies on the correlation between the measured state of the process (obtained via sensors) and the state predicted by a mathematical model. Consequently, evaluating these redundant methods requires continuous monitoring of the system model, which contains numerous parameters assumed to be known under normal operating conditions. The alignment between the actual state of the system and the expected state—as estimated by the model—allows for the determination of an indicator known as the "residual," which is used to assess the system's health.

Multivariate statistical techniques have proven to be the most effective for handling residual generation. Among these, methods based on Principal Component Analysis (PCA) are particularly effective at clearly highlighting significant correlations among the mechanism's parameters, without the need for explicitly developing a system model. In this way, the PCA model encompasses all correlations between the various variables. This study focuses on applying this diagnostic model to an industrial process based on a gas turbine, thereby enabling precise detection of equipment or subsystem failures.

To this end, this work aims to evaluate the efficiency and performance of fault detection techniques based on Principal Component Analysis (PCA) by applying these approaches to data derived from a gas turbine.

**Keywords:** Process monitoring, Fault detection and isolation, linear Principal component analysis, electric power production process.

## **Introduction générale :**

Dans tous les systèmes industriels, les défaillances provoquent une énorme perte économiques, des systèmes de surveillance et de diagnostic doivent donc être mis en place pour éviter les pannes inattendues, et en conséquence d'assurer la performance des installations industrielles.

Cette situation justifie la mise en œuvre de recherches scientifiques visant à développer des méthodes fiables de surveillance des systèmes afin de détecter précisément et précocement l'apparition de pannes et de trouver des solutions adaptées à chaque système industriel.

Le diagnostic industriel dont la fonction principale est de détecter et de localiser les défauts du système, pour lesquels il faut agir dès la phase de conception d'un procédé industriel.

La détection consiste la réalisation dans certitude des incidents qui affectent le fonctionnement normal des processus industriels. Typiquement, un événement peut refléter une modification des conditions qu'il considère comme normales (par exemple, dues à une action effectuée par un opérateur) ou anormales (par exemple, dues à un défaut). La détection des pannes consiste à comparer le fonctionnement réel du système au fonctionnement du système dans l'hypothèse d'un fonctionnement normal.

Les tâches de localisation limitent les échecs à un sous-ensemble de processus surveillés. Il comprend l'analyse des types d'événements afin de pouvoir déterminer la défaillance de l'instrument de mesure (défaillance du type de capteur), la défaillance de l'actionneur, le composant défaillant du processus.

L'une des principales techniques dans le domaine du diagnostic sont les méthodes basées sur la notion de redondance des informations. Leur raisonnement est souvent basé sur des tests de corrélation entre l'attitude constaté du processus livré par des capteurs et l'attitude prédit livré par une évocation arithmétique du processus. Par conséquent, l'analyse des méthodes redondantes nécessite une surveillance du modèle du système. Le modèle contient de nombreux paramètres dont les valeurs sont supposées connues en fonctionnement habituel. La similitude de l'attitude réelle du système avec l'attitude attendu reçu par le modèle donne une quantité appelée le résidu. Ceci est utilisé pour déterminer si le système est sain.

Les techniques les plus efficaces pour traiter la génération résiduelle sont les techniques statistiques multivariées. Parmi elles, Les théories à base de l'analyse en composantes principales (ACP) sont assez efficaces afin mettre en certitude des corrélations importantes entre les paramètres de mécanisme sans poser explicitement un modèle du système. Par conséquent, le modèle ACP prend en compte toutes les corrélations entre différentes variables. Cette étude examine ce modèle particulier de diagnostic de processus industriel basé sur une turbine à gaz (détection précise d'équipements ou de sous-ensembles défectueux).

Cette thèse est constituée en cinq chapitres :

Le chapitre 1 présente quelques définitions et généralités sur le diagnostic opérationnel des procédés industriels, ainsi que les principales méthodes de diagnostic.

Le chapitre 2 présente les méthodes statistiques utilisées dans notre étude, et après un peu d'histoire, nous allons détailler les différentes étapes de la modélisation ACP pour retrouver la structure et les paramètres des modèles, qui aident ensuite à la détection des défauts.

Le chapitre 3 est une revue des différentes méthodes de détection et d'isolation des défauts basées sur l'approche de l'analyse en composantes principales (ACP).

Le chapitre 4 présente une description détaillée de notre système qui choisit comme un exemple d'application de l'approche basée sur l'analyse en composante principale, où nous avons montré la description générale avec le principe de fonctionnement d'une turbine à gaz accouplé avec alternateur due à la production de l'énergie électrique. En plus, on présente les différents équipements constituant la turbine à gaz modèle 6002B fabriqué par générale électrique (GE).

Le chapitre 5 présente les résultats et leur interprétation de notre application choisit (l'analyse en composantes principales par réseau neurone à cinq couches) sur le processus de production d'énergie électrique basée sur la turbine à gaz.

# **Chapitre I**

## **Les méthodologies de diagnostic**

## 1. Introduction :

La complexité de l'installation industrielle ne cesse de croître. Elle concerne la technologie utilisée, le contrôle de l'utilisation et le processus de contrôle de la production, en particulier la grande quantité d'informations utilisées. L'objectif est clairement de chercher un fonctionnement optimal, une efficacité maximale, le respect des impératifs techniques de production, la sûreté et la sérénité du matériel et du personnel.

On parle aujourd'hui d'automatisation intégrée, les systèmes automatisés sont davantage délicat et doivent satisfaire à des enjeux majeurs de sûreté et de sécurité de travail pour assurer leur bon fonctionnement. Par conséquent, une bonne automatisation du mécanisme doit servir de mettre en œuvre de la résolution presque optimale dans le processus de fabrication. Cependant, la pratique s'écarte considérablement de ce plan conceptuel, puisqu'elle suppose implicitement que les fonctions de base du procédé, capteurs, actionneurs, régulateurs, etc. sont réalisées correctement.

Ces importance justifier le développement de la contrôle des installations et la réussite de la technologie de diagnostic de tous les systèmes industriels ces dernières années. Initialement, les diagnostics étaient limités aux domaines industriels à haut risque pour la collectivité, comme le nucléaire ou l'aviation, et aux activités de haute technologie, comme l'armement ou l'aérospatiale [01] [02]. Les premiers travaux sur le diagnostic remontent au début des années 1970, et en raison de l'intérêt croissant de l'industrie pour le diagnostic, le sujet est progressivement devenu un sujet de recherche indépendant.

## 2. Terminologie :

Dans un premier instant, il a semblé intéressant d'aller aux principaux termes et définitions utilisés dans le diagnostic système, où la Comité Technique SAFEPROCESS de la Fédération Internationale de l'Automatique IFAC a tenté d'offrir une nomenclature unifiée (Isermann et Ballé 1997, Patton 1999, Frank et al. Année 2000).

Nous proposons certaines définitions de cette commission à partir des bibliographies suivantes (Derbel 2009, Lauti 2012, Fragkoulis 2008) :

– **Système physique** : Un dispositif est une entité, un ensemble d'éléments interconnectés (composants), qui peut avoir une (ou multiples) entrées et peut avoir une (ou plusieurs) sorties, afin d'exécuter une fonction.

- **Composant** : Un composant est une partie (élément de base) d'un système sélectionné selon des critères liés à la modélisation.
- **Modèle** : Un modèle d'un dispositif physique est une représentation de sa composition et une description du comportement ou de la fonction de chaque composant.
- **Surveillance** : Il s'agit d'une fonction permanente en temps réel qui détermine l'état possible d'un dispositif physique tout en identifiant et en signalant les irrégularités comportementales.
- **Dysfonctionnement** : est une anomalie irrégulière dans l'exécution de la fonction demandée du système.
- **Défaillance** : Une défaillance est la modification ou l'arrêt de la capacité d'un composant à remplir sa fonction essentielle selon les performances définies dans la spécification technique.
- **Panne** : les défaillances peuvent perturber de manière permanente la capacité du système à exécuter les fonctions requises dans certaines conditions de fonctionnement et peuvent entraîner un arrêt complet du système.
- **Résidu** : Il s'agit de la similitude entre l'attitude réelle du dispositif et l'attitude attendue offerte par le modèle et offrir la quantité utilisée pour déterminer si le système est dans un état défectueux.
- **Seuil** : Il s'agit de la limite d'écart du résidu par rapport à zéro. Par conséquent, en cas de dépassement, une détection de défaut est déclarée.
- **Observation** : indication dérivée du comportement ou du fonctionnement évident d'un système.
- **La mesure** : est une constatation de base car elle marque une et une unique dimension physique. Il est représenté par une variante qui est le fond de l'image d'une dimension physique. Il est obtenu par le capteur.
- **Le mode de fonctionnement** : L'évolution du dispositif pendant le temps s'explique par différents modes de fonctionnement. On distingue généralement :
  1. Mode de fonctionnement normal : mode dans lequel le dispositif productif exécute sa tâche dans l'exigence de travail demandé par le constructeur et les exigences attendues par l'exploitant.
  2. Mode de fonctionnement dégradé : correspond soit à des tâches partiellement réalisées soit à des performances moindres. En d'autres termes, l'appareil ou le système est dégradé, mais pas défectueux.

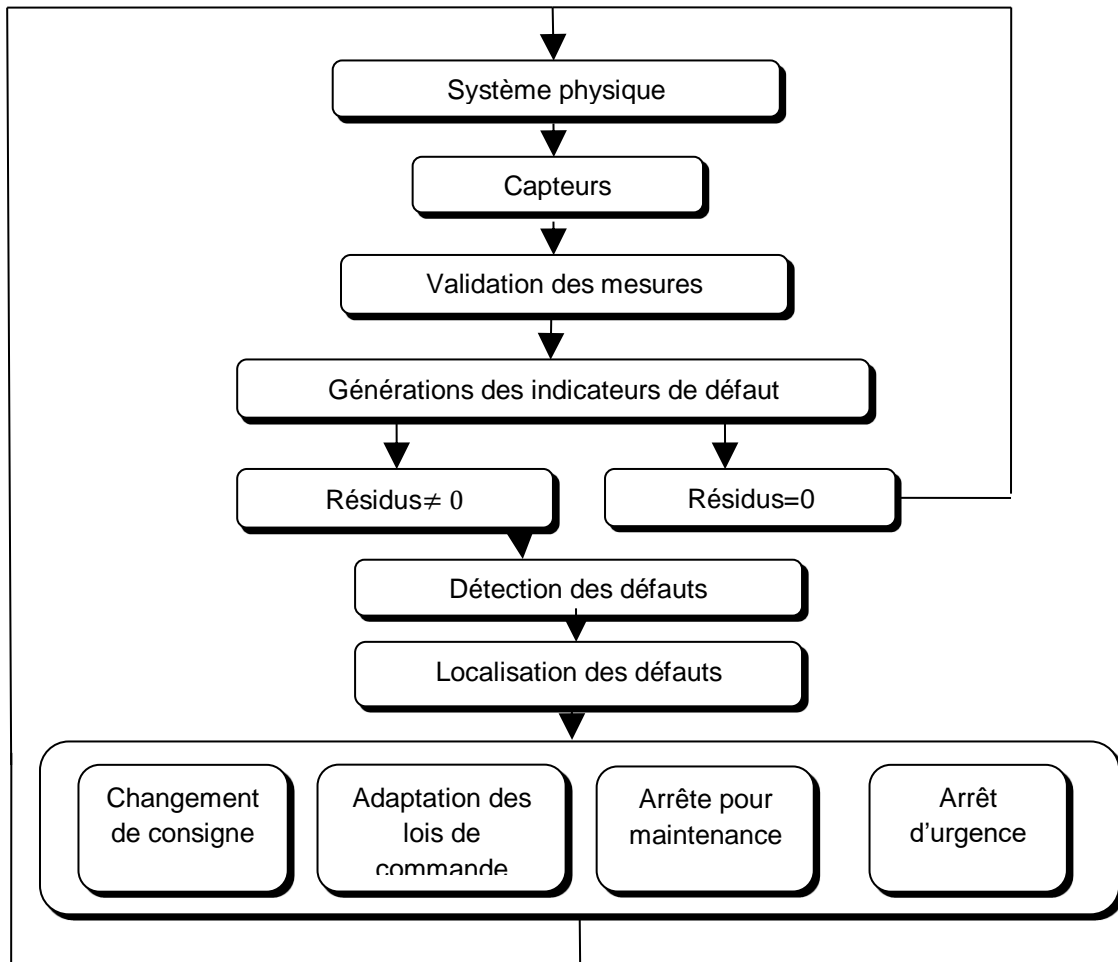
3. Modes de fonctionnement anormaux : modes dans lesquels certaines ou toutes les tâches ne sont pas terminées, y compris les modes de défaillance, les modes d'inhibition, qui sont différents états qu'un processus peut prendre sous l'influence d'une défaillance ou d'une défaillance. Ces modes spécifiques peuvent nécessiter un arrêt immédiat de l'installation, ou un basculement de la régulation vers un mode veille, voire un mode dégradé, ce qui inclut la modification de la consigne de la boucle locale, voire un changement complet de l'architecture de la régulation ou du procédé.

– **Diagnostic** : Le diagnostic est l'utilisation d'un raisonnement logique pour déterminer les causes possibles d'un dysfonctionnement sur la base d'une intégralité d'informations issues d'une inspection.

### 3. Les concepts fondamentaux du diagnostic :

Le diagnostic implique la détermination du type, de la taille, de l'emplacement et de l'heure du défaut et est une fonction de suivi de la détection des défauts, y compris des fonctions d'isolation et d'identification. Par conséquent, il s'agit d'un ensemble d'opérations conçues pour évaluer l'état d'un processus en fonction de la connaissance de l'opération du processus. Par l'observation du processus, le degré de défaillance du système, la source de ces défaillances et leurs causes sont déterminés par comparaison avec différents états de fonctionnement connus. Le but du diagnostic est d'identifier une ou plusieurs défaillances possibles du dispositif par l'étude de son impact [3].

Le diagnostic repose sur deux concepts de base présentés dans l'organigramme de la Fig. (1.1) [04], d'une part détecter les défauts au fur et à mesure qu'ils surviennent et d'autre part isoler les défauts aussi précisément que possible. Afin de prendre les mesures correctives appropriées. Si les résidus (avec défauts) ne sont pas nuls, le positionnement doit être fait pour l'étape finale (décision) pour prendre une décision sur le processus.



**Figure. I.1 :** Structure générale d'un système de diagnostic et surveillance

En général, les étapes de base du diagnostic sont les suivantes :

### 3.1. La détection d'un défaut :

Exécuter pour déterminer si le dispositif est dans un état sain ; il s'agit d'une opération logique et la solution doit être binaire (1 soit 0). La première technique de reconnaissance de défaut consiste à dupliquer les composants de l'instrument de mesure pour améliorer la qualité du système. Ceci nous servir de décider des métriques raisonnables parmi celles disponibles. Cette approche est appelée redondance matérielle. En revanche, cela coûte très cher et crée des problèmes de surcharge matérielle et de confusion. De plus, la portée de la redondance matérielle est essentiellement limitée à la défaillance du capteur. Beaucoup d'applications utiles permettent la redite matérielle des actionneurs [5]. A cet effet, la redondance analytique est très intéressante, tant financièrement que techniquement, car elle repose sur l'exploitation des relations existantes entre différentes variables mesurées ou estimées. Ceux-ci peuvent être

dérivés d'expressions mathématiques des lois de la physique ou de l'analyse statistique des mesures. Par conséquent, cela réduit le degré de redondance physique [6].

Par conséquent, le processus de détection de défaut lui-même se compose essentiellement de deux étapes [7] :

- a. Génération des résidus :** Cette phase permet de gérer un signal (résidus) pour vérifier l'accord entre le comportement observé et attendu. En l'absence d'échec, le résidu doit être nul. En présence de défauts, les résidus auront des valeurs non nulles.
- b. Évaluation résiduelle :** Cette phase analyse les indicateurs de défaillance générés et formule des règles de décision, définissant des seuils (fixes, adaptatifs ou statistiques) qui détermineront l'instant auquel l'état de marche du dispositif change.

### **3.2. La localisation de défauts :**

Le fait de définir où le système est en panne, donc de localiser ou d'isoler la panne, comprend le suivi des symptômes pour trouver tous les éléments défectueux. Ce problème est difficile à résoudre. En fait, les défaillances causées par des défauts peuvent être déterminées.

### **3.3. La reconfiguration du système :**

Ces opérations permettent d'appliquer des actions correctives au système en fonction des informations fournies dans les deux étapes précédentes, afin que le système puisse reprendre un fonctionnement normal, ou être détérioré ou stoppé pour conserver son intégrité et/ou son environnement.

## **4. Les exigences liées au diagnostic :**

Nous énumérerons une intégralité d'exigences qui ont été démontré entre les travaux de diagnostic [8] et nécessite d'être tenue en compte dès que la conception et du développement des systèmes de surveillance.

### **4.1. Exigences fonctionnelles :**

Les obligations fonctionnelles du diagnosticien falloir refléter la fonction prévue, quelles que soient les solutions techniques.

**- Rapidité de diagnostic :** Une fois qu'un défaut s'est produit, le temps nécessaire à sa détection et son isolement doit être rapide. Par conséquent, les diagnostiqueurs doivent fournir des résultats rapidement afin que les décisions appropriées puissent être prises avant que des effets indésirables sur le dispositif et/ou son environnement ne se produisent. A cet effet, les outils de diagnostic conçus pour être rapides seront certainement sensibles aux bruits sournois ou aux

perturbations (tant transitoires que temporaires), ce qui impliquerait un grand accroissement des faux positifs en marche normal, affectant le système.

**-Discernement entre les défauts :** Le diagnostiqueur doit être capable de distinguer plusieurs défauts. D'où la performance de la partie isolée du diagnostic.

**-Identification de défauts multiples :** C'est la capacité de l'outil de diagnostic à identifier plusieurs défauts qui se produisent simultanément. La difficulté de cette "simultanéité" vient de l'interaction entre les différentes conséquences de pannes survenues d'une part, et la quantité importante de calculs nécessaires pour des détections multiples d'autre part.

**-Identification de nouveaux défauts :** Un autre avantage des outils de diagnostic est la possibilité d'identifier de nouveaux défauts qui n'étaient pas répertoriés auparavant. Ceci contenu que si un défaut pas répertorié se produit, le diagnostiqueur nécessite d'abord être en mesure de le détecter (confirmer que le dispositif ne se comporte pas de façon anormale) puis de l'isoler en tant que défaut inconnu.

#### **4.2. Exigences non fonctionnelles :**

Les exigences non fonctionnelles du diagnosticien doivent tenir compte des caractéristiques que doit avoir un tel système.

- **Robustesse :** Les outils de diagnostic doivent être robustes aux bruits de mesure et aux incertitudes du modèle ou des normes de fonctionnement utilisées. Admirablement que cette robustesse permet d'être améliorée en augmentant le seuil de tolérance afin détecter une attitude aberrant ou séparer un défaut survenu, cela affecte toujours les performances du programme de diagnostic.

- **Adaptabilité :** L'outil de surveillance étant couplé au dispositif tout au long de son fonctionnement, il nécessite pouvoir s'adapter aux évolutions du dispositif et incorporer aisément de récents grandeurs ou informations obtenus par l'installation. En pratique, les exigences de fonctionnement du dispositif être apte de changer en raison de perturbations ou de modifications des conditions de fonctionnement. Par conséquent, le diagnosticien doit être capable de s'adapter à tous les changements potentiels.

- **Estimation des erreurs de diagnostic :** Il s'agit de définir la certitude de l'utilisateur terminal du dispositif dans la crédibilité de l'outil de diagnostic : ses éventuelles faute de diagnostic (faux positifs, non détectés ou sévèrement isolés). Ceci peut être fait en établissant à l'avance les estimations et les erreurs de classification que le diagnosticien est susceptible de faire, ce qui

peut améliorer leur crédibilité puisque l'opérateur aura le potentiel davantage de comprendre les synthèses du diagnosticien après ces erreurs d'estimation.

### **5. Les différentes méthodes de diagnostic :**

Cette section présente les principales méthodes diagnostiques identifiées dans la littérature [9] [10]. De nombreuses méthodes sous-tendent le travail de diagnostic, et le choix de la méthode est lié à la complexité du système ainsi qu'aux connaissances que l'on souhaite obtenir dans le système.

#### **5.1. Les méthodes de diagnostic à base de modèles :**

Les méthodes de diagnostic basées sur un modèle comparent l'altitude observée réel d'un système avec l'altitude prédit produit par le modèle de fonctionnement du système [11]. Deux types de modèles sont utilisés dans ces méthodes : les modèles quantitatifs et les modèles qualitatifs.

##### **5.1.1. Le diagnostic à base de modèles quantitatifs :**

Ce sont des approches servi par la corporation de l'automatisation, mieux connues sous le nom de Model-Based Fault Detection and Isolation (dont l'acronyme est FDI). L'utilisation d'un modèle adapté au système peut entraîner une incohérence entre l'attitude réelle du système et le comportement prédit par le modèle. Ces discordances, appelées indicateurs de défaillance ou résidus, proviennent de mesures de variables système connues et de calculs basés sur le modèle du système. Cette approche de diagnostic exiger deux phase :

- La première phase génère des résidus à partir des mesures de paramètre dispositif connues.
  - La deuxième phase est une coutume de jugement de diagnostic fondé sur ces résidus générés.
- Plusieurs conception de génération résiduelle régner, et nous décrivons la méthode la plus couramment utilisée [12]. Résidus d'orientation et de structuration :

–**Résidus directionnels** : L'idée de cette approche est d'engendrer un résidu sous la façon d'un vecteur. En existence d'une faute donnée, le vecteur résiduel est dirigé vers la direction favorisé de l'espace résiduel. Ensuite, l'étape d'isolation de défaut comporter à déterminer, à travers plusieurs orientation prédéfinies, la direction le mieux rapproché de la direction générée via le vecteur résiduel.

– **Résidus structurés** : les résidus structurés ont la propriété que lorsqu'un défaut se produit, les résidus ne répondent qu'à un sous-ensemble de défauts précis, et uniquement à un sous-ensemble des résidus. En d'autres termes, les résidus structurés sont sensibles à un sous-ensemble de défauts et insensibles à d'autres sous-ensembles de défauts.

**Approches à base d'observateurs :**

Les approches basées sur des observateurs sont les plus fréquemment employées, les débuts de ces études remontant aux années 1970 [13]. La notion habituelle est de produire un système tel qu'il puisse donner une image (ou une estimation) de certaines variables nécessaires au cycle, adaptée à des fins de diagnostic (par exemple : [14], [15]), et consiste donc à comparer la sortie mesurée avec l'estimation. La sortie est comparée à la sortie. La différence entre ces valeurs est ensuite utilisée comme résidu.

**Approche de l'espace de parité :**

Cette méthode, précédemment introduite par [16] puis développée par [17], fonctionne en transformant les équations d'un modèle pour obtenir une relation spécifique appelée Analytical Redundancy Relation (son acronyme pour RRA). Ces liaisons n'utilisent que des quantités répandues dans le système et disponibles en ligne, et les résidus sont obtenus en substituant des variables connues dans ces relations à leurs vraies valeurs (extraites du système en cours d'exécution). L'ensemble des grandeurs que peut prendre le reste du système forme alors un espace appelé espace de parité, contenant encore de taille que le reste. Dans cet espace, le vecteur de parité est déterminé tant que la grandeur résiduelle à un moment précis, qui a alors un sens en cas de panne. L'enjeu est alors de changer l'espace de parité initial en un espace capable de découpler les défauts : c'est-à-dire que chaque défaut ne représente qu'un élément du vecteur.

**5.1.2. Le diagnostic à base de modèles qualitatifs :**

Ce sont des approches couramment exploitées dans le monde de l'IA, et l'acronyme DX signifie Data Mining. Les modèles qualitatifs autorisés de tirer des résultats sur l'état du système lorsque la connaissance du processus physique est incomplète ou incertaine. Ils s'appuient sur divers aspects de connaissances qualitatives pour le diagnostic des pannes. Les méthodes qualitatives basées sur des modèles peuvent être divisées dans les catégories suivantes :

**Modèle causal des approches utilisant les diagrammes :** Un graphique dirigé signé ou un digraphe signé (GDS), comme modèle qualitatif, représente effectivement et graphiquement un système de processus. Des relations ou les modèles de Cause-effet peuvent être représentés sous forme de digraphes signés. GDS peut être obtenu à partir des équations algébriques différentielles pour le processus.

La question des arcs conditionnels dans GDS est abordée, également l'idée de GDS a été prolongée pour inclure des modèles de cinq-gamme au lieu du modèle habituel de trois-gamme utilisé dans le GDS standard. La dynamique partielle de système, les informations statistiques

sur la panne d'équipement, et les digraphes représentent le réseau de propagation d'échec pour identifier l'emplacement de défaut sont employés. Des méthodes basées sur les règles utilisant GDS ont été employées pour le diagnostic de défaut [18].

**Approche par arbre de défaillance :** Des arborescences de défaillances sont employées en analysant la fiabilité du système et la sécurité. Les approches d'arborescence de défaillances sont la technique hiérarchisée d'analyse qui décrit les relations entre les événements de base (échecs, erreurs humaines, etc.), les états intermédiaires (modes opérationnels, états environnementaux, etc.) et les événements supérieurs (incidents, accidents). Les relations sont modélisées dans une structure comme un arbre avec la porte logique ET/OU. L'arborescence de défaillances numériques peut alors être analysée les ensembles minimaux de coupe (combinaison des événements et des conditions de base qui causent l'événement supérieur) et être employée pour déterminer la probabilité de l'événement supérieur.

**Approches physiques qualitatives :** Un modèle physique détaillé est basé sur une compréhension détaillée des relations physiques et des propriétés de tous les composants du système. Un modèle détaillé peut simuler des conditions de fonctionnement normales et défectueuses du système. La connaissance de la physique qualitative dans le diagnostic des défauts s'exprime de deux manières principales. La première méthode consiste à dériver une équation qualitative à partir d'une équation appelée équation de confluence. Une autre approche de la physique qualitative consiste à dériver un comportement qualitatif à partir d'équations constantes. Ces opérations qualitatives sur diverses failles peuvent être utilisées comme source de connaissance [18].

## 5.2. Les méthodes de diagnostic à base de données :

Inversement aux approches basées sur des modèles, les approches à bases de données reposent sur de grandes quantités de données suffisantes pour représenter le système. La seule information disponible est le signal des capteurs du système. Cela signifie que ces méthodes supposent que le système peut être entièrement décrit par des observations passées et présentes. Le but de ces méthodes est de construire un modèle qui s'adapte aux paramètres collectées. Le premier problème réside donc dans la définition de la bonne structure du modèle, mais aussi dans la définition du bon calibrage entre ce modèle et le système.

### 5.2.1. Méthodes basées sur des données qualitatives :

Il existe deux manières importantes d'utiliser l'extraction de caractéristiques qualitatives :

**Système expert :** sont exploités dans des applications où l'expertise humaine est élevée et le déploiement de modèles est faible. Ce sont des systèmes basés sur des règles « si » et « ou » « alors » qui utilisent des informations heuristiques pour relier le signe aux déficits, établissant aussi plusieurs associations empiriques entre les résultats et l'origine du déficit [19]. Ces associations sont fréquemment basées sur l'expérience d'experts (appelés experts) précisément que sur l'appréhension de la structure et/ou d'attitude du dispositif. Leur fonction est de chercher des raisons d'observations par le biais d'un raisonnement sur l'addiction à travers des règles préalablement établies.

L'attrait des systèmes experts vient de leur architecture, qui utilise le langage naturel pour séparer clairement la connaissance du système des mécanismes de raisonnement. L'essentielle limite des systèmes experts demeure dans la compréhension nécessaire à leur développement, c'est-à-dire distinguer a priori les défauts du système et les transcrire en règles claires. Cependant, d'une part, la liste des défauts ne peut être exhaustive, et d'autre part, toutes les expertises ne peuvent pas être formalisées sous forme de règles.

**Analyse qualitative des tendances :** L'analyse et la prévision des tendances sont une partie importante de la surveillance et de la surveillance des processus. La modélisation des tendances peut être utilisée pour expliquer différents événements significatifs qui se produisent dans un processus, diagnostiquer les défauts et prédire les états futurs.

D'un point de vue procédural, afin d'attendre les tendances de signal trop insensibles aux changements transitoires induits par le bruit, un certain type de filtrage doit être utilisé. A titre d'exemple, lors de l'utilisation d'une identification de comportement de processus connu, une représentation de série chronologique suppose un certain comportement a priori. Alternativement, un filtre avec des coefficients de filtrage choisis a priori (comme un filtre autorégressif) peut être simplement utilisé (en précisant le degré de lissage souhaité). Les deux types de filtres souffrent du fait qu'ils ne peuvent pas bien distinguer entre une instabilité transitoire et une véritable instabilité [11].

### 5.2.2. Méthodes à bases des données quantitatives :

Les méthodes quantitatives définissent essentiellement la résolution de problèmes de diagnostic comme un problème de reconnaissance de formes. Le but de la reconnaissance de formes est de classer les points de données dans des catégories généralement prédéfinies.

Les méthodes d'extraction d'informations quantitatives peuvent être largement divisées en méthodes non statistiques et en méthodes statistiques. Les réseaux de neurones sont une classe importante de classificateurs non statistiques. L'analyse en composantes principales (ACP), les moindres carrés partiels (PCL) et les classificateurs de modèles statistiques sont les principaux éléments constitutifs des techniques d'extraction de caractéristiques statistiques [11].

Les méthodes quantitatives définissent principalement les solutions aux problèmes de diagnostic comme des questions de reconnaissance de formes. Le but de la reconnaissance de formes est de classer les points de données dans des catégories généralement définies. Les conceptions mathématiques utilisent une compréhension préalable des distributions de classe pour opérer la classification.

Les techniques d'extraction d'informations quantitatives doivent être largement divisées en méthodes non mathématique et en méthodes mathématique. Les réseaux de neurones sont une catégorie cruciale de classificateurs non mathématique. L'analyse en composantes principales (ACP), les moindres carrés partiels (PCL) et les classificateurs de modèles statistiques sont des éléments clés des techniques d'extraction de caractéristiques statistiques [11].

#### **Approches statistiques multi variées :**

Les méthodes mathématique multivariées sont des moyens efficaces qui compriment les données et réduisent leur dimensionnalité afin que les informations essentielles soient préservées et soient plus faciles à analyser que de grandes quantités de données brutes; elles sont également capables de gérer le bruit et les corrélations pour extraire efficacement les informations réelles. L'application réussie de méthodes mathématique multivariées dans le diagnostic des défauts, telles que l'analyse en composantes principales (ACP) et les moindres carrés partiels (PCM), a été largement rapportée dans la littérature. L'analyse en composantes principales est l'une des méthodes les plus étudiées pour détecter les défaillances du système [11].

**-L'analyse factorielle :** est une méthode statistique utilisée pour décrire la variabilité entre les variables observées, variables corrélées en termes d'un nombre potentiellement inférieur de variables inobservées appelées facteurs.

L'objectif de l'analyse factorielle est d'expliquer le résultat de variables dans la matrice de données en utilisant moins de variables, les soi-disant facteurs.

**-L'Analyse en composantes principales (ACP) :** transforme un certain nombre de variables éventuellement corrélées dans un ensemble de données dans un plus petit nombre de pseudo non corrélées ou variables latentes.

Cela se fait par une décomposition bilinéaire de la matrice de covariance de l'ensemble de données. Les variables non corrélées (orthogonales) obtenues sont appelées les composantes principales et elles représentent les axes obtenus par rotation du système de coordonnées d'origine suivant la direction de la variance maximale.

Les principales hypothèses de cette méthode sont que les données suivent une distribution gaussienne et que tous les échantillons sont indépendants l'un de l'autre. Puisque l'approche ACP est adoptée dans ce travail.

**-Moindre carrés partiels (MCP) :** est une réduction dimensionnelle ainsi qu'une régression technique qui trouve un nouvel ensemble de variables latentes qui maximisent la covariance entre la matrice de données d'entrée et la matrice de données de sortie. L'objectif principal ici est de rapprocher et en formes dimensionnelles réduites, ainsi que pour modéliser une relation linéaire entre eux.

**-Analyse en composantes indépendantes (ACI) :** est une statistique et informatique technique pour révéler des facteurs cachés qui sous-tendent des ensembles de variables aléatoires des mesures ou des signaux.

### **Approches classificatrices statistiques :**

Le diagnostic de défaut est principalement un souci de classification, il peut donc être inclus dans le cadre statistique classique de la reconnaissance de formes. Le diagnostic de défaut peut être réputé tant que un sujet de combinaison d'estimations instantanées d'un classificateur dans le temps en utilisant la connaissance des usages statistiques des usages d'insuffisance du dispositif [20].

### **Réseaux de neurones artificiels :**

Ils ne nécessitent pas de connaissances spécifiques en structure de processus. Ils contiennent de nombreux paramètres qui ne sont souvent pas adaptés à l'interprétation physique du système modélisé.

Les réseaux de neurones artificiels visent à produire les spécificités les plus essentiels d'attitude biologique : l'apprentissage et la généralisation.

L'apprentissage d'un réseau de neurones est l'étape où les paramètres du réseau peuvent être déterminés ou modifiés pour adopter le comportement souhaité. Le principe de base de cette

méthode de contrôle fondé sur un réseau de neurones est de chercher des liaisons entre les paramètres d'entrée et de sortie. En fonction des variables d'entrée, le réseau de neurones renverra une réaction marquée par les paramètres de sortie. Les paramètres de sortie représentent l'état opérationnel du dispositif (sain ou non) [20].

Cette approche a des propriétés très intéressantes, comme sa capacité à apprendre et à s'auto-organiser. Ceci offre des possibilités d'application spécifiquement passionnant pour l'aide au diagnostic. Afin d'identifier les défauts d'un système, les diagnostics effectués par le réseau de neurones doivent contenir des fonctionnalités et des exemples de défauts suffisamment bons pour les apprendre. Durant l'étape d'apprentissage, des preuves sont transmis au réseau d'entrée et les diagnostics correspondants sont transmis à la sortie. Le réseau s'organise et apprend à corréler les exemples qu'il voit avec son diagnostic. Après la formation, le réseau peut reconnaître non seulement des exemples appris mais aussi des paradigmes similaires à ceux-ci. Cela correspond à une certaine robustesse aux distorsions du signal causées par le bruit.

Cependant, le principal inconvénient est la capacité d'identifier le problème spécifique, principalement le choix de la structure, la taille du réseau et la manière de contrôler l'algorithme d'apprentissage spécifique au problème. Leur principal intérêt pour le diagnostic industriel, en revanche, est leur capacité à apprendre et à mémoriser de grandes quantités d'informations.

## **6. Conclusion :**

Dans ce chapitre, nous tentons d'amener en publication la terminologie utilisée dans le champ du diagnostic de pannes des systèmes productif et de présenter brièvement les différentes méthodes de diagnostic qui lui sont associées. Parmi ces techniques, nous nous intéressons spécialement aux méthodes basées sur le traitement des données, et plus spécifiquement, l'approche statistique d'analyse en composantes principales. Une intégralité d'indices d'évaluation de l'efficacité et leur influence sur l'essentiel rôle de contrôle et de diagnostic sont discutés. Dans les sections suivantes, la méthode d'analyse en composantes principales (ACP) sera décrite plus en détail, en particulier en ce qui concerne la modélisation du système.

# **Chapitre II**

## **Principe de l'analyse en composantes principales(ACP)**

---

## 1. Introduction :

Le contrôle mathématique des processus est principalement basé sur des méthodes multivariées. Néanmoins, appliquer ces méthodes à de grands systèmes (avec un énorme nombre de variables) devient compliqué, voire difficile. De plus, les items des statistiques descriptives univariées et bi-variées ne sont pas informatifs quand les variables sont scrutées ensemble. Ce travail concomitant des variables est l'objet de l'analyse en composantes principales (ACP). Cette dernière est une méthode évocatrice servie pour examiner les liaisons qui trouvent entre des variables sans avoir d'aucune structure préalable [21]. Son objectif est d'identifier des structures d'interdépendance entre des observations multivariées pour acquérir une représentation descriptive ou compacte de ces dernières.

Son utilité se limite à projeter des données sur distincts axes factoriels et à calculer les écarts à partir de ces axes, en tant qu'outil de détection des valeurs absurde. Dès que les années 1970, de multiples études sont présenté par l'utilisation de l'ACP tant que mécanisme de modélisation de processus à partir duquel des modèles peuvent être dérivés [21, 22, 23]. Le modèle peut estimer des variables ou des paramètres du processus à contrôler.

En fait, l'ACP est une projection orthographique linéaire qui projette des observations multidimensionnelles figuré dans un espace à  $m$  dimensions (où  $m$  est le nombre de variables d'observation) vers un sous-espace de dimension inférieure ( $\ell < m$ ) en maximisant la projection de la variance. L'ACP est un moyen de modélisation des liaisons linéaires entre divers paramètres qui décrivent le comportement d'un processus. La modélisation par l'ACP consiste d'abord à normaliser les données, puis à déduire les grandeurs de la matrice de corrélation des données et des vecteurs propres afin évaluer les grandeurs du modèle de l'ACP, et finalement à déterminer la structure des données. Le modèle doit déterminer le nombre optimal de composants pour aider à le construire. A cette fin, un critère de choix de la quantité de composants est proposé [23]. Il est adapté pour détecter et localiser les anomalies possibles au niveau d'un dispositif et est une technique d'analyse de données multivariée [24].

Ce chapitre décrit la modélisation par l'ACP. Avant de nous y plonger, nous devons d'abord comprendre certains concepts statistiques liés à cette méthode.

Cette approche est entièrement fondée sur l'utilisation des mesurages d'entrée et de sortie du dispositif. Une matrice de données est ensuite construite à partir de ces mesures. En fractionnant la matrice de données en sommes singulières, l'ACP divise la matrice en deux parties. L'un

contient les principales valeurs singulières et représente les données utiles et l'autre contient les valeurs singulières restantes et est supposé négligeable et représente le bruit [25].

Récemment, plusieurs recherches sur l'utilisation de la technique de l'ACP dans le domaine de la détection des lésions sont apparues dans la littérature [26, 27, 28, 29].

Ce chapitre présente la modélisation par l'ACP. Avant de plonger, nous devons d'abord comprendre certains concepts statistiques liés à cette méthode.

## 2. Notions de base :

En cette partie, nous introduisons certaines notions de base utilisés par l'analyse en composantes principales (ACP).

### 2.1. Tableau de données :

L'ACP offre par un tableau de données (appelé une matrice) voir figure (II.1), la représentation géométrique servir de constituer un nuage dit de points, lequel chaque point est coordonné selon sa position dans le plan, voir figure (II.1) .2) et (II.3).

$$\mathbf{X} = \begin{matrix} & \begin{matrix} v_1 & v_2 & \longrightarrow & v_m \end{matrix} & \\ \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{pmatrix} & \begin{matrix} \vartheta_1 \\ \vartheta_2 \\ \downarrow \\ \vartheta_n \end{matrix} \end{matrix}$$

**Figure. II.1.** Structure d'un tableau de données.

### 2.2. Variable :

Toute colonne de la matrice de données est nommée une variable, et toute variable (ou colonne) est un vecteur contenant «  $n$  » échantillons ou paramètres qui sont les grandeurs de cette variable pour toute observation.

### 2.3. Observation :

Chaque ligne de la matrice de données est nommée une observation, qui est un vecteur (ligne) de «  $m$  » échantillons qui sont les grandeurs des  $m$  observations pour ces grandeurs.

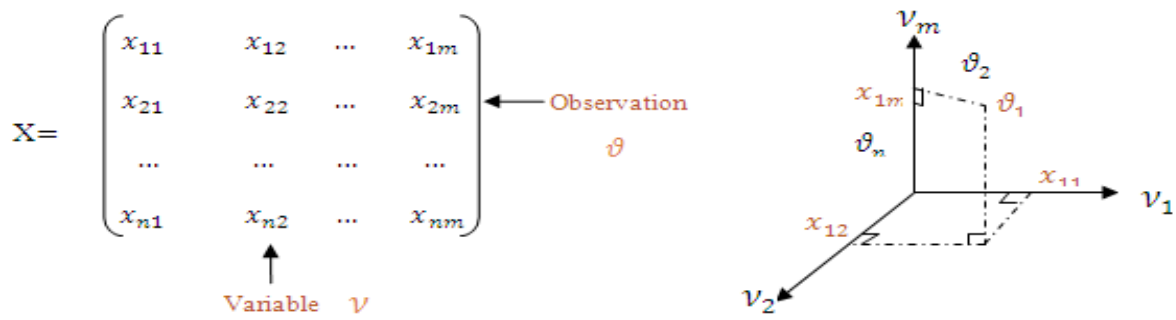


Figure. II.2. Représentation géométrique des observations.




Figure. II.3. Nuage des points dans le cas m=3.

Géométriquement, la matrice peut être assimilée à un nuage de  $N$  points à l'espace  $\mathbb{R}^m$  ou un nuage de  $m$  points dans  $\mathbb{R}^N$ . En effet, la démarche de l'ACP consiste à réajuster le nuage des  $N$  points par un sous espace de dimension  $\ell < m$ .

**2.4. Moyenne :**

La moyenne arithmétique d'une série de nombre réel est la somme des valeurs divisé par le nombre des valeurs.

La moyenne d'une variable  $v$  où  $v_j^T = [x_{1j} \ x_{2j} \ \dots \ x_{nj}]$ ,  $i = [1 \dots n]$  et  $j = [1 \dots m]$

$$\bar{v}_j = \frac{1}{n} \sum_{i=1}^n x_{ij} \tag{II.1}$$

**2.5. Variance :**

Cette quantité est déterministe et continuellement supérieure ou équivaux à zéro, et elle peut être interprétée comme une mesure de la fluctuation (dispersion) d'une variable aléatoire alentour de sa moyenne.

Si  $j = [1 \dots m]$  et  $i = [1 \dots n]$  alors la variance de chaque variable à l'équation suivante :

$$\sigma_j^2 = \frac{1}{n} \sum_{i=1}^n (x_{ij} - \bar{v}_j)^2 \tag{II.2}$$

### 3. Principes de l'analyse en composantes principales (ACP) [30] :

L'objectif de l'ACP est de déterminer la relation linéaire qui subsiste entre les différentes variables du système. L'identification d'un modèle ACP commence par la reconstruction d'une matrice récipiente toutes les informations disponibles, sans différenciation entre les entrées et les sorties du dispositif. Ces informations sont présumées être collectées sur un dispositif stable et fonctionnel (données « saines »).

Considérons un vecteur de données aléatoires  $x = [x_1, \dots, x_m]^T \in \mathfrak{R}^m$  de moyenne nulle  $\varepsilon\{x\} = 0$ , et de matrice de covariance ou d'autocorrélation  $\Sigma = \varepsilon\{x^T x\} \in \mathfrak{R}^{m \times m}$ .

En ACP, un vecteur propre  $t \in \mathfrak{R}^\ell$  est joint à chaque vecteur de données, ce qui améliore sa reproduction dans le sens de minimiser l'erreur d'estimation de  $x$  ou de maximiser la variance  $t$ .

$$P_{opt} = \arg_p \min J_e(P) = \varepsilon(\|x - \hat{x}\|) = \text{trace}(\Sigma) - \varepsilon\{x^T x\} \quad (\text{II.3})$$

Où :  $J_e$  montre le critère d'erreur d'estimation,

$\hat{x}$  représente l'estimation d'un vecteur de données  $x$ .

A souligner que la trace d'une matrice carrée est indiquée par la somme de ces substances diagonaux. La matrice de covariance  $\Sigma$  devenir autonome de la matrice de grandeurs  $P$ , pour diminué  $J_e$ , il est mieux de maximiser le deuxième terme de son expression,  $J_v$ :

$$P_{opt} = \arg_p \max J_v(P) = \varepsilon\{x^T x\} \quad (\text{II.4})$$

Où  $J_v$  la variance des projections  $t_j$  des données.

Un souci de l'ACP possible, en termes de maximisation de la variance des projections de données, est celui-ci de définir des vecteurs propres de la matrice de covariance  $\Sigma$ .

Les vecteurs  $t$  et  $x$  voient attachés par la transformation linéaire  $t = P^T x$ . Parmi elles, la matrice de transformation  $P \in \mathfrak{R}^{m \times \ell}$  évalue la clause d'orthogonalité  $P^T P = I_\ell$ . Les colonnes de la matrice  $P$  constituent les vecteurs de fondement orthonormés du sous-espace  $\mathfrak{R}^\ell$  de la description simplifiée des données.

Par conséquent, une transformation linéaire est similaire à la projection d'un espace de données à  $m$  dimensions dans un sous-espace orthogonal à  $\ell$  dimensions.

Les entrées ( $j = 1, \dots, \ell$ ) du vecteur propre  $t$  constituer les entrées jetées du vecteur de données  $x$  dans ce sous-espace.

Au vision de l'ACP, la projection  $P$  est idéale si l'erreur quadratique estimée du vecteur de données  $x$  est minimale ou si la variance de  $t$  est maximale.

Sous l'hypothèse nulle de la moyenne du vecteur de données  $x$ , la moyenne de la projection  $t$  est également vide :  $\varepsilon\{t\} = p^T \varepsilon\{x\} = 0$ . Ainsi, la variance de la projection,  $var\{t\}$ , est identifiée par sa valeur quadratique :

$$\begin{aligned} var\{t\} &= \varepsilon\{(t - \varepsilon\{t\})^2\} = \varepsilon\{t^2\} = \varepsilon\{(p^T x)(x^T p)\} \\ &= p^T \varepsilon\{xx^T\}p = p^T \Sigma p \end{aligned} \quad (\text{II.5})$$

Notons que  $\lambda_1, \dots, \lambda_m$  sont les  $m$  valeurs propres de la matrice de covariance  $\Sigma$ , et  $p_1 \in \mathfrak{R}^m, \dots, p_m \in \mathfrak{R}^m$  les  $m$  vecteurs propres qui leur sont joints. On peut alors écrire :

$$\Sigma p_i = p_i \lambda_i, \quad i = 1, \dots, m \quad (\text{II.6})$$

Où sous forme matricielle :

$$\Sigma P = P \Lambda \quad (\text{II.7})$$

Avec  $P = (P_1 P_2 \dots P_m) \in \mathfrak{R}^{m.m}$  et  $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_m) \in \mathfrak{R}^{m.m}$ .

La notation diagonale  $(\lambda_1, \lambda_2, \dots, \lambda_m)$  fait référence à une matrice carrée desquels seuls les objets non nuls sur la diagonale ont pour valeurs  $\lambda_1, \dots, \lambda_m$ . Imposer une contrainte de norme unitaire sur cette propriété fait que les vecteurs propres  $p_i (i = 1, \dots, m)$  constituent une assiette orthonormée :

$$P^T P = P P^T = I_m \quad (\text{II.8})$$

La transposée d'une matrice carrée orthogonale correspond à son inverse, soit  $P^T = P^{-1}$ . Par conséquent, l'équation matricielle (II.7) a la forme équivalente :

$$P^T \Sigma P = \Lambda \quad (\text{II.9})$$

De la comparaison des relations (II.5) et (II.9), il résulte :

$$var\{t\} = \varepsilon\{t^2\} = p_i^T \Sigma p_i = \lambda_i, \quad i = 1, \dots, m \quad (\text{II.10})$$

L'expression (II.10) indique que les valeurs propres de la matrice de covariance  $\Sigma$  indiquent la variance de la projection  $t_i$  des données dans la direction représentée par les vecteurs propres  $p_i (i = 1, \dots, m)$ .

En résumé, le chemin dans laquelle la variance projetée du vecteur de données  $x$  est la plus grande est indiquée par le vecteur propre  $p_i$  ressemblant à la plus grande valeur propre  $\lambda_i$ .

Une projection  $t = P^T x$  d'un vecteur donné  $x \in \mathfrak{R}^m$  est un nouveau vecteur de variables de transformation indépendantes dont la variance est les valeurs propres de la matrice  $\Lambda$  récipient les valeurs propres  $\ell$  de la matrice  $\Sigma$  en ordre dégradant.

Les composantes principales  $t_i$  du vecteur de données  $x$  sont déterminer comme :

$$t_i = p_i^T x = x^T p_i \quad i = 1, \dots, m \quad (\text{II.11})$$

La transposée matricielle du type relation de projection (II.11) fournit une expression mathématique pour l'analyse en composantes principales du vecteur de données  $x$  :

$$t = P^T x \quad (\text{II.12})$$

Où  $P^T$  indique la matrice de projection parfaite des données.

Il est simple d'estimer un vecteur de données  $x$  à base de son vecteur de composante principal joint  $t$ . Multipliez simplement chaque côté de l'équation (II.12) par  $P$  comme suit :

$$x = Pt = \sum_{i=1}^m t_i P_i \quad (\text{II.13})$$

Par conséquent, l'ACP est intéressant pour diminuer la dimensionnalité de la représentation des données ou pour simplifier la compression des données.

Par conséquent, la dimensionnalité de la représentation des données peut être réduite en ne gardant que les termes  $t_j p_j$  ( $j = 1, \dots, \ell$ ) liés à  $\lambda_j$  de l'expression (II.13), où  $\ell$  est le plus grand.

Le  $\hat{x}$  estimé pour le vecteur de données  $x$  est alors décrit par l'équation simplifiée :

$$\hat{x} = \sum_{j=1}^{\ell} t_j P_j = \sum_{j=1}^{\ell} (P_j^T x) P_j \quad (\text{II.14})$$

Ainsi, les données sont encodées avec  $\ell$  composantes principales  $t_1, \dots, t_{\ell}$ , qui présente la plus grande variance par rapport aux  $m$  valeurs descriptives  $x_1, \dots, x_m$  qui étaient requises à l'origine. La détérioration d'information due à la diminution de la dimensionnalité de la reproduction pour toute vecteur de données  $x$  est modérée par la différence  $e$  entre sa représentation fidèle (II.13) et approximative (II.14) :

$$e = x - \hat{x} = \sum_{i=\ell+1}^m t_i P_i \quad (\text{II.15})$$

Par conséquent, le vecteur de données  $x$  peut être montré par :

$$x = \hat{x} + e \quad (\text{II.16})$$

Ci-dessous nous utiliserons  $\hat{P}$  pour noter  $\ell$  la matrice des initiaux vecteurs propres, d'où :

$$\hat{t} = \hat{P}^T x \quad (\text{II.17})$$

Si on note par  $\hat{P}$  les premiers  $\ell$  vecteurs propres, et  $\tilde{P}$  ceux les dernières  $(m - \ell)$  vecteurs propres.

Où  $\hat{t}$  est le vecteur de la première composante principale, donc :

$$\hat{x} = \hat{P} \hat{P}^T x = \hat{C} x \quad (\text{II.18})$$

Où la matrice  $\hat{C} = \hat{P} \hat{P}^T$  constitue le modèle ACP du système.

Ainsi, le vecteur  $\tilde{x}$  s'écrit :

$$\tilde{x} = e = \tilde{C} x = (I_m - \hat{C}) x \quad (\text{II.19})$$

telque:  $\tilde{C} = \tilde{P} \tilde{P}^T$

Donc le vecteur de mesures  $x$  se décompose en deux vecteurs estimé  $\hat{x}$  et d'erreur  $\tilde{x}$  :

$$x = \hat{x} + \tilde{x} \quad (\text{II.20})$$

Les deux matrices  $\hat{C}$  et  $\tilde{C}$  sont symétriques [30] :


$$\hat{C} = \hat{C}\hat{C}^T \text{ et } \tilde{C} = \tilde{C}\tilde{C}^T \quad (\text{II.21})$$

et elles sont idempotentes [30] ; les deux vecteurs d'estimation et d'erreurs sont liés par :

$$\hat{x}^T \tilde{x} = x^T \hat{C} (I_m - \hat{C}) x = 0 \quad (\text{II.22})$$

Par conséquent, le modèle décompose l'espace de données en deux sous-espaces orthogonaux, comme le montre la Figure (II.4) [31] :

- l'espace principal de représentation (Principal Component Subspace PCS) est constitué par les  $\ell$  premiers vecteurs propres. Il contient les variations significatives des données.
- l'espace résiduel (Residual Subspace RS) est représenté par les  $(m - \ell)$  finaux vecteurs propres. Il contient essentiellement les bruits affectant les mesures et les variations dues aux erreurs du modèle.



**Figure. II.4.** Décomposition du vecteur de mesures.

Dans la figure (II.5) nous présentons l'algorithme de l'ACP qui résume le principe de l'analyse en composante principale [54].

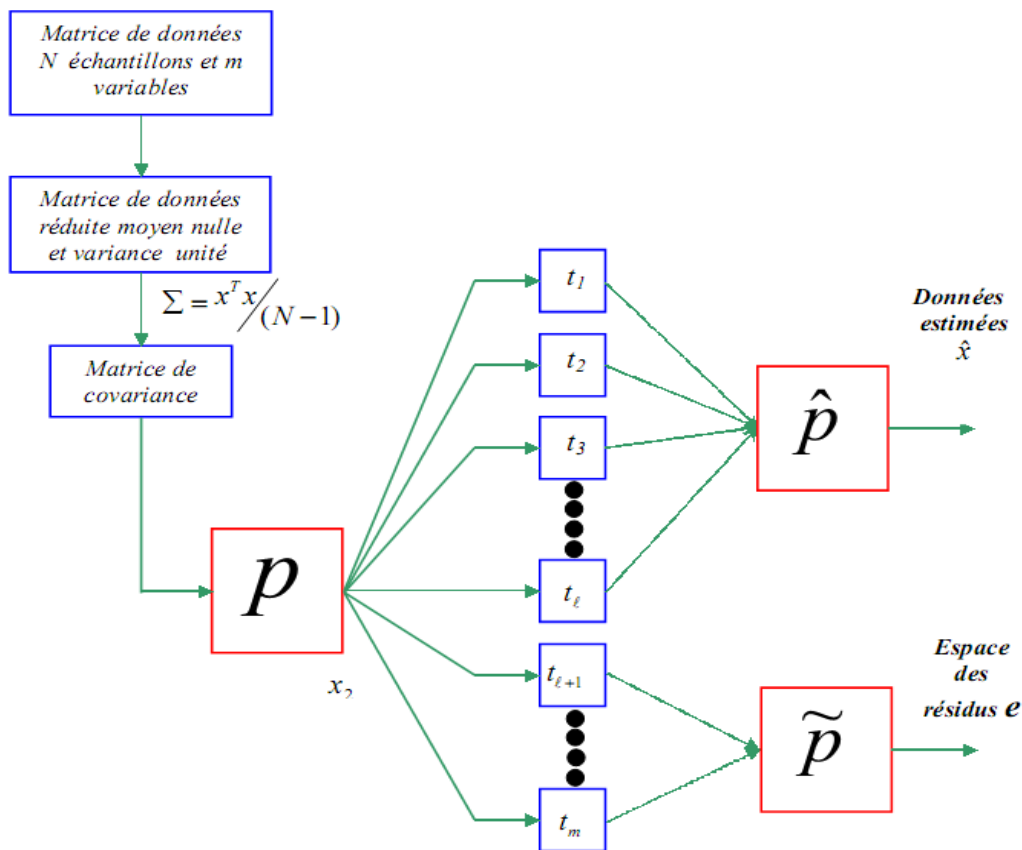


Figure. II.5. Algorithme de l'ACP.


#### 4. Modélisation par l'ACP Linéaire :

L'analyse en composantes principales (ACP) est réputé tant que une méthode de modélisation qui est utilisée afin acquérir un modèle d'un dispositif. Pour trouver de tels modèles, nous avons nécessité d'une assiette de données de variables qui suit une composition de mesures réalisé sur la marche normale du système. En règle générale, le processus de reconnaissance du modèle comprend l'estimation des grandeurs du modèle après la normalisation des données, suivie de la sélection de la structure fixe et enfin de la validation du modèle.

##### 4.1. Traitement des données (normalisation de la matrice de données) :

Souvent, les informations sont exprimées dans différentes unités et échelles. Pour ce faire, nous centrons d'abord les données. Ensuite, pour fournir les résultats distinct des unités servies pour les diverses variables, ces ultimes ont été réduites par rapport à leurs variances respectives [32]. Les données aussi acquis sont centrées et réduites de manière à ce que leur moyenne et leur variance unitaire soient nulles. Pour cela, les données brutes doivent être prétraitées avant d'être utilisées dans l'analyse en composantes principales (ACP).

Nous allons d'abord essayer de centrer la matrice de données sur le centre de gravité du nuage de points, car le point 0 correspondant au vecteur de toutes les coordonnées nulles n'est pas évidemment une origine convenable, puisque si les associées du nuage de points sont élevées, le nuage est écarté de cette origine, il est donc nécessaire de déterminer une origine alliée au nuage de points lui-même, comme le présente dans la figure (II.6).



**Figure. II.6.** Illustration graphique de l'effet du centrage d'une distribution bi-variable  
(a) Distribution d'origine (b) Centrage de cette distribution.

Soit  $X$  une matrice de données de la configuration :

$$X = [x_{i,j}]_{i=1,n}^{j=1,m} \quad (\text{II.23})$$

Avec  $x_{i,j} \in \mathfrak{R}$ .

Alors le centre de gravité  $G$  du nuage variable est la position dont les associées sont la valeur moyenne de la variable :

$$G = \left( \bar{v}_1 = \frac{1}{n} \sum_{i=1}^n x_{i1} \quad \bar{v}_2 = \frac{1}{n} \sum_{i=1}^n x_{i2} \quad \dots \quad \bar{v}_m = \frac{1}{n} \sum_{i=1}^n x_{im} \right) \quad (\text{II.24})$$

Les données sont centrées et réduites par l'opération suivante :

$$X^{(N)} = (X - \bar{v}_j) / \sigma_j \quad (\text{II.25})$$

Où  $\bar{v}_j$  la moyenne et  $\sigma_j^2$  est la variance de la  $j^{\text{ème}}$  variable.

$X^{(N)}$  représente la récente matrice de données normalisée. Cela permet aux résultats d'être distincts des unités des différentes données.

Ceci est fait pour empêcher que quelques variables ne dominent l'analyse simplement parce qu'elles sont relativement importantes par rapport à d'autres. Une fois les données centrées et mises à l'échelle, la matrice de corrélation des données  $\Sigma$  est mesurée quand suit :

$$\Sigma = \frac{1}{N-1} X^T X \quad (\text{II.26})$$

L'ACP permet à décomposer la matrice  $X$  de la manière suivante :

$$X=TP^T \text{ et } T=XP \tag{II-27}$$

Où les colonnes de la matrice T sont les composantes principales et les colonnes de P sont les vecteurs propres normalisés de la matrice de corrélation de la matrice.

Nous avons pour toute valeur de  $\ell$  comprise entre 1 et  $m- \ell$  :

$$X = \sum_{i=1}^m t_i p_i^T = \sum_{i=1}^{\ell} t_i p_i^T + \sum_{i=\ell+1}^m t_i p_i^T = \hat{T}\hat{P}^T + \tilde{T}\tilde{P}^T \tag{II-28}$$

$$= \hat{X} + \tilde{X} \tag{II-29}$$

Où les  $t_i$  et  $p_i$  sont, respectivement, les colonnes de T et de P .


Les vecteurs de P forment une base orthonormée de  $\mathfrak{R}^m$ . Si on ne garde que les premières composantes principales, on peut décomposer  $\mathfrak{R}^m$  en deux sous espaces orthogonaux : le sous espace de composantes principales (PCS, principal component subspace,  $\varphi_p$ ), engendré par les vecteurs  $p_1, \dots, p_{\ell}$  et le sous espace résiduel (RS, residual subspace,  $\varphi_r$ ), engendré par les vecteurs  $p_{\ell+1}, \dots, p_m$ . Les matrices  $\hat{C}$  et  $\tilde{C}$  sont, en fait, les matrices de projection sur ces deux espaces, on a alors : pour un instant k, un vecteur de mesure peut être donné :

$$x = \hat{x} + \tilde{x} = \hat{x} + e \tag{II-30}$$

avec  $\hat{x} = \hat{C}x, \tilde{x} = \tilde{C}x$  et  $\tilde{x}^T \hat{x} = 0$

$\hat{x}$  et  $\tilde{x}$  sont la partie modélisation et la partie résiduelle du vecteur x.

La figure (II.7) représente les observations (x) et des parties modélisées et résiduelle de l'un d'entre elle dans le cas de deux variables (dimension).



**Figure. II.7.** Représentation d'observations et des parties modélisée et résiduelle de l'une d'entre elles (x) dans le cas de deux variables (m=2).

**4.2. Estimation des paramètres du modèle :**

Les estimations des grandeurs du modèle ACP sont résumées sous forme d'estimations des valeurs propres et des vecteurs de la matrice de corrélation  $\Sigma$ . Décomposer ce dernier en valeurs singulières peut s'écrire :

$$\Sigma = PAP^T = \sum_{i=1}^m \lambda_i p_i p_i^T \quad (\text{II.31})$$

Où  $p_i$  est le  $i^{\text{eme}}$  vecteur propre de  $\Sigma$  et  $\lambda_i$  est la valeur propre ressemblante.

L'estimation des grandeurs d'un modèle PCA se décompose en trois étapes :

- **Étape 1** : Calculer la matrice de corrélation.

Cette matrice fournit le premier élément décrivant l'association qui existe entre les variables.

- **Étape 2** : Déterminer les valeurs propres.

Les valeurs propres (ou inerties liées aux facteurs) sont les variances des coordonnées des points individuels sur les axes correspondants. Par conséquent, ce sont les indices de dispersion des nuages individuels dans les directions définies par les axes. Il est souvent intéressant d'observer la décroissance des valeurs propres.

- **Étape 3** : Calculer les vecteurs propres pertinents.

Ces vecteurs propres représentent l'axe factoriel du nouvel espace et sont des combinaisons linéaires des variables initiales. Les composantes principales sont alors définies axe par axe à partir du vecteur propre joint à la plus grande valeur propre.

L'examen des diagrammes factoriels permet de visualiser les corrélations entre les variables et d'identifier les groupes d'individus qui prennent la même valeur pour la même variable.

Cependant, pour l'estimation des variables d'origine, seules les composantes comportant des informations importantes doivent être conservées afin de déterminer les distinctes variables. Pour cette logique, la suite sera sacrée à la détermination de la structure du modèle ACP.

#### 4.3. Détermination de la structure du modèle :

L'ACP trouve une estimation de la matrice de données originelle  $x$  par une matrice de échelon amoindri générée par dissociation en valeurs singulières. Les problèmes qui se posent sont largement discutés dans la littérature et portent sur la sélection du nombre de composants principaux à conserver. Un certain nombre de règles ont été offertes dans la littérature pour définir le nombre de composants à conserver [33].

Le choix de la quantité de CPs à conserver est l'étape la plus essentiel du modèle de reconnaissance ACP. La plupart des méthodes existantes pour déterminer le nombre de PC utilisent une décroissance exponentielle monotone [34].

Dans le domaine de l'ACP appliquée au diagnostic, la quantité de CPs a une influence significative sur toute phase de l'algorithme et peut être implémenté de manière répétée pour identifier plusieurs pannes qui ne se produisent pas simultanément. Il est inhabituel d'avoir plus d'un défaut simultanément. Ce fait permet de distinguer entre la défaillance d'un élément et une

condition de fonctionnement anormale où un groupe de variables s'écarte de la corrélation normale établie par le modèle de la composante principale [35]. La fiabilité de l'algorithme de diagnostic par ACP, dépend de la définition de la structure du modèle.

Cependant, dans le contexte de l'ACP appliquée au diagnostic, la quantité de composants a une incidence significative sur toute phase du processus de détection et d'isolation. Si à peine de composantes sont exploitées, on détresse d'affaiblir les indications comprise dans les données initiales en propulsant quelques grandeurs dans le sous-espace résiduel, créant une erreur de modélisation qui contamine les résidus, entraînant des faux positifs. En revanche, si de nombreuses composantes sont utilisées, la composante conservée (celle correspondant à la valeur propre la plus basse conservée dans le modèle) a le potentiel de véhiculer du bruit, ce qui n'est pas souhaitable. De plus, il existe un risque de pannes non détectées. Dans ce qui suit, nous décrivons certains des critères utilisés pour déterminer le nombre de composants et aussi déterminer le modèle.

#### 4.3.1. Pourcentage cumulé de la variance totale (PCV) :

L'approche est fondée sur la variance de la variable de mesure, en notant que toute composante principale représente une partie de la variance de la mesure du processus à l'étude. Les valeurs propres de la matrice de corrélation sont une mesure de cette variance et savent donc être minées pour choisir la quantité de composantes principales. Pour la détermination de  $\ell$ , nous devons définir le pourcentage de variance totale que nous voulons garder. La quantité de composants est alors la quantité minimum qui atteint ou dépasse ce pourcentage ; les composants sont sélectionnés par ordre de variance décroissante.

Le pourcentage de variance expliqué par les initiales composantes  $\ell$  est bénéfique par :

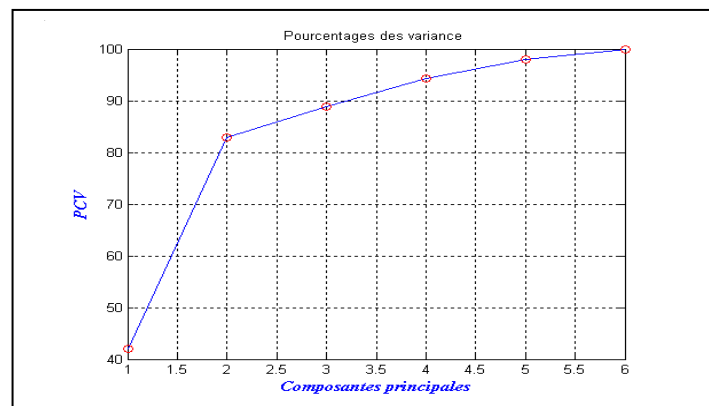
$$PCV(\ell) = 100 \left( \frac{\sum_{j=1}^{\ell} \lambda_j}{\sum_{j=1}^m \lambda_j} \right) \% \quad (\text{II.32})$$

Même si le PCV est l'une des méthodes les plus utilisées, un problème majeur émerge du fait que le pourcentage de la variance cumulée doit être fixé à l'avance. Habituellement, un pourcentage compris entre 80 et 85% est utilisé dans un certain contexte tandis que certaines références encouragent l'utilisation de pourcentages supérieurs à 85%, mais la sélection

optimale qui garantit la meilleure représentation des données est dépendante des données et toujours hors de portée.

La valeur optimale du PCV qui est la plus représentative des données peut varier considérablement en raison de la quantité de bruit présente dans la mesure et de la redondance entre différentes variables. En l'absence de règles claires, le PCV s'est avéré subjectif et le fait que le pourcentage cumulé augmente avec le nombre de composants rend la méthode ambiguë. De plus, alors que nous voulons conserver autant de variance que possible, nous voulons préserver autant que possible les composants principaux et garder le bruit à l'écart. Par conséquent, la décision est de négocier la quantité de variance à conserver et le nombre de composants à conserver [36].

La figure (II.8) montre la procédure à accompagner pour obtenir le modèle d'un dispositif en fonctionnement sain, à l'assistance de l'approche du pourcentage cumulé de la variance totale.

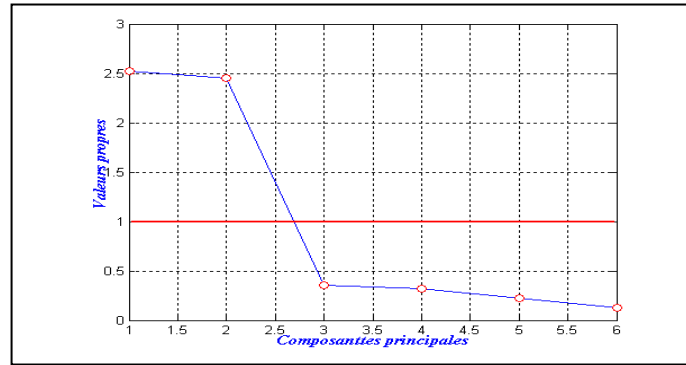


**Figure.II.8.** Exemple illustratif de la méthode variance cumulée en fonction des composantes principales.

#### 4.3.2. Moyenne des valeurs propres :

Cette méthode comportée à ne considérer que les composantes dont les valeurs propres soient supérieures à la moyenne arithmétique de l'entières les valeurs propres. Puisque elles sont considérées comme plus instructives que les variables originales. Néanmoins, l'utilisation de ce test conduit généralement à prendre en compte un grand chiffre de composants, duquel certains peuvent ne pas avoir d'importance.

La figure (II.9) donne un exemple d'évolution des valeurs propres sous forme de fonctions composantes principales.



**Figure. II.9.** Évolution des valeurs propres en fonction des composantes principales.

### 4.3.3. Critère de validation croisée :

La validation croisée est une technique assez appréciée, simple mais coûteuse en calculs. Le procédé estime des mesures sur la base d'un ensemble de données de validation dans un modèle calculé à l'aide d'un autre ensemble de données identifiées, et compare ces estimations aux valeurs mesurées. À la suite Wold [37], Eastment et Krzanowski [38], la quantité de composantes principales retenues est idéale si l'estimation globale de la métrique  $x_i(k)$  n'est plus significativement optimisée par l'addition d'une autre composante.

Cette procédure de validation croisée est fondée sur la minimisation de la quantité PRESS, qui montre la somme des erreurs au carré parmi les données observées et les estimations du modèle obtenues.

$$PRESS = \frac{1}{Nm} \sum_{k=1}^N \sum_{i=1}^m (\hat{x}_i(k) - x_i(k))^2 \quad (\text{II.33})$$

$N$  : est la taille de l'ensemble de validation.

Une variété réduite de l'algorithme pour amener la quantité de composantes principales par validation croisée est comme suit :

1. diviser les données en ensemble d'identification et en ensemble de validation,
2. effectuer une ACP avec  $\ell$  composantes ( $\ell = 1, \dots, m$ ) sur le jeu d'identification et déterminer les critères ressemblant sur le jeu de validation  $PRESS(1), \dots, PRESS(m)$ ,
3. la  $\ell$  ème composante où le minimum PRESS se produit sera le dernier composant retenu, et  $\ell$  sera le nombre de composants principaux retenus.

Bien que la méthode de validation croisée soit réputée, elle ne rien envisager comme supérieure aux autres normes. Besse et Ferré [39] montrent théoriquement que, bien que coûteuse en

calcul, l'utilisation de la validation croisée dans l'ACP ne fournit pas de règles de décision plus objectives.

#### 4.3.4. Critère de la variance de l'erreur de reconstruction :

Sur la base des travaux présentés par Dunia et al [40], un autre critère de choix de la quantité de composantes principales est proposé fondé sur la minimisation de la variance de l'erreur de reconstruction (aussi appelée variance non reconstruite VNR).

##### 4.3.4.1. Reconstruction linéaire :

Leur notion comporte à évaluer une des variables du vecteur de données  $x(k)$  à un moment donné, notée  $x_i(k)$ , en minant entières sauf la  $i^{eme}$  variable  $x_j(k)$ , où  $j \neq i$ . Pour le cas de chaque variable estimée ( $\hat{x} = z_i$ ), bien reconstruite, il y a toujours une variation partielle ou partielle de celle-ci, et ne peut être reconstruite qu'à partir d'autres variables  $x_j(k)$ . Ce qui n'est pas capturé dans chaque mesure utilisant le modèle PCA et d'autres variables est la variation non reconstruite, également connue sous le nom d'erreur de reconstruction.

L'information véhiculée par la variable  $i$  est estimée à l'aide de toutes les autres mesures des différentes variables comme suit :

$$z_i = \frac{[c_{-i}^T \ 0 \ c_{+i}^T]}{1 - c_{ii}} x \quad (C_{ii} \neq 1) \quad (\text{II.34})$$

Où les indices  $+i$  et  $-i$  désignent le vecteur formé à partir du premier ( $i - 1$ ) et du dernier ( $m - i$ ) objets du vecteur d'origine. Dans cet état, la reconstruction d'une telle variable se traduirait par un vecteur d'observation reconstruit comme suit :

$$x_i = [x_1 \dots z_i \dots x_m] \in \mathfrak{R}^m \quad (\text{II.35})$$

L'équation de la reconstruction  $x_i$  du vecteur de données  $x$  sur une direction  $\xi_i \in \mathfrak{R}^m$  est donnée par :

$$x_i(k) = (I_m - \xi_i (\xi_i^T \tilde{C} \xi_i)^{-1} \xi_i^T \tilde{C}) x(k) \quad (\text{II.36})$$

Où  $\xi_i$  est la direction de la variable reconstruite. Donc,  $\xi_i = [0 \ 0 \ 0 \ 1 \ 0 \ 0 \ 0]$  est la  $i^{eme}$  colonne de la matrice identité, dont 1 représente la variable reconstruite par des autres variables (avec 0). De plus, la  $i^{eme}$  variable ne peut être reconstruite que sous la condition que  $\xi_i^T \tilde{C} \xi_i \neq 0$ . Cela signifie que le vecteur  $\tilde{C} \xi_i$  n'est pas nul (il y a une variable projetée dans le sous-espace résiduel). L'erreur de reconstruction est la diversité entre une variable et ses estimations (reconstructions) obtenues à partir d'autres variables et d'un modèle ACP. En d'autres termes, l'erreur de reconstruction est la section du changement de mesure qui ne peut pas être reconstruite avec d'autres variables. L'erreur de reconstruction pour la  $i^{eme}$  variable est déterminée comme :

$$\xi_i^T (x - x_i) = (\xi_i^T \tilde{C} \xi_i)^{-1} \xi_i^T \tilde{C} x \quad (\text{II.37})$$

Suivant Qin et Dunia, l'indice de variance de non-reconstruction (VNR), ou variance d'erreur de reconstruction, montre une valeur minimale lorsque toutes les variables sont mieux reconstruites. Pourtant, l'exactitude de l'erreur de reconstruction enchaîne de la quantité de composantes principales maintenues par le modèle d'ACP. Par conséquent, de meilleures reconstructions ne peuvent être obtenues qu'en choisissant raisonnablement le nombre de composants clés. La variance de l'erreur de reconstruction pour la  $i^{\text{eme}}$  composante du vecteur de données  $x$  est montrée par :

$$u_i = \text{var}\{\xi_i^T (x - x_i)\} = \varepsilon\{\|x - x_i\|\} \quad (\text{II.37})$$

$$= \frac{\xi_i^T \tilde{C} \varepsilon\{xx^T\} \tilde{C} \xi_i}{(\xi_i^T \tilde{C} \xi_i)^2} = \frac{\xi_i^T \tilde{C} \Sigma \tilde{C} \xi_i}{(\xi_i^T \tilde{C} \xi_i)^2} \quad (\text{II.38})$$

Où  $\Sigma = \varepsilon\{x^T x\}$  est la matrice de corrélation évaluée par des données. Intuitivement,  $u_i$  est la variance de l'erreur de reconstruction lors de l'estimation de  $x$  à l'assiste de  $x_i$ .

La propriété d'orthogonalité de la matrice  $P$  permet d'exprimer  $\Sigma$  sous la forme :

$$\Sigma = C \Sigma C + (I - C) \Sigma (I - C) = \hat{\Sigma} + \tilde{\Sigma} \quad (\text{II.39})$$

Où  $\hat{\Sigma} = \varepsilon(\hat{x}\hat{x}^T)$  et  $\tilde{\Sigma} = \varepsilon(\tilde{x}\tilde{x}^T)$  sont les portions modélisées et non modélisées de la matrice de corrélation  $\Sigma$ , respectivement. Par conséquent, le remplacement de cette formule dans la relation (II.38) donne par :

$$u_i = \frac{\xi_i^T \tilde{C} \Sigma \tilde{C} \xi_i}{(\xi_i^T \tilde{C} \xi_i)^2} = \frac{\xi_i^T \tilde{C} \tilde{\Sigma} \tilde{C} \xi_i}{(\xi_i^T \tilde{C} \xi_i)^2} \quad (\text{II.40})$$

Cette équation représente le changement de  $u_i$  dans les données non modélisées. Bien que plusieurs variables soient à étudier simultanément, il faut également déterminer la quantité de composantes principales qui minimisent la variance de la Variance de non-reconstruction (VNR) de la reconstruction.

Pour éviter la difficulté d'échelle des variances non reconstruites, les contributions des différentes variables au critère sont mesurées par leurs variances appropriées  $\xi_i^T \tilde{\Sigma} \xi_i$ . Actuellement, afin de faire comprendre comment ce critère permet la plus petite valeur, correspondant au meilleur modèle et permettant une meilleure reconstruction, nous utilisons les identités suivantes :

$$\|\tilde{C} \xi_i\|^2 + \|\hat{C} \xi_i\|^2 = \|\xi_i\|^2 = 1 \quad (\text{II.41})$$

Depuis l'expression (II.41), on peut écrire la relation (II.40) sous la configuration suivante :

$$u_i(l) = \frac{\xi_i^T \tilde{C} \tilde{\Sigma} \tilde{C} \xi_i}{(\xi_i^T \tilde{C} \xi_i)^2} = \frac{\xi_i^T \tilde{C} \tilde{\Sigma} \tilde{C} \xi_i}{\|\tilde{C} \xi_i\|^2 (1 - \|\tilde{C} \xi_i\|^2)} \quad (\text{II.42})$$

$$= \frac{\xi_i^T \tilde{C} \tilde{\Sigma} \tilde{C} \xi_i}{\|\tilde{C} \xi_i\|^2} \left(1 + \frac{\|\tilde{C} \xi_i\|^2}{1 - \|\tilde{C} \xi_i\|^2}\right) \quad (\text{II.43})$$

En notant que :

$$\tilde{u}_i(l) = \frac{\xi_i^T \tilde{C} \tilde{\Sigma} \tilde{C} \xi_i}{\|\tilde{C} \xi_i\|^2} \quad (\text{II.44})$$

$$\hat{u}_i(l) = \tilde{u}_i(l) \left( \frac{\|\tilde{C} \xi_i\|^2}{1 - \|\tilde{C} \xi_i\|^2} \right) \quad (\text{II.45})$$

L'équation (II.43) transforme alors sous l'aspect suivant :

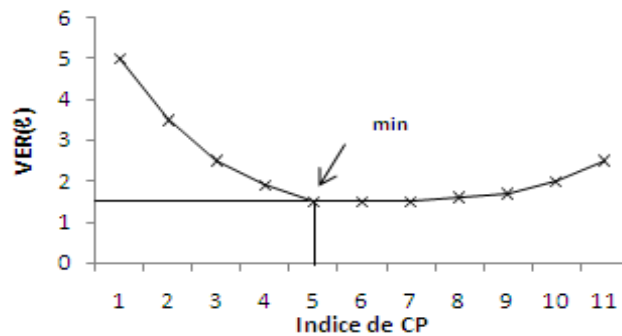
$$u_i(l) = \hat{u}_i(l) + \tilde{u}_i(l) \quad (\text{II.46})$$

Où  $\hat{u}_i$  indique la variance non reconstruite dans le sous-espace des composantes principales et  $\tilde{u}_i$  montre la variance non reconstruite dans le sous-espace résiduel. Par conséquent, on peut voir à partir de l'expression mathématique (II.46) auquel la variance complète de l'erreur de reconstruction est liée aux deux changements de non-reconstruction. Le premier est la variance de l'erreur de reconstruction dans le sous-espace principal, et la seconde est la variance considérée dans le sous-espace résiduel.

Notons que la variance non reconstruite  $u_i$  doit avoir une valeur minimale correspondant au nombre optimal de composantes principales  $l \in [1, m]$ . Par conséquent, la valeur idéale de  $l$  pour reconstruire intégrales les variables  $x_i$  est définies par les critères suivants :

$$J(l) = \min \sum_{i=1}^m u_i(l) \quad (\text{II.47})$$

Il doit  $u_i$  y avoir une valeur minimale dans l'intervalle  $[1, m]$ . La figure (II.10) illustre l'évolution de la variance non reconstruite (VER) [54].



**Figure. II.10.** Sélection du nombre de CPs par VER.

#### 4.3.4.2. Reconstruction non linéaire :

A base des données montrées par le vecteur  $x$ , on peut déterminer le vecteur des composantes principales  $t$  de la manière suivante :

$$t = \sum_{j=1}^r \mathcal{W}_j \phi(\mathcal{Y}_j) \quad (\text{II.48})$$

Où  $\mathcal{Y}_j = -\frac{1}{2} \left\| \frac{x-c_j}{\sigma_j} \right\|^2$ . De plus, on peut définir l'estimation de  $x$  par :

$$\hat{X} = |V^T \Psi(t) \quad (\text{II.49})$$

Où  $V \in \mathfrak{R}^{m \times k}$  et  $\Psi(t) \in \mathfrak{R}^{1 \times k}$ . A base des équations (II.48) et (II.49), on peut déterminer l'erreur d'estimation  $e = X - \hat{X}$ , ensuite le SPE :

$$\text{SPE} = e^T e = \|X - \hat{X}\|^2 \quad (\text{II.50})$$

Comme dans le cas linéaire, la  $i^{\text{ème}}$  variable notée  $z_i$  peut être reconstruite en minimisant la SPE de cette variable :

$$\frac{\partial \text{SPE}}{\partial z_i} = (\xi_i^T - \frac{\partial \psi^T(t)}{\partial z_i} V)(X - \hat{X}) = 0 \quad (\text{II.51})$$

On peut montrer à partir de (II.51) que :

$$z_i = \xi_i^T V^T \psi(t) - \sum_{j=1}^r [\mathcal{W}_j (\frac{z_i - c_{ij}}{\sigma_j^2}) \frac{\partial \phi_j}{\partial y_i}] \frac{\partial \psi^T}{\partial t} V(x - V^T \psi(t)) \quad (\text{II.52})$$

Dont  $\xi_i$  est la  $i^{\text{ème}}$  colonne de la matrice identité.

Pour le cas linéaire, on a :

$$\psi(t) = t, \phi(\mathcal{Y}) = \mathcal{Y}, c_j = 0, \sigma_i = 1, V^T = \hat{P}, W^T = P^T.$$

$$\text{Donc : } t = \hat{P}^T X \text{ et } \hat{X} = \hat{P} t = \hat{P} \hat{P}^T X = \hat{C} X.$$

En substituant la nouvelle variable présenté par l'expression  $z_i$  dans le cas non linéaire, on obtient :

$$z_i = \xi_i^T \hat{P} \hat{P}^T X - \xi_i^T \hat{P} X \hat{P}^T (\hat{P} \hat{P}^T X - X) = \xi_i^T \hat{P} \hat{P}^T X \quad (\text{II.53})$$

Cette expression est la même que celle de l'équation (II.34). Enfin, l'expression de l'équation  $z_i$  de (II.52) peut s'écrire :

$$z_i = \xi_i^T V^T \psi(t) - \sum_{j=1}^r [\mathcal{W}_j (\frac{z_i - c_{ij}}{\sigma_j^2}) \frac{\partial \phi_j}{\partial y_i}] \frac{\partial \psi^T}{\partial t} v_i (z_i - v_i^T \psi(t)) \quad (\text{II.54})$$

Où  $v_i^T$  est la  $i^{\text{ème}}$  colonne de la matrice  $V$ . Par conséquent, nous présentons une approche de reconstruction pour le cas non linéaire afin de définir la quantité de composantes à conserver dans le modèle ACPNL. Cette méthode reconstruit les variables à l'aide de la formule (II.54). Puisque l'obstacle d'amélioration est non linéaire par rapport à  $z_i$ , nous adoptons une approche

répétitive pour résoudre ce problème. Par conséquent, nous proposons la récursivité à partir de (II.52).

$$z_i^{(iter)} = \xi_i^T V^T \psi(t) - \sum_{j=1}^r [\mathcal{W}_j(\frac{z_i^{(iter)} - c_{ij}}{\sigma_j^2}) \frac{\partial \phi_j}{\partial y_i}] \frac{\partial \psi^T}{\partial t} v_i(z_i^{(iter)}) - v_i^T \psi(t) \quad (\text{II.55})$$

Pour ce faire, une valeur initiale pour  $z_i$  doit être choisie. Nous avons choisi  $z_i^{(0)} = x_i$ .

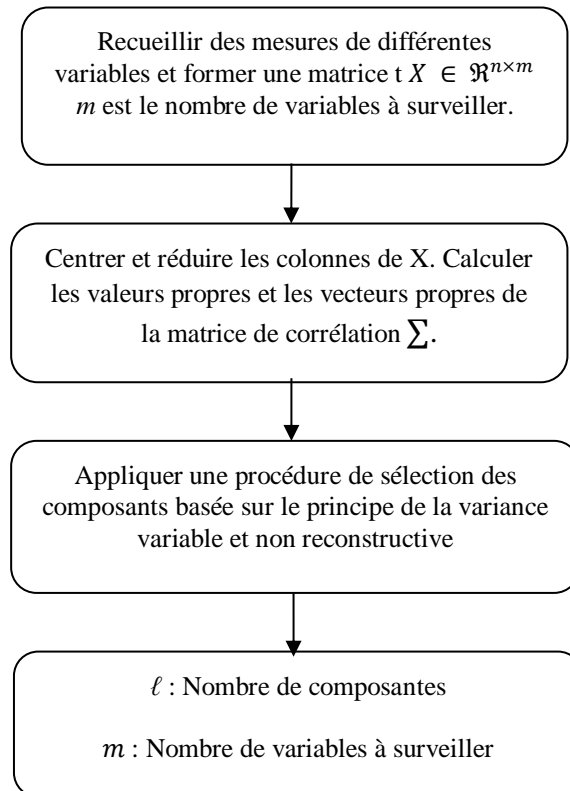
Pour déterminer la quantité de composantes à conserver dans le modèle ACPNL, nous allons diminuer la variance de l'erreur de reconstruction, semblablement dans le cas linéaire [35]. Par conséquent, en utilisant un modèle à  $l$  composantes, la variance non reconstruite de la  $i^{\text{ème}}$  variable est linéairement résolue comme :

$$p_i(l) = \text{var}\{x_i - z_i\} = \mathcal{E}\{(x_i - z_i)^2\} \quad (\text{II.56})$$

et le critère à diminuer par rapport à  $l$  est présenté par :

$$\min_l \sum_{i=1}^m p_i(l) \quad (\text{II.57})$$

Afin de bien résumer la modélisation par Analyse en Composantes Principales (ACP), nous montrons les différentes étapes de détermination du nombre de composantes sur la figure (II.11).




**Figure. II.11.** Différentes étapes pour déterminer la quantité de composantes (modèle ACP) et les variables à surveiller.

## 5. Analyse en composantes principales non linéaire :

L'ACP non linéaire est une élévation de l'ACP linéaire (Fig. II.10). Ainsi que, l'impair de l'ACP non linéaire est d'arracher au coup les rapports linéaires et non linéaires. Ce développement est obtenu en projetant les données de processus sur des courbes et des plans plutôt que sur des lignes et des plans. Dans la littérature [42, 43, 44, 45, 46, 47, 48, 49] plusieurs extensions de l'ACP ont été développées pour traiter des problèmes non linéaires. Premièrement, Hastie [44, 50] a montré une méthode pour généraliser l'ACP à la phase non linéaire, fondée sur la hypothèse de la courbe maîtresse. C'est une courbe lisse qui minimise l'écart entre tous les parties de données et leur projection sur la courbe. Cependant, cette méthode est non paramétrique (pas de modèle de représentation) et ne peut pas être minée pour le suivi. Davantage, il n'accepte que de définir des composantes principales non linéaires unidimensionnelles.

Sur la base des recherches de Hastie, Kramer [45] a offert un examen non linéaire en composantes principales (ACPNL) minant un réseau de neurones à cinq couches dans lequel les poids sont déterminés en minimisant l'erreur quadratique parmi les arrivées et les sorties du réseau. Compte tenu de la difficulté du réseau, Dong [43] a proposé l'ACPNL, qui combine le réseau de neurones et l'approche de la courbe maîtresse. Cette méthode utilise deux sous-réseaux à 3 couches. Les composantes principales sont obtenues par l'algorithme de courbe principale de Hastie [50, 51] pour transformer le problème en une complication de régression non linéaire. Tan et Mavrovouniotis [46] ont fourni un ACPNL obtenu à l'assiste d'un réseau de neurones à trois couches et formé en minimisant les poids et les entrées du réseau. Néanmoins, pour de similaires réseaux, l'apprentissage est très laborieux et nécessite beaucoup de durée d'opération en plus des complications de mise en route et de convergence. Pour cette logique, Webb [52] a fourni une méthode d'analyse en composantes principales minant deux réseaux de fonctions de base radiales (RBF) à trois couches en cascade. Wilson [53] a également adopté le même principe. Cependant, la formation de tels réseaux est encore très compliquée. Notez que dans notre étude nous ne nous intéressons pas à l'étude de la combinaison des réseaux.




**Figure. II.12.** Présentation de l'ACPL et l'ACPNL.

Pour mieux comprendre le problème et pouvoir se rapporter à la situation linéaire, la Figure (II.13) [55] représente les principes généraux des modèles ACP, qu'ils soient linéaires ou non linéaires.

Le spécimen intégral se compose de deux sous-modèles, l'un qui projette des données à  $m$  dimensions sur l'espace des composants principaux à  $\ell$  dimensions, et l'autre qui effectue l'opération inverse,  $\mathfrak{R}^\ell \rightarrow \mathfrak{R}^m$  Model.

Dans la phase linéaire, les deux sous-modèles sont présentes par deux matrices orthogonales  $\hat{P}$  et  $\hat{P}^{-1} = \hat{P}^T$  des vecteurs propres de la matrice de corrélation des données. Le spécimen intégral est présenté par la matrice de projection amenée par  $\hat{C} = \hat{P}\hat{P}^T$ .

Dans la phase non linéaire, l'objectif est de trouver deux fonctions non linéaires  $\mathcal{F}$  et  $\mathcal{G}$ . où  $\mathcal{G}$  évoque un modèle de compression non linéaire qui peut compter des composantes principales non linéaires et  $\mathcal{F}$  représente un modèle de décompression non linéaire. Ce dernier permet d'estimer les variables d'origine par des composantes principales non linéaires présentée par le modèle compressé.



**Figure II.13.** Principe de la modélisation par l'analyse en composantes principales.

En ce phase, la matrice de données  $X$  peut être montrée par l'estimation  $\hat{X}$ , plus une erreur d'estimation  $E$  :

$$X = \hat{X} + E = \mathcal{F}(T) + E. \quad (\text{II.58})$$

Dans lequel  $T = [t_1, t_2, \dots, t_\ell] \in \mathfrak{R}^{N \times \ell}$  est la matrice des composantes principales non linéaires qui est montrée par :

$$T = \mathcal{G}(X) \quad (\text{II.59})$$

Selon cette relation, le modèle non linéaire (ACP NL) est évoqué par la fonction  $\mathcal{F}(\mathcal{G}(\cdot))$ , et l'estimation de  $X$ , écrite  $\hat{X}$ , est enregistrée par :

$$\hat{X} = \mathcal{F}(\mathcal{G}(X)) \quad (\text{II.60})$$


L'analyse en composantes principales non linéaire (NLPCA) généralise les principales composantes des lignes droites aux courbes (non linéaires). Par conséquent, le sous-espace dans l'espace de données d'origine décrit par tous les composants non linéaires est également courbe. Dans ce qui suit, nous discutons des différentes méthodes d'extraction des composantes principales non linéaires. Tout d'abord, nous glissons le principe de la courbe maîtresse, puis introduisons des méthodes neuronales pour l'ACP NL minant des réseaux de neurones MLP ou des réseaux des activités de base radiales [56].

### 5.1. Approche des Courbes Principales :

Proposé par Hastie [44]; cette méthode résume la distribution des données autour d'une courbe polygonale unidimensionnelle appelée courbe maîtresse dans un espace de représentation multidimensionnel en démunissant la distance par un point de données et sa projection sur cette courbe, il convient de noter que, il est difficile de construire plus de deux composants principaux en utilisant cette méthode. La courbe maîtresse est résolue semblablement une courbe auto-cohérente, où les propriétés auto-cohérentes s'expliquent par l'action que toute point de la courbe  $\mathcal{F}$  est la moyenne de tous les points projetés sur elle. Par conséquent, la courbe maîtresse est une courbe lisse auto-cohérente qui défilé au centre d'un nuage de points à  $m$  dimensions et produit un résumé non linéaire des données [50].

Il y a plusieurs façons de comprendre mathématiquement cette idée. L'algorithme de Hastie et Stuetzle a été le premier à être étudié le concept de la courbe maîtresse. Ils ont utilisé l'ACP comme direction de projection (Fig. II.14). Après avoir calculé la moyenne de la majorité des points projetés dans le même voisinage, la majorité des points représente la courbe principale.

Par conséquent, la courbe maîtresse est définie comme une courbe auto-cohérente passant par le milieu du nuage de points et montre un résumé non linéaire unidimensionnel des données. Après avoir calculé la moyenne d'un ensemble de points projetés dans le même voisinage, l'ensemble de points représente la courbe maîtresse. Par conséquent, la courbe maîtresse est définie comme une courbe auto-cohérente qui passe par le milieu du nuage de points et produit un résumé non linéaire unidimensionnel des données.



**Figure II.14.** Indice de projection. Pour tout  $i$ ,  $t_i$  désigne  $t_{\mathcal{F}}(x_i)$

### 5.1.1. Algorithme de calcul des courbes principales de Hastie :

Puisqu'il n'y a généralement pas de médian droit de amener la courbe maîtresse, le résultat comprend à recourir à un algorithme fréquentatif qui verra une évaluation. Aussi, en pratique, on ne éprouve pas la loi de  $X$ , pourtant on regarde  $X_1, \dots, X_n$ , en supposant qu'ils sont indépendants et distribués selon cette loi. Ici, la courbe  $\mathcal{F}$  est représentée par une ligne pointillée reliant des points ressemblant à  $n$  couples  $(t_i, \mathcal{F}(t_i))$  dans un ordre croissant de  $t_i$ . La courbe est paramétrée par un arc, notant que l'indice  $t_i$  vérifie  $t_i = t_{i-1} + \|\mathcal{F}(t_i) - \mathcal{F}(t_{i-1})\|$ . L'algorithme de Hastie et Stuetzle [50] substitue entre la phase de projection et la phase de spéculation de l'espérance conditionnelle, puis procède comme suit :

Soit  $\mathcal{F} = (\mathcal{F}_1, \dots, \mathcal{F}_d)$  une courbe paramétrée continue définie sur un intervalle fermé  $I = [a, b]$ .

#### - Initialisation :

Soit  $\mathcal{F}^{(0)}$  la droite ressemblant à l'initiale composante principale de  $X_1, \dots, X_n$ .

#### - Etape de projection :

Pour tout  $i=1, \dots, n$ , on comportement  $t_i^{(j)} = t_{\mathcal{F}^{(j)}}(X_i)$ .

#### -Etape espérance conditionnelle :

Il s'agit d'évaluer la quantité  $\mathcal{F}^{(j+1)}(t) = \mathbb{E}(X | t_{\mathcal{F}^{(j)}}(X) = t)$  aux points  $t_1^{(j)}, \dots, t_n^{(j)}$ .

**-Condition d'arrêt :**

L'algorithme se finis quand la variation de  $\frac{1}{n} \sum_{i=1}^n \left\| X_i - \mathcal{F}^{(j)}(t_i^{(j)}) \right\|^2$  tombe sous un seuil donnée.

La méthode de la courbe maîtresse a été introduite comme méthode de généralisation pour l'ACP non linéaire unidimensionnelle. Hastie [44] a également proposé une méthode de surface principale (cas de la dimension 2).

Le principal inconvénient des courbes principales est qu'elles ne peuvent pas représenter des composantes principales non linéaires. Par conséquent, pour de nouvelles épreuves, il est pénible, certainement impraticable, de définir la valeur de la composante non linéaire correspondante. Cependant, à des fins de diagnostic, il est souhaitable d'avoir une image des composantes principales non linéaires, acceptant la spéculation des valeurs des composantes non linéaires pour les originales observations. Les réseaux de neurones artificiels sont avoués pour leur rendement à reconnaître les rapports non linéaires entre les variables. En la partie suivante, l'algorithme ACPNL fondé sur les réseaux de neurones sera présenté.

**5.2. Les approches basées sur les réseaux de neurones artificiels :**


En la partie suivante, nous présenterons l'algorithme ACPNL fondé sur un réseau de neurones à cinq couches (MLP). Il avoue identiquement d'écrire qu'il existe d'autres méthodes neuronales (modèles) pour l'analyse en composantes principales non linéaires, telles que l'ACPNL en optimisant l'entrée du réseau (entrée pour former le réseau), les réseaux à trois couches et courbes principales, et les réseaux à fonction de base radiale (RBF) et chacun de ces modèles a ses caractéristiques et ses défauts, dans notre projet, nous ne nous intéressons qu'à l'ACPNL basé sur le MLP à cinq couches.

**5.2.1. ACPNL par réseau neurone à cinq couches :**

En tant qu'extension de l'ACP linéaire, Kramer a proposé une approche d'analyse en composantes principales non linéaire fondé sur la topologie des réseaux neuronaux d'autocorrélation en 1991. Les réseaux de neurones artificiels ont été amplement exploités pour modéliser des rapports non linéaires. L'analyse en composantes des non-linéarités (ACPNL) basée sur les réseaux de neurones a suscité un grand avantage dans le secteur du diagnostic fonctionnel du dispositif industriel. [35, 57, 58, 59, 60, 61, 62].

Une approche non linéaire basée sur des réseaux de neurones artificiels "RNAs" utilise un perceptron "MLP" multicouche avec une topologie d'association automatique composée de cinq

couches et d'une couche goulot d'étranglement (bottleneck layer) [45] : Les MLP sont des modèles de plus grande puissance de calcul. Sa structure est constituée d'une couche d'accès, d'une couche de sortie et d'une ou nombreuses couches médianes nommées couches cachées. Il est important de pointer que ce modèle utilise une règle d'apprentissage par rétro-propagation.



**Figure II.15.** Réseau à cinq couches pour l'extraction d'une seule composante principale non linéaire.

Le réseau de neurones à cinq couches pour l'arrachement de composante principale non linéaire unique (Fig. II.15) comprend trois couches parmi les grandeurs d'entrée et de sortie. La fonction de transfert  $\mathcal{G}_1$  effectue la projection du vecteur  $x$  (vecteur d'entrée de dimension  $m$ ) au la première couche cachée (couche d'encodage). Exprimé sous la forme  $h_j^{(x)}$  ( $j = 1, \dots, r$ ), un vecteur colonne de pondération  $r$ , où  $r$  est le quantité de neurones dans la première couche cachée :

$$h_j^{(x)} = \mathcal{G}_1(V^{(x)}x + b^{(x)}) = \mathcal{G}_1(\sum_{i=1}^m (v_{ij}^{(x)} x_i + b_j^{(x)})) \tag{II.61}$$

$V^{(x)}$  est une matrice de poids de dimension  $(r \times m)$ , et  $b^{(x)}$  est un vecteur récipier  $r$  éléments de biais.

La seconde fonction de transfert  $\mathcal{G}_2$  projette les données de la première couche cachée au la couche goulot et consiste en un neurone dont la sortie représente la composante principale non linéaire  $t$ . La fonction de transfert  $\mathcal{G}_1$  est généralement non linéaire, également la fonction  $\mathcal{G}_2$  représente la fonction identité ( $\mathcal{G}(x) = x$ ).

$$t_i = \mathcal{G}_2(W^{(x)}h^{(x)} + \bar{b}^{(x)}) = \mathcal{G}_2(\sum_{j=1}^r (w_{ji}^{(x)} h_j^{(x)} + \bar{b}_i^{(x)})) \tag{II.62}$$

Transférez ensuite la fonction  $\mathcal{G}_3$ , qui est une fonction non linéaire qui projette les données de  $t$  au la deuxième couche cachée (la couche de décodage).  $h_j^{(x)}$  ( $j = 1, \dots, r$ ) et  $r$  représentent le quantité de neurones dans la troisième couche cachée :

$$h_j^{(t)} = \mathcal{G}_3(W^{(t)}t + b^{(t)}) = \mathcal{G}_3(\sum_{i=1}^l w_j^{(t)} t_i + b_j^{(t)}) \quad (\text{II.63})$$

La finale fonction de transfert  $\mathcal{G}_4$  est la fonction identité, qui projette les grandeurs de la deuxième couche de décodage vers la couche de sortie  $\hat{x}$ , le vecteur de sortie est de dimension  $m$ .

$$\hat{x}_i = \mathcal{G}_4(V^{(t)}h^{(t)} + \bar{b}^{(t)}) = \mathcal{G}_4(\sum_{j=1}^r v_{ji}^{(t)} h_j^{(t)} + \bar{b}_i^{(t)}) \quad (\text{II.64})$$

La fonction de coût minée pour constituer ce réseau de neurones est :

$$e = \sum_{j=1}^n \sum_{i=1}^m (x_i - \hat{x}_i)_j^2 \quad (\text{II.65})$$

Où  $x_i$  sont les observations attendues du jeu de données  $x$  et  $\hat{x}_i$  sont la sortie réelle du réseau. La fonction de coût  $E = \|x_i - \hat{x}_i\|^2$  est diminué pour découvrir la valeur optimale  $V^{(x)}$ ,  $b^{(x)}$ ,  $W^{(x)}$ ,  $\bar{b}^{(x)}$ ,  $W^{(t)}$ ,  $b^{(t)}$ ,  $V^{(t)}$  et  $\bar{b}^{(t)}$ .

Un coup la structure globale résolue, nous devons conduire la structure exacte du modèle neuronal (architecture de réseau). Afin de, nous devons décider de la quantité de couches cachées que nous voulons et de la quantité de neurones dans tout couche cachée. Funahashi [63] et Cybenko [64] pour déterminer le nombre de couches cachées. La quantité de neurones de la couche cachée est souvent résolue en accomplissant une validation croisée sur l'ensemble de validation. L'algorithme construit de façon itérative des couches cachées et complète le contrôle du développement du réseau grâce à la validation croisée. D'autres conceptions utilisent l'exact parcours inverse de l'approche précédente, en partant d'un réseau avec une ample quantité de neurones dans la couche cachée et en supprimant graduellement les liaisons décidé inefficace jusqu'à l'acquisition d'une structure acceptable. Un aperçu des manières de suppression est donné dans Kerling [65].


En fait, il convient de montré que l'extraction des composants principaux peut s'effectuer de deux manières. Le premier est l'extraction séquentielle des composants, où un seul neurone de la couche intermédiaire est utilisé, le goulot d'étranglement (ACPNL séquentiel). La seconde comprend à arracher simultanément  $\ell$  composants souhaités en introduisant initialement  $\ell$  neurones (ACPNL parallèles ou simultanés) dans la couche médiane.

### 5.2.1.1 le modèle séquentiel de L'ACPNL :

Chaque réseau consiste à extraire séquentiellement une composante principale en n'ayant qu'un unique neurone dans la couche goulot d'étranglement. Après avoir estimé les données par des premières composantes principales non linéaires, nous devons construire le vecteur résiduel  $E = X - \hat{X}$  puis nous effectuons la deuxième extraction non linéaire des composantes.

Ce processus être apte de répété avec ce la quantité de composantes ou l'erreur d'estimation soit insuffisant à un exact point sélectionné a priori, figure. (II.16) [56] [66]. La méthode s'affiche comme suit :

1. Projetez les données  $X$  dans l'espace de discrétion  $\ell$  de la composante principale, par l'utilisation d'une structure en treillis à cinq niveaux.
2. Instruire le réseau et évaluer  $\hat{X}$  par rétroprojection.
3. Calculez l'erreur estimée  $E = X - \hat{X}$ . Répétez les étapes 1 et 2, en remplaçant  $X$  par la matrice  $E$ , jusqu'à ce que la proportion de variance de  $X$  soit capturé.



**Figure. II.16.** Le modèle séquentiel de l'ACPNL.


### 5.2.1.2 le modèle parallèle de l'ACPNL :

Le modèle de L'ACPNL parallèle possède une couche d'étranglement contient des neurones qui consistent à extraire les composantes principales simultanément de dimension (figure (II.17)) [66]. Le nombre de composantes est doit être connu auparavant. Comparé au modèle séquentiel, ce modèle apprend plus vite [67]. L'annonce du processus pour le modèle est la suivante :

1. Projetez les données  $X$  dans l'espace des composantes principales de dimension  $\ell$  à l'aide d'une structure en treillis à cinq niveaux.

2. Inculquer le réseau et estimer les données  $\hat{X}$  par rétroprojection.

Le principal avantage des algorithmes parallèles par rapport aux algorithmes séquentiels est un apprentissage plus rapide : pour les composants  $\ell$ , un seul réseau de neurones est requis dans le cas parallèle, tandis que les réseaux  $\ell$  sont requis dans le cas séquentiel. L'inconvénient des algorithmes parallèles est la première phase. Cette phase estime que la quantité de composantes principales doit être éprouvée a priori.



**Figure.II.17.** le modèle parallèle de l'ACPNL.

Il est à souligner que l'extraction des composants principaux peut chercher de deux manières. La première constituée à arracher les composants de manière séquentielle en ne possédant qu'un seul neurone dans la couche intermédiaire « couche goulot d'étranglement » (ACPNL séquentiel) (Fig. II.14). La deuxième approche consiste à insérer  $\ell$  neurones dans la couche intermédiaire (ACPNL parallèle ou synchrone) tout en extrayant les composants souhaités de  $\ell$  (Fig. II.15). L'ACPNL parallèle nécessite de définir le nombre de composants non linéaires à maintenir  $\ell$  avant la formation du réseau. Alors que dans le fait de l'ACPNL séquentiel, le réseau est originellement formé en compagnie d'une composante principale non linéaire. Ensuite approximation des données pour cette initiale composante non linéaire, le résultat obtenu doit être soustrait de la majorité de données de début, et une relation d'extraction pour la deuxième composante non linéaire est accomplie sur le reste obtenu. Ce processus peut être répété jusqu'à ce que la quantité de composante souhaitée soit aboutie ou que l'erreur d'estimation soit amoindrie à une limite adoptée a priori.

### 5.2.1.3. Apprentissage du réseau neurone à cinq couches :

La majorité des algorithmes d'apprentissage de réseaux neuronaux sont des formules d'amélioration et tentent d'atténuer la fonction de coût grâce à des techniques d'optimisation non linéaires. Cette amélioration s'accomplit de façon fréquentative en améliorer les poids en fonction du gradient de la fonction de coût. Les poids sont initialisés de manière aléatoire auparavant de l'apprentissage et changer de manière itérative jusqu'à ce qu'un arrangement convenable entre l'exactitude de l'estimation de la majorité d'apprentissage et l'exactitude de validation de l'estimation de la majorité soit obtenu. Malthose [68] a proposé un réseau de neurones à cinq couches qui apprend à reproduire ces entrées pour abaisser la fonction de coût suivante :

$$\min_{\mathcal{F}, \mathcal{G}} \sum_{k=1}^N \|x(k) - \mathcal{F}(\mathcal{G}(x(k)))\|^2 + \left(\sum_{i=1}^m \left(\frac{\partial \mathcal{F}(x(k))}{\partial t}\right)^2\right) \quad (\text{II.66})$$

Nous avons antérieurement exprimé le problème d'apprentissage d'un réseau de neurones artificiels tant que un souci d'amélioration de fonction de coût. La formule de rétro propagation des erreurs est l'un des algorithmes les plus souvent utilisés dans les problèmes de classification supervisée.

Les paramètres d'entrée du programme d'apprentissage sont les suivantes :

- Base de données, vecteur d'entrée et la catégorie correspondante ;
- Les poids, les biais initiaux ;
- La fonction d'activation ;
- Le nombre d'itérations.

Les poids dedans un réseau de neurones sont d'abord initialisés avec des grandeurs aléatoires. Subséquemment, nous considérons un ensemble de données qui seront utilisées pour la formation. Chaque échantillon à sa valeur cible, qui est ce que le réseau de neurones devrait éventuellement découvrir lorsqu'il est donné avec le même échantillon. L'algorithme suit ces étapes :

- Soit  $x$  l'échantillon montré à l'ouverture du réseau neuronal et  $\hat{x}$  l'échappement attendue.
- Nous propageons le signal à côté les couches du réseau de neurones :  $x_k^{(n-1)} \rightarrow x_j^{(n)}$ , où  $n$  est le nombre de couches.
- La diffusion vers l'avant se fait à l'assiste de la fonction d'activation  $\mathcal{G}$ , de la fonction d'association  $h$  (généralement le produit scalaire entre le poids du neurone et l'entrée) et du

poids synaptique entre le neurone  $x_k^{(n-1)}$  et le neurone  $x_j^{(n)}$ . Inversez ensuite la notation :  $w_{jk}$  désigne bien les poids de  $k$  à  $j$ .

$$x_j^{(n)} = \mathcal{G}^{(n)}(h_j^{(n)}) = \mathcal{G}^{(n)}(\sum_k w_{jk}^{(n)} x_k^{(n-1)}) \quad (\text{II.67})$$

- Une fois la diffusion vers l'avant achevée, la conséquence  $y$  est obtenue en sortie.
- Calculez ensuite l'erreur entre la sortie donnée par le réseau  $y$  et le vecteur  $\hat{x}$  requis pour cette sortie d'échantillon. Avec tout neurone  $i$  de la couche de sortie, on compte ( $\mathcal{G}'$  est la dérivée de  $\mathcal{G}$ ) :

$$e_i^{\text{sortie}} = \mathcal{G}'(h_i^{\text{sortie}}) (y_i - \hat{x}_i) \quad (\text{II.68})$$

- Nous propageons l'erreur vers l'arrière favor à la relation suivante  $e_i^{(n)} \rightarrow e_j^{(n-1)}$ :

$$e_j^{(n-1)} = \mathcal{G}'^{(n-1)}(h_j^{(n-1)}) \sum_i w_{ij}^{(n)} e_i^{(n)} \quad (\text{II.69})$$

Note :  $e_i^{(n)} = e_i^{\text{sortie}} = (y_i - \hat{x}_i) \frac{\partial y_i}{\partial h_j^{(n)}}$

- Nous mettons à jour les poids de toutes les couches :

$$w_{ij}^{(l)} = w_{ij}^{(l)} - \lambda e_i^{(l)} x_j^{(l-1)} \quad (\text{II.70})$$

Où  $\lambda$  est le taux d'apprentissage (faible amplitude et entre (0,0 et 1,0)).


La transition du réseau via la rétro-propagation est un souci critique parce qu'elle nécessite de multiples itérations. Pour surmonter tel souci, des paramètres sont généralement ajoutés pour avancer la convergence. Cet élément est nommé "momentum". Le momentum est un solution agissant d'avancer l'apprentissage et de se débarrasser des minima locaux [81].

### 5.2.2. L'approche de l'ACPNL par optimisation des entrées du réseau neurone (Input Training Network) :

C'est un réseau à trois couches avec des couches cachées. La couche de sortie est constituée de  $m$  neurones conforme à la dimension de données  $x$ . La couche d'entrée comporter  $\ell$  neurones, équivalent au nombre  $t$  de composantes principales non linéaires. Au moment de former un réseau auto-associatif à cinq couches, seul un morceau de ce réseau à trois couches (sous-réseau décompressé) est formé. L'apprentissage de tels sous-réseaux est intéressant et peut se faire en étendant la formule de rétro propagation car la fonction d'erreur est parfaitement caractérisé. La composition de ce réseau diffère des réseaux multicouches ordinaires en ce que les entrées de ce réseau sont inconnues puisque elles reflètent les composants principaux recherchés. Par conséquent, pendant l'étape d'apprentissage, non seulement les éléments internes du réseau

doivent être ajustés, pourtant aussi la valeur de l'entrée doit être ajustée en minimisant l'erreur de sortie du réseau. Tan et Mavrouniotis [46] ont souligné que les ANN sont topologiquement complexes et difficiles à former. En règle générale, un accroissement de la quantité de couches cachées dégrade les performances des algorithmes basés sur la rétro propagation, tels que ceux montrés par Levenberg-Marquardt [71, 72].

L'article de Tan et Mavrouniotis présente également une étude d'application simplifiée décrivant un cercle qui démontre les difficultés de formation d'une topologie de réseau aussi grande. Pour pallier cette carence, ils ont proposé un réseau d'apprentissage d'entrée qui a la topologie montrée dans la figure(II.18) pour un total de 5 variables originales,  $z_1, z_2, z_3, z_4$  et  $z_5$  et deux composants principaux non linéaires  $t_1$  et  $t_2$ .



**Figure. II.18.** Le modèle d'optimisation des entrées par Tan.

La formation d'entrée où le réseau neurone détermine les poids du réseau ainsi que les variables de manière itérative. Pour la distance des moindres carrés entre les observations originales et reconstruites, la fonction de coût suivante peut être utilisée :

$$J = \sum_{i=1}^K \sum_{j=1}^N (z_{ij} - \hat{z}_{ij})^2 = \sum_{i=1}^K \sum_{j=1}^N (z_{ij} - \theta_j(t_i))^2 \quad (\text{II.71})$$

Où  $\theta_j(\cdot)$  est la fonction de réseau pour reconstruire la  $j^{\text{ème}}$  variable originale  $z_j$  et  $t_i^T = (t_1, t_2, \dots, t_n)$ . En supposant que les poids du réseau sont constants et prédéterminés, la descente la plus raide dans la direction des entrées réseau optimales est donnée par le gradient de  $J$  par rapport aux scores non linéaires :

$$\Delta t_{ik} = - \frac{\partial J}{\partial t_{ik}} = \sum_{j=1}^N 2(z_{ij} - \theta_j(t_i)) \frac{\partial \theta_j(t_i)}{\partial t_{ik}} \quad (\text{II.72})$$

La reconstruction de  $z_{ij}$ , c'est-à-dire la détermination de  $z_{ij}$  à l'aide du réseau neurone, est basée sur les couches d'entrée et intermédiaire :

$$\hat{z}_{ij} = \theta_j(t_i) = \sum_{p=1}^{M_d} w_{pj}^{(2)} \sigma \left( \sum_{q=1}^n w_{pq}^{(1)} t_{iq} + b_p \right) \quad (\text{II.73})$$

Où les indices (1) et (2) se réfèrent aux poids d'entrée et de couche intermédiaire et  $b_p$  est un terme de biais. Par souci de simplicité, les termes linéaires ne sont pas inclus, ce qui, cependant, ne restreint pas la généralité. La combinaison des équations (II.71) et (II.72) peut déterminer la descente la plus raide dans la direction de l'entrée d'apprentissage du réseau entre les couches d'entrée et cachée :

$$\Delta t_{ik} = \sum_{p=1}^N w_{pj}^{(1)} \delta_{ip} \quad (\text{II.74})$$

Où :

$$\delta_{ip} = \sum_{j=1}^N 2(z_{ij} - \theta_j(t_i)) \frac{\partial \theta_j(t_i)}{\partial t_{ik}} \quad (\text{II.75})$$

Qui est donné par :

$$\frac{\partial \theta_j(t_i)}{\partial t_{ik}} = \sum_{p=1}^{M_d} w_{pj}^{(2)} \frac{\partial}{\partial t_{ik}} \sigma \left( \sum_{q=1}^n w_{pq}^{(1)} t_{iq} + b_p \right) \quad (\text{II.76})$$

Et, par conséquent :

$$\frac{\partial \theta_j(t_i)}{\partial t_{ik}} = \sum_{p=1}^{M_d} w_{kj}^{(2)} \sigma' \left( \sum_{q=1}^n w_{pq}^{(1)} t_{iq} + b_p \right) \quad (\text{II.77})$$

De sorte que  $\delta_{ip}$  peut finalement être déterminé comme :

$$\delta_{ip} = \sigma' \left( \sum_{q=1}^n w_{pq}^{(1)} t_{iq} + b_p \right) \sum_{j=1}^N 2w_{kj}^{(2)} (z_{ij} - \theta_j(t_i)) \quad (\text{II.78})$$

En suivant la dérivée ci-dessus, la direction de inclinaison la plus raide des poids du réseau entraîné entre la couche d'entrée et la couche cachée peut être obtenue semblablement suit :

$$\Delta w_{pk}^{(1)} = - \frac{\partial J}{\partial w_{pk}^{(1)}} = \sum_{i=1}^K \sum_{j=1}^N \frac{\partial}{\partial w_{pk}^{(1)}} (z_{ij} - \sum_{p=1}^{M_d} w_{pj}^{(2)} \sigma \left( \sum_{q=1}^n w_{pq}^{(1)} t_{iq} + b_p \right))^2 \quad (\text{II.79})$$

Qui est donné par :

$$\Delta w_{pk}^{(1)} = \sum_{i=1}^K \sum_{j=1}^N 2(z_{ij} - \sum_{p=1}^{M_d} w_{pj}^{(2)} \sigma \left( \sum_{q=1}^n w_{pq}^{(1)} t_{iq} + b_p \right)) t_{ik} \sigma' \left( \sum_{q=1}^n w_{pq}^{(1)} t_{iq} + b_p \right) \quad (\text{II.80})$$

Qui est une forme simplifiée est donnée par :

$$\Delta w_{pk}^{(1)} = \sum_{i=1}^K \eta_{ik}^{(1)} \sum_{j=1}^N (z_{ij} - \sum_{p=1}^{M_d} w_{pj}^{(2)} \sigma \left( \sum_{q=1}^n w_{pq}^{(1)} t_{iq} + b_p \right)) \quad (\text{II.81})$$

Où  $\eta_{ik}^{(1)} = t_{ik} \sigma' \left( \sum_{q=1}^n w_{pq}^{(1)} t_{iq} + b_p \right)$ . D'une manière similaire à (II.80), une descente la plus raide peut également être dérivée pour les poids de réseau  $w_{pk}^{(2)}$ . En utilisant la descente la plus raide dérivée ci-dessus, le réseau de neurones peut être formé en utilisant la technique de rétro propagation.

Entraînez un réseau IT pour définir la relation de projection entre les composants principaux non linéaires et les données de dispositif. Cependant, aucun modèle n'est défini pour déterminer les composantes principales non linéaires correspondantes par de nouvelles observations. Afin de résoudre cet obstacle, Tan et Mavrouniotis [46] ont proposé un algorithme d'amélioration

en ligne pour les entrées du réseau informatique afin de compter les composantes principales non linéaires des nouvelles observations.

### 5.2.3. L'approche de réseau de neurones de type RBF (Radial Basis Functions) :

Réseaux à fonction de base radiale (RBF) Un modèle de lien facile à mettre en œuvre et très bien compris largement utilisé pour l'éloignement et la discrimination. Leurs domaines théoriques et pratiques ont été ordonnées en détail à partir de la fin des années 1980 ; bien sûr, les perceptrons multicouches sont les modèles de connexion les plus connus. Une fonction d'assise radiale (RBF) est une fonction symétrique autour du centre  $\mu_j = \phi_j(x) = \phi(\|x - \mu_j\|)$ , où  $\|\cdot\|$  est la norme [73]. En général, le RBF est paramétré par  $\sigma$ , qui correspond à la «largeur» de la fonction :

Réseaux à fonction de base radiale (RBF) Un modèle de lien facile à mettre en œuvre et facile à comprendre largement utilisé pour la régression et la discrimination. Leurs caractéristique théoriques et pratiques ont été étudiées en développement depuis la fin des années 1980 ; bien sûr, le perceptron multicouche est le modèle de connexion le plus connu. Les fonctions de base radiales (RBF) sont des fonctions symétriques autour du centre :

$$\phi_j(x) = \phi(\|x - \mu_j\|, \sigma_j) \quad (\text{II.82})$$

Définir un modèle ACPNL basé sur un réseau RBF, en considérant les deux réseaux RBF présentés par les deux figures (Figure (II.19)) et (Figure (II.20)). L'initial réseau définit une projection non linéaire pour calculer les composantes principales non linéaires  $t$  des données  $x$ . En conséquence, la sortie  $t$  du réseau peut se correspondre :

$$t = \mathcal{G}(x) \quad (\text{II.83})$$

$$t = \sum_{i=1}^r w_i \phi_i = W^T \Phi(X) \quad (\text{II.84})$$


Où  $W \in \mathfrak{R}^r$  est le vecteur de poids de la couche de sortie du initial réseau,  $\Phi \in \mathfrak{R}^r$  est le vecteur des variables de transformation, et  $r$  est la quantité de transformations ou la quantité de neurones dans la couche cachée.

Le deuxième réseau définit une transformée opposée qui permet de compter l'estimation de  $\hat{X}$  par de  $t$ . Par conséquent, nous avons :


$$\hat{X} = \mathcal{F}(t) \quad (\text{II.85})$$

$$\hat{X} = \sum_{j=1}^r v_j \psi_j(t) = V^T \Psi(X) + v_0 \quad (\text{II.86})$$

Où  $\psi_j$  ( $j = 1, \dots, r$ ) est la fonction noyau,  $V^T = [v_0 \dots v_r] \in \mathfrak{R}^{m \times r}$  est la matrice de pondération,  $v_0$  est le nom de biais et  $r$  est la quantité de noyaux.



**Figure. II.19.** Réseau RBF pour la compression des données (projection).



**Figure. II.20.** Réseau RBF pour la décompression des données (projection inverse).

### ***Apprentissage le modèle RBF :***

Pour former un modèle RBF, nous devons définir son structure (la quantité de fonctions radiales  $N$ ) et les grandeurs des paramètres fixes. L'apprentissage du réseau RBF est contrôlé, et nous avons un groupe d'apprentissage composé de  $l$  paires (vecteur d'entrée, valeur cible)  $(x_1, y_1), \dots, (x_m, y_m)$ .

Et le coût associé à tout exemple :

$$E_i = \frac{1}{2} (y_i - \mathcal{F}(x_i))^2 \quad (\text{II.87})$$

Une particularité passionnant du modèle RBF est qu'il divise les paramètres en trois groupes : centre  $\mu$ , largeur  $\sigma$  et poids. L'interprétation de toute groupe servir un algorithme de descente de gradient simple et efficace [74].

### ***Apprentissage par descente de gradient :***

Cette manière d'apprentissage a été proposée fin 1993 [74]. L'avantage de cette technique est qu'elle est aisée à mettre en œuvre, nécessite légèrement de spéculations et attribution des résultats acceptables. Cependant, la conclusion acquis n'est pas parfaite, comme tous les

modèles connexionnistes. Il est nécessaire de calculer des dérivées (éventuellement régularisées) du coût par rapport à distincts paramètres. Pour la fonction gaussienne :

$$\Phi_{ij} = \exp\left(-\frac{\|x_i - \mu_j\|^2}{2\sigma_j^2}\right) \quad (\text{II.88})$$

et un coût  $E_i = \frac{1}{2}(y_i - y(x_i))^2$ , la dérivée partielle s'écrit :

$$\frac{\partial E_i}{\partial w_j} = -w_j (y_i - \sum_j w_j \Phi_{ij}) \Phi_{ij} \quad (\text{II.89})$$

$$\frac{\partial E_i}{\partial \sigma_j} = -w_j \frac{\|x_i - \mu_j\|^2}{\sigma_j^2} (y_i - \sum_j w_j \Phi_{ij}) \Phi_{ij} \quad (\text{II.90})$$

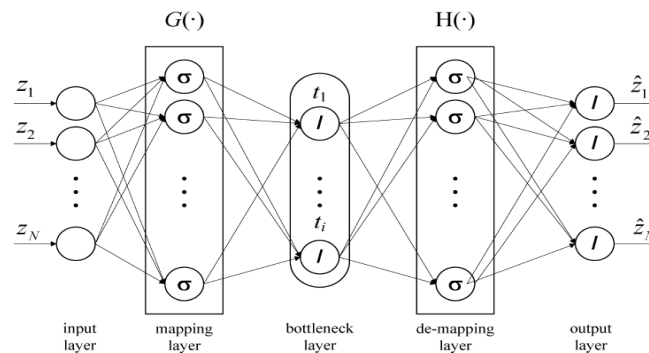
$$\frac{\partial E_i}{\partial \mu_j^k} = -w_j \frac{\|x_i^k - \mu_j^k\|^2}{\sigma_j^2} (y_i - \sum_j w_j \Phi_{ij}) \Phi_{ij} \quad (\text{II.91})$$

Selon ces équations, l'algorithme d'apprentissage par minimisation des erreurs standard peut être soit une version par lots (calculer l'erreur pour tous les exemples avant de mettre à jour les paramètres) ou en ligne (mise à jour ensuite toute exemple, généralement avec de mieux performances). Cependant, il se fait d'un souci non linéaire et l'algorithme d'amélioration peut se coincer dans les minimaux régionaux de la fonction de coût. Par conséquent, le succès de l'optimisation provenir fortement des conditions initiales. Par conséquent, nous recommandons de miner la descente de gradient pour l'optimisation globale des paramètres uniquement suite d'un apprentissage séquentiel traditionnel. La descente de gradient peut affiner les paramètres pour améliorer les performances [74]. Puisque la composante principale non linéaire  $t$  représentant la sortie du premier réseau (Fig. (II.16)) et l'entrée du second réseau (Fig. (II.17)) est inconnue.

### 5.3. Approche combinant les réseaux de neurones et les courbes principales :

Dong et McAvoy [69] ont proposé une autre approche pour simplifier la structure de la structure complexe originale à 5 couches de Kramer. Ce travail repose sur une séparation du réseau à 5 couches en la fonction de compression à 3 couches  $G(\cdot)$  et un autre réseau à 3 couches représentant la fonction de décompression  $H(\cdot)$ . Selon la (figure.II.21), les entrées de la fonction de compression sont les grandeurs d'origine  $z \in \mathfrak{R}^N$  et la sortie sont les grandeurs de score non linéaire  $t \in \mathfrak{R}^n$ , tandis que les entrées et sorties de la fonction de décompression sont les variables de score et les variables reconstruites  $\hat{z} \in \mathfrak{R}^N$ , respectivement. Au lieu de déterminer les entrées de la fonction de décompression  $H(\cdot)$  en optimisant l'équation (II.65) en

fonction des variables de score non linéaires pour chaque observation, l'approche de Dong et McAvoy utilise les courbes principales pour déterminer les variables de score non linéaires. Les problèmes potentiels de cette approche sont discutés par Jia et al [70]. La méthode de la courbe maîtresse de Dong et McAvoy suppose qu'une approximation d'une relation non linéaire peut être remportée par une combinaison linéaire de plusieurs fonctions non linéaires univariées. Cependant, il s'agit d'une limitation de généralité et signifie que seule une classe limitée de fonctions non linéaires peut être approchée à l'aide de cette technique.



**Figure.II.21.** Topologie des réseaux de neurones auto-associatifs.

Dong et McAvoy [69] offrir de former ces deux sous-réseaux indépendamment. L'approche présentée exige trois étapes :

- Appliquer en continu l'algorithme de la courbe maîtresse de Hastie pour traiter les données et identifier les composants non linéaires.
- Former un réseau à 3 couches avec des données de processus en entrée et des composants principaux en sortie,
- Entraînez un deuxième réseau à 3 couches pour estimer les données d'origine avec les composants principaux non linéaires en entrée. La formation des deux réseaux à 3 couches peut être effectuée par tout algorithme approprié de gradients conjugués ou de Levenberg-Marquardt [71, 72].

#### 5.4. Analyse en composantes principales non linéaire (KPCA) :

Analyse non linéaire en composantes principales, identiquement éprouvée sous le nom d'ACP noyau ou ACP noyau, Schölkopf et al. [75] peut être considérée comme un déploiement de l'ACP classique. Cela nous permet de générer une réduction de dimensionnalité non linéaire en termes d'espace initial d'une image des données. Le principe est de projeter les données initiales à travers une fonction non linéaire  $\Phi(\cdot)$  dans un espace de plus grande valeur que d'habitude afin que les images contenant les variables (non linéaires) des données initiales puissent plus

facilement être séparées linéairement dans le nouvel espace, est appelé l'espace des caractéristiques. On peut alors obtenir une réduction de dimensionnalité non linéaire dans l'espace des données initiales en réalisant simplement une ACP classique sur cet espace linéaire. L'analyse en composantes principales (ACP) est la transformation de base qui diagonalise l'évaluation de la matrice de covariance des données  $x_k$ ,  $k = 1, \dots, \ell$ ,  $x_k \in \mathfrak{R}^N$ ,  $\sum_{k=1}^{\ell} x_k = 0$ , défini comme :

$$C = \frac{1}{\ell} \sum_{j=1}^{\ell} x_j x_j^T \quad (\text{II.92})$$

Les nouvelles assorties dans l'assise des vecteurs propres, la projection orthogonale sur les vecteurs propres, sont nommées composantes principales. Dans cette section, nous généralisons ce paramètre à un paramètre non linéaire du type suivant. Supposons que nous compressions d'abord les données de manière non linéaire dans un espace d'entités  $F$  par :  $\Phi : \mathfrak{R}^N \rightarrow F$ ,  $x \rightarrow X$ .

Nous montrerons que même si  $F$  à une dimensionnalité arbitrairement grande, pour certains choix de  $\Phi$ , on peut toujours effectuer l'ACP en  $F$ . Ceci est fait par l'utilisation des fonctions du noyau connues de Support Vector Machines [76].

Supposons pour le moment que nos données mappées dans l'espace des fonctionnalités,  $\Phi(x_1), \dots, \Phi(x_{\ell})$ , sont centrées, c'est-à-dire  $\sum_{k=1}^{\ell} \Phi(x_k) = 0$ . Pour faire l'ACP pour la matrice de covariance :

$$\bar{C} = \frac{1}{\ell} \sum_{j=1}^{\ell} \Phi(x_j) \Phi(x_j^T) \quad (\text{II.93})$$

On veut trouver la valeur propre  $\lambda \geq 0$  et le vecteur propre  $V \in F \setminus \{0\}$  qui satisfont  $\lambda V = \bar{C} V$ .

En substituant (II.93), nous notons que toutes les solutions  $V$  se trouvent dans l'étendue de  $\Phi(x_1), \dots, \Phi(x_{\ell})$ . Cela implique que l'on peut considérer le système équivalent :

$$\lambda(\Phi(x_k) * V) = (\Phi(x_k) * \bar{C} V) \text{ pour } : k = 1, \dots, \ell. \quad (\text{II.94})$$

et qu'il existe des coefficients  $\alpha_1, \dots, \alpha_{\ell}$  tel que :

$$V = \sum_{j=1}^{\ell} \alpha_j \Phi(x_j) \quad (\text{II.95})$$

Substituer (II.93) et (II.95) dans (II.94), et définir une  $\ell * \ell$  matrice  $K$  par :

$$K_{ij} = (\Phi(x_i) * \Phi(x_j)) \quad (\text{II.96})$$

Nous arrivons à :

$$\ell \lambda K \alpha = K^2 \alpha \quad (\text{II.97})$$

où désigne  $\alpha$  le vecteur de colonne avec les entrées  $\alpha_1, \dots, \alpha_\ell$ . Pour trouver des solutions de (II.97), nous résolvons le problème des valeurs propres :

$$\ell\lambda\alpha = K\alpha \quad (\text{II.98})$$

Pour les valeurs propres non nulles. Clairement, toutes les solutions de (II.98) satisfont (II.97). De plus, on peut montrer que les éventuelles solutions supplémentaires de (II.98) ne font pas de différence dans l'expansion (II.95) et ne sont donc pas intéressantes pour nous.

Nous normalisons les solutions  $\alpha^k$  appartenant à des valeurs propres non nulles en exigeant que les vecteurs homologues dans  $F$  soient normalisés, c'est-à-dire  $(V^k * V^k) = 1$  : en vertu de (II.95), (II.96) et (II.98), cela se traduit par :

$$1 = \sum_{i,j=1}^{\ell} \alpha_i^k \alpha_j^k (\Phi(x_i) * \Phi(x_j)) = (\alpha^k * K\alpha^k) = \lambda_k(\alpha^k * \alpha^k) \quad (\text{II.99})$$

Pour l'arrachement des composantes principales, nous calculons des projections de l'image d'un point de test  $\Phi(x)$  sur les vecteurs propres  $V^k$  dans  $F$  selon :

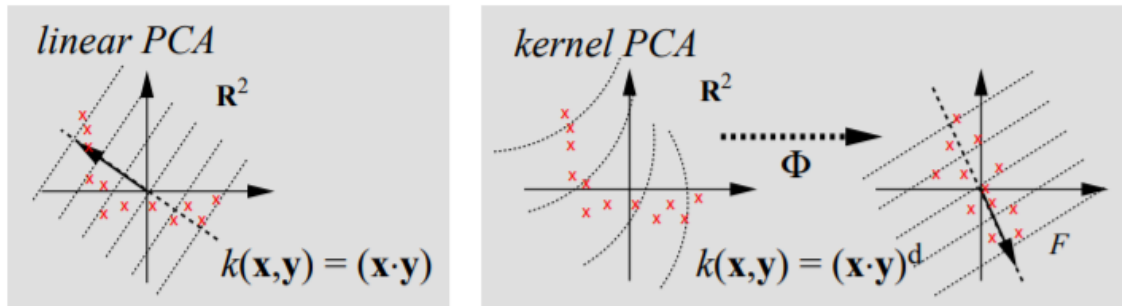
$$(V^k * \Phi(x)) = \sum_{i=1}^{\ell} \alpha_i^k (\Phi(x_i) * \Phi(x)) \quad (\text{II.100})$$

Notez que ni (II.96) ni (II.100) n'exigent le  $\Phi(x_i)$  sous forme explicite, ils ne sont nécessaires que dans les autres termes pour le produit intérieur. Par conséquent, nous pouvons utiliser les fonctions du noyau pour calculer ces produits scalaires sans effectuer réellement la carte [77, 78] : pour certains choix d'un noyau  $k(x; y)$ , on peut montrer par des méthodes d'analyse fonctionnelle qu'il existe une carte dans un espace de produit scalaire  $F$  (possiblement de dimension illimitée) telle que  $k$  calcule le produit scalaire dans  $F$ . Les noyaux qui ont été utilisés avec succès dans les machines à vecteurs de support [79] incluent les noyaux polynomiaux :

$$k(x, y) = (x * y)^d \quad (\text{II.101})$$

Fonctions de base radiale  $k(x, y) = \exp(-\|x - y\|^2 / (2\sigma^2))$ , et noyaux sigmoïdes  $k(x, y) = \tanh(k(x * y) + \theta)$ . On peut montrer que les noyaux polynomiaux de degré  $d$  correspondent à une carte  $\Phi$  dans un espace de caractéristiques qui est couvert par tous les produits de  $d$  entrées d'un modèle d'entrée, par exemple pour le cas  $N=2, d=2$ .

$$(x * y)^2 = (x_1^2, x_1x_2, x_2x_1, x_2^2)(y_1^2, y_1y_2, y_2y_1, y_2^2)^T \quad (\text{II.102})$$




**Figure.II.22.** principe de l'analyse en composantes principales du noyau KPCA.

La Figure(II.22), montre la notion de soubassement de l'ACP du noyau : en utilisant une fonction de noyau non linéaire  $k$  au lieu du produit scalaire standard, nous exécutons implicitement l'ACP dans un espace dimensionnel  $F$  possiblement élevé qui n'est pas lié de manière linéaire à l'espace d'entrée. Les lignes pointillées sont des courbes de niveau de valeur caractéristique constante.

Si les motifs sont des images, nous pouvons donc travailler dans l'espace de tous les produits de  $d$  pixels et ainsi prendre en compte des statistiques d'ordre supérieur lors de l'ACP.

En remplaçant les fonctions du noyau pour toutes les occurrences de  $(\Phi(x) * \Phi(y))$ , nous obtenons l'algorithme suivant pour le noyau PCA (Figure(II.23)) : nous calculons la matrice du produit scalaire (cf. Eq. (II.96))  $K_{ij} = (k(x_i, x_j))_{ij}$ , résoudre (II.98) en diagonalisant  $K$ , normaliser les coefficients d'expansion des vecteurs propres  $\alpha^n$  en exigeant l'Eq. (II.99), et extraire les composants principaux (correspondant au noyau  $k$ ) d'un point de test  $x$  en calculant des projections sur des vecteurs propres (Eq. (II.100), Figure(II.19)).



**Figure.II.23.**Extraction de fonctionnalités PCA du noyau pour une tâche OCR (point de test  $x$ , vecteur propre  $V$ ).

Il convient de souligner qu'en pratique, notre algorithme n'est pas équivalent à la forme de l'ACP non linéaire pouvant être obtenue en mappant explicitement dans l'espace des fonctionnalités  $F$  : même si le rang de la matrice de produit scalaire sera limité par le taillage de l'échantillon, nous ne pouvons même pas être capables de calculer cette matrice, si la dimensionnalité est prohibitive. Par exemple, 16 images d'entrée de 16 pixels et un degré polynomial  $d = 5$  donnent une dimensionnalité de  $10^{10}$ . Le noyau PCA traite ce problème en choisissant automatiquement un sous-espace de  $F$  (avec une dimensionnalité donnée par le rang de  $K$ ), et en fournissant un moyen de calculer les produits scalaires entre les vecteurs dans ce sous-espace. De cette façon, nous devons évaluer les  $\ell$  fonctions du noyau dans l'espace d'entrée plutôt qu'un produit scalaire dans un espace dimensionnel de  $10^{10}$ .

Pour conclure cette section, nous mentionnons brièvement le cas où nous abandonnons l'hypothèse que les  $\Phi(x_i)$  sont centrés dans  $F$ . Notez que nous ne pouvons pas en général centrer les données, car nous ne pouvons pas calculer la moyenne d'un groupe de points que nous n'avons pas sous forme explicite. Au lieu de cela, nous devons passer par l'algèbre ci-dessus en utilisant  $\tilde{\Phi}(x_i) := \Phi(x_i) - 1/\ell \sum_{i=1}^{\ell} \Phi(x_i)$ . Il s'avère que la matrice que nous devons diagonaliser en cela cas, appelez-le  $\tilde{K}$ , peut être exprimé en termes de  $K$  comme  $\tilde{K}_{IJ} = K - 1_{\ell}K - K1_{\ell} + 1_{\ell}K1_{\ell}$ ; en utilisant le raccourci  $(1_{\ell})_{ij} := 1/\ell$  (pour plus de détails, voir [80]).

## 6. Conclusion :

En cette partie, nous avons introduit le principe de l'analyse en composantes principales. Le concept de fondement de l'ACP est de simplifier la dimensionnalité de la matrice de données. Cette simplification n'est faisable que si les variables débutantes ne sont pas libres et que le coefficient de corrélation entre elles sont non nul. Ces variables débutantes sont modifiées en nouvelles variables dénommées composantes principales. Cette approche accepte d'explorer les rapports qui trouvent entre les variables et de reconnaître les liaisons entre les observations multivariées pour conquérir une image compressée de ces finales. L'ACP est donc utilisé comme manière pour modéliser les rapports entre diverses variables de processus. Les paramètres du modèle PCA sont estimés en estimant les valeurs de la matrice de corrélation et les vecteurs propres des données. Cependant, afin de déterminer la structure d'un modèle, il faut déterminer le nombre de composant (nombre de vecteurs propres) à conserver dans ce modèle. En fait, les principaux buts de l'ACP sont les suivants [42] :

- Réduire la dimensionnalité des données, c'est-à-dire représenter les données avec moins de nombre de variables aléatoires.

-Supprimer les dépendances des données, c'est-à-dire changer les données en un groupe de variables non liées.

Pour résumer, l'ACP transforme un groupe de variables dépendantes en un groupe de variables non corrélées, nommées composantes principales, qui sont ordinales, de sorte que la première composante contient la plupart des informations de l'ensemble de données d'origine. Étant donné qu'un changement de base est appliqué, l'ACP suppose clairement une relation linéaire entre les données originales. Dans les sections suivantes, nous présentons les indicateurs ainsi que les critères permettant la détection et la localisation des défauts en recourant aux méthodes fondées sur l'approche de l'analyse en composantes principales.

# **Chapitre III**

## **Détection et localisation des défauts par l'analyse en composantes principales (ACP)**

---

### 1. Introduction :

La philosophie de l'analyse en composante principale est de réduire la dimensionnalité des données d'origine en formant un nouvel ensemble de variables qui sont une combinaison linéaire des données d'origine, sans perte d'information essentielle.

Pour le diagnostic des défauts, cette méthode a pour objectif de détecter les défauts provenant par exemple de capteurs en temps réel et d'en déterminer l'origine. Il permet, pour chaque nouvelle mesure, de se prononcer sur sa validité par comparaison avec un modèle mathématique représentatif du fonctionnement normal du procédé. La première phase consiste donc à établir ce modèle. Il est obtenu en effectuant une analyse en composantes principales sur un tableau parfait de données. Cette approche permet d'obtenir une représentation globale du comportement des variables dans un espace de dimensionnalité réduit. Cette première étape est générique à la méthode présentée. La deuxième phase est celle de la détection réelle des défauts. Pour chaque nouvelle mesure, un test de cohérence est effectué entre celle-ci et le modèle. Des approches nouvelles minent l'erreur quadratique de la SPE prédite et l'indice de Hotelling  $T^2$  afin de détecter les échecs dans les mesures [83, 84, 85, 86, 87, 88]. Cependant, on ne peut pas dire quelle variable est biaisée. Ensuite, nous devons passer par la troisième étape : Afin de localiser les variables de défaut, mutiles techniques d'isolation d'anomalies basées sur l'analyse en composantes principales ont été présentées au cours de la dernière décennie.

La localisation des défauts a été développée en utilisant le modèle résiduel du modèle ACP [89]. Y compris Gertler et al. [90] ont utilisé une structure de résidu spéciale appelée ACP partielle. L'approche proposée par Dunia et al [35], ont détaillé le principe basé sur le refacturation. Cette approche est basée sur le SPE local ; nous comparons les SPE avant et après reconstruction pour définir les variables problématiques. Une méthode d'isolation fréquemment utilisée par l'ACP fondée sur le calcul de la contribution des variables individuelles au taux de détection ( $T^2$  ou SPE) [91, 4]. Ce chapitre vise à introduire le principe de détection et d'isolation des anomalies reposé sur l'analyse en composantes principales.

### 2. Détection de défauts :

Plusieurs métriques sont couramment utilisées pour détecter les défauts [23]. En règle générale, les exposants SPE et  $T^2$  de Hotelling trouvent exploitées afin de représenter la variation des données dedans l'espace résiduelles et la racine, respectivement. L'exposant de Hawkins  $T_H^2$  [4] également connu sous le nom de SWE, décrit aussi la variabilité des données dans l'espace

résiduel. Inversement à SPE, cette métrique est pondérée en fonction des valeurs propres de la matrice variance-covariance des données. Profitant de la dualité des indicateurs ci-dessus, les indices hypersensibles à l'ensemble de l'espace évoqué par les données sont présentés sous forme d'indicateurs de combinaison ou de distance de Mahalanobis.

L'existence d'une erreur affectant l'une des variables se traduit par une modification de la corrélation parmi les variables, montrant une anomalie car la relation dans les variables n'est encore validée. En cet exemple, la projection du vecteur métrique sur le sous-espace résiduel sera augmentée par rapport au cas normal. Pour détecter ce changement dans la corrélation entre les variables, l'ACP utilise une variété de mesures de détection.

### 1.1.Indices statistiques pour la détection de défauts :

La décision sur la présence d'un défaut est associée à l'étape de détection de défaut. L'étape de génération de résidus prend un modèle de travail bien établi et prend des mesures pour créer des signaux indicatifs de l'existence d'anomalies, appelés résidus [92]. Des décisions analytiques sont prises pour ces conditions résiduelles. Notez que le terme "résiduel" est utilisé pour illustrer que les projections de mesures dans l'espace résiduel mettent en évidence le bruit affectant ces mesures ; également, les projections d'amplitude anormalement élevée dans cet espace peuvent représenter des mesures anormales qui reflètent une défaillance. Utilisé pour projeter des observations dans l'espace principal.

Les défauts interfèrent avec la visualisation de l'espace principal et la projection de l'espace restant. Néanmoins, selon le modèle, la projection de défauts peut avoir un objectif plus important sur les espaces principaux ou restants. La présence de défauts est alors mise en évidence en utilisant l'indice de la variable dans l'un de ces sous-espaces : principalement SPE dans l'espace restant et  $T^2$  dans l'espace principal ou complet [23].

#### 1.1.1. Statistique SPE (Q-Statistic) :

La métrique SPE (erreur de prédiction au carré) assure la détection des défauts dans l'espace restant. Il est basé sur l'utilisation des propriétés statistiques du vecteur d'erreur d'estimations (résiduel)  $\tilde{x}$ . Cet exposant à chaque instant  $k$  est donné par :

$$SPE(k) = e^T(k)e(k) = \tilde{x}^T(k)\tilde{x}(k) \quad (\text{III-1})$$

Où  $e(k)$  est le vecteur d'erreurs d'estimation à l'instant  $k$ .

Compte tenu de l'équation (II.19) et de la propriété d'idempotence de la matrice  $\tilde{C}$  (II.21), l'indicateur SPE s'écrit :

$$SPE(k) = x^T(k) \tilde{C} x(k) \quad (\text{III-2})$$

A partir de l'équation (II.17), l'expression de SPE s'écrit :

$$SPE(k) = \|\tilde{t}(k)\|^2 \quad (\text{III-3})$$

L'indice SPE est basé par la variation de la corrélation entre les variables dans  $\mathbf{x}$  qui augmente la projection dans l'espace résiduel, par conséquent, l'amplitude de  $\tilde{x}$  porte des valeurs non désirées si on comparant celles-ci obtenus dans les conditions normales.

Pour détecter la présence d'anomalies,  $SPE$  doit vérifier les conditions suivantes :

$$SPE(k) > \delta_\alpha^2 \quad (\text{III-4})$$

Où  $\delta_\alpha^2$  représente la limite de détection de SPE. La limite de détection  $\delta_\alpha^2$  a été théoriquement quantifié par Jackson et Mudholkar [93] sous l'hypothèse que les données suivent une distribution normale multivariée :

$$\delta_\alpha^2 = \theta_1 \left[ \frac{c_\alpha \sqrt{2\theta_2 h_0^2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]^{\frac{1}{h_0}} \quad (\text{III-5})$$

Où  $\theta_i = \sum_{j=i+1}^m \lambda_j^i$  avec  $i = 1, 2, 3$  et  $\lambda_j$  est la  $j^{eme}$  valeur propre de la matrice de covariance  $\Sigma$  et

$$h_0 = 1 - \frac{2\theta_1\theta_3}{3\theta_2^2} \quad \text{et} \quad c_\alpha = \frac{\left[ \left( \frac{\|e\|^2}{\theta_1} \right)^{h_0} - 1 - \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1} \right]}{\sqrt{2\theta_2 h_0^2}} \quad (\text{III-6})$$

$c_\alpha$  est la limite du niveau de confiance dans le cas d'une distribution normale.

L'indice SPE peut être compris comme une métrique non capturée par le modèle ACP [94]. En d'autres termes, SPE est un test global qui somme les résidus [95] sans tenir compte des différentes variances entre ces valeurs, et accumule ainsi les erreurs [54]. La sensibilité de l'indice SPE aux faussetés de modélisation conduit à un grand nombre de faux positifs. Cependant, un test de fausse détection est considéré comme ayant une forte probabilité de détection si sa probabilité de fausse alarme est faible.

Afin de réduire le taux de faux positifs et d'améliorer la qualité de la détection, Harkat et al [54], suggérons d'utiliser le filtre EWMA [34]. Cependant, ce dernier entraîne un retard de détection. Par conséquent, il semble clair que SPE est relativement inefficace. Face à ce

problème, Harkat et al. Il est recommandé d'appliquer la métrique SPE au sous-espace résiduel, car les défauts affectant certaines variables peuvent être détectés à partir du sous-espace résiduel de dimensionnalité bien inférieure à la métrique SPE.

### 1.1.2. Statistique $T^2$ de Hotelling :

La statistique  $T^2$  de Hotelling mesure la variation de la projection observée chez l'espace principal. Il est compté à partir de la première composante  $\ell$  :

$$T^2(k) = \hat{t}^T(k) \Lambda_\ell^{-1} \hat{t}(k) = \sum_{i=1}^{\ell} \frac{t_i^2}{\lambda_i^2} \quad (\text{III-7})$$

Où  $\Lambda_\ell = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_\ell)$  est une matrice diagonale contenant les  $\ell$  plus grandes valeurs propres de la matrice de corrélation.

Pour détecter la présence d'une anomalie la statistique  $T^2$  doit vérifier la condition suivante :

$$T^2(k) > \chi_{\ell, \alpha}^2 \quad (\text{III-8})$$

Où  $\alpha$  la borne supérieure du seuil de confiance pour  $\chi_{\ell, \alpha}$  est obtenue par :

$$\chi_{\ell, \alpha}^2 = \frac{\ell(N+1)(N-1)}{N(N-\ell)} F_{\ell, (N-\ell), \alpha} \quad (\text{III-9})$$

Où  $F_{\ell, (N-\ell)}$  est distribution du Fisher, donc pour déterminer ce seuil, la statistique  $T^2$  doit être suivie cette distribution.

Il est clair que la statistique  $T^2$  basée sur les premières composantes principales qui sont représentées le processus normal de comportement, en aspect théorique capable de représenter ce comportement n'est pas affectée par les bruits apportés par aspect les composantes l'autre principale, avec les d' l'utilisation de cette statique est rarement vérifiée à cause de la corrélation entre les variables du processus qui ne suit Nécessairement une distribution normale [54].

### 1.1.3. Statistique SWE :

L'indice SWE (Squared Weighted Error), également appelé indice de Hawkins, est semblable à le statistique  $T^2$  dans l'espace résiduel. L'indice SWE peut également représenter comme SPE modéré par le transpose de la variance de la dernière caractéristique dominante [4], exprimée par :

$$SWE(k) = e^T \Lambda_{m-\ell}^{-1} e = x^T(k) \tilde{P} \Lambda_{m-\ell}^{-1} \tilde{P}^T x(k) \quad (\text{III-10})$$

Où  $\Lambda_{m-\ell}^{-1} = \text{diag}(\lambda_{\ell+1}, \dots, \lambda_m)$  est la matrice en diagonale récipient les  $(m-\ell)$  terminales valeurs propres de la matrice de corrélation  $\Sigma$ .

Cette statistique accompagne une distribution du chi-2 à l'égard de  $(m-\ell)$  degrés de liberté :

$$SWE(k) = \tilde{t}^T(k) \Lambda_{m-\ell}^{-1} \tilde{t}(k) \quad (\text{III-11})$$

Le processus est prétendu en anomalie si :

$$SWE(k) > \chi_{(m-\ell), \alpha}^2 \quad (\text{III-12})$$

#### 1.1.4. Statistique combinée $\zeta$ :

Les statistiques combinées utilisent les indices  $T^2$  et SPE afin de dériver une nouvelle statistique de détection d'anomalies. Yue et Qin [96] proposent de définir un indice qui couvre tout l'espace de représentation des données, combine les indices précédents et normalisé à leurs seuils respectifs. Cette statistique combinée, notée  $\zeta$  représentée par, à l'expression :

$$\zeta(k) = \frac{SPE(k)}{\delta_\alpha^2} + \frac{T^2}{\chi_{l,\alpha}^2} = x^T(k) \mathcal{M} x(k) \quad (\text{III-13})$$

où  $\mathcal{M}$  est donné par :

$$\mathcal{M} = \frac{(1-\hat{p}\hat{p}^T)}{\delta_\alpha^2} + \frac{\hat{p}\Lambda_{m-\ell}^{-1}\hat{p}^T}{\chi_{l,\alpha}^2} = \frac{\hat{p}\hat{p}^T}{\delta_\alpha^2} + \frac{\hat{p}\chi_l^2\hat{p}^T}{\chi_{l,\alpha}^2} \quad (\text{III-14})$$

et où  $\delta_\alpha^2$  et  $\chi_{l,\alpha}^2$  représentent respectivement les seuils de détection de SPE et de  $T^2$ .

Notons que  $\mathcal{M}$  est une matrice symétrique et définie positive.

$$\zeta(k) = x^T(k) \mathcal{M} x(k) \sim g \chi_h^2 \quad (\text{III-15})$$

où le coefficient  $g$  est donné par :

$$g = \frac{\sum_{j=1}^m \lambda_j^2}{\sum_{j=1}^m \lambda_j} = \frac{\text{trace}(\Sigma \mathcal{M})^2}{\text{trace}(\Sigma \mathcal{M})} \quad (\text{III-16})$$

$\lambda_j$  est la  $j^{\text{ième}}$  valeur propre de la matrice  $\Sigma \mathcal{M}$  et le quantité de degrés de liberté pour le  $\chi^2$  est déterminé par :

$$h = \frac{(\sum_{j=1}^m \lambda_j)^2}{\sum_{j=1}^m \lambda_j^2} = \frac{(\text{trace}(\Sigma M))^2}{\text{trace}(\Sigma M)^2} \quad (\text{III-17})$$

Après définir de  $g$  et  $h$ , l'anomalie peut être découvert si :

$$\zeta(k) \geq g \chi_{h,\alpha}^2 \quad (\text{III-18})$$

Une fois qu'un défaut est détecté, la deuxième étape du diagnostic des données est l'emplacement d'anomalie aperçu et l'estimation de l'ampleur de l'anomalie.

### 1.2. Filtrage EWMA pour la détection :

Pour optimiser la valeur de la détection et diminuer les faux positifs, un filtre EWMA (moyenne mobile pondérée exponentiellement) [83] peut être utilisé aux résidus. La formule globale pour appliquer ce filtre aux résidus est :

$$\bar{e}(k) = (I - \beta)(\bar{e}(k-1) + \beta e(k)) \quad (\text{III-19})$$

Où  $\beta$  est une matrice en diagonale desquels les objets sont des facteurs d'oubli résiduels,  $I$  est une matrice d'identité et  $\bar{e}(0) = 0$ .

Le nouveau  $SPE$  filtré  $\overline{SPE}$  appliqué sur les résidus est donné comme suit :

$$\overline{SPE}(k) = \|\bar{e}(k)\|^2 \quad (\text{III-20})$$

où  $\bar{e}(k)$  et  $\overline{SPE}(k)$  sont les vecteurs des résidus et  $SPE$  filtrés.

Qin.al [87] a été développé le statistique  $\overline{SPE}$ , et pour simplifier les calculs ils supposent que la matrice des facteurs d'oubli est présenté comme suit :

$$\beta = \gamma I \quad (\text{III-21})$$

où  $\gamma$  est un facteur d'oubli, on utilise l'équation (III-18) pour purifier les données, puis déterminer les résidus. D'où :

$$\bar{x}(k) = (I - \gamma)(\bar{x}(k-1) + \gamma x(k)) \quad (\text{III-22})$$

$$\bar{e}(k) = (1 - C)\bar{x}(k) \quad (\text{III-23})$$

Dans lequel  $\bar{x}(k)$  montrent là le vecteur des données filtrées. En présupposant  $x(k)$  est un processus indépendant, le rapport de covariance suivante peut être remontée à partir de l'équation (III-22) :

$$\bar{\Sigma} = \frac{\gamma}{2-\gamma} \Sigma \quad \text{(III-24)}$$

La matrice  $\Sigma$  est la matrice de covariance de  $x(k)$  et la matrice  $\bar{\Sigma}$  est la matrice de covariance de  $\bar{x}(k)$ , les valeurs propres de  $\Sigma$  et  $\bar{\Sigma}$  sont assemblées par :

$$\bar{\lambda}_i = \frac{\gamma}{2-\gamma} \lambda_i \quad \text{pour } i = 1, \dots, m \quad \text{(III-25)}$$

Donc, par analogie avec les équations (III-4) (III-5) (III-6), on peut écrire :

$$\overline{SPE} > \bar{\delta}_\alpha^2 \quad \text{(III-26)}$$

$$\bar{\delta}_\alpha^2 = \frac{\gamma}{2-\gamma} \delta_\alpha^2 \quad \text{(III-27)}$$

Cette expression relie les statistiques SPE filtrées par une constante aux statistiques SPE non filtrées.  $\overline{SPE}$  Le filtrage déterminer une zone de confiance plus proche que SPE.

## 2. Localisation de défauts :

Après avoir détecté l'erreur, il est essentiel que les variables mentionnées. Dans la littérature, le sujet du diagnostic des pannes n'est pas aussi préoccupant que celui de la détection des erreurs. La règle générale est de construire d'abord une composition de résidus qui attachent a priori de toutes les valeurs par défaut. Ils sont alors construits de manière plus granulaire et moins sensibles à certaines erreurs [92]. En ce qui concerne la localisation des erreurs ACP, nous distinguons ces méthodes. La première est basée sur la structure résiduelle dans le cas des espaces pairs-impairs. D'autres méthodes utilisent des tables de modélisation où chaque table est sensible à un ensemble de défauts mais au lieu par exemple des méthodes d'ACP partielle ou des méthodes d'élimination, basées sur le même principe on retrouve le reste selon le principe de reconstruction [54].

Ces approches peuvent être regroupées en deux groupes dans la méthode utilisée pour structurer les résidus [32]. Dans ce contexte, on distingue les méthodes de localisation sans ou avec optimisation des résidus aux défauts.

### 2.1. Méthodes sans optimisation des résidus aux défauts :

Dans ce groupe des méthodes, on trouve :

- le calcul des contributions,
- les ACP partielles,
- la méthode d'élimination.

#### 2.1.1. Localisation par calcul des contributions :

Les méthodes de localisation par calcul des participations sont très efficaces [23, 24, 4, 54]. Il est généralement basé sur l'estimation de la part de toute variable dans l'opération d'une métrique de détection donnée. L'approche est fondée sur le concept que les variables qui contribuent le plus à la métrique de détection de fautes sont les plus pointilleux de porter des fautes. Elle comporte à définir la participation de chaque variable aux métriques de détection de fautes utilisées [93, 4, 54].

#### Contribution à l'indice SPE :

Miller et al. [91] ont proposé la participation exacte de la  $j^{ième}$  variable à l'indice SPE :

$$cont_j^{SPE}(k) = \left( e_j(k) \right)^2 = (x_j(k) - \hat{x}_j(k))^2 \quad (\text{III-28})$$

Si l'on examine le vecteur de mesure subséquent, duquel la  $i^{ième}$  composante est affectée par l'anomalie  $d$  :

$$x = x^* + \xi_i d \quad (\text{III-29})$$

Le vecteur résiduel peut être conquis par la relation suivante :

$$e(k) = (I - \hat{P}\hat{P}^T)x(k) = \tilde{C}(x^*(k) + \xi_i d(k)) \quad (\text{III-30})$$

Le SPE peut être calculé par :

$$SPE(k) = e^T(k)e(k) = \sum_{j=1}^m e_j^2(k) \quad (\text{III-31})$$

A partir de l'équation (III-29), la quantité  $e_j$  peut être exprimée par :

$$e_j(k) = \sum_{l=1}^m \tilde{C}_{jl} x_l^*(k) + \tilde{C}_{jl} d(k) \quad (\text{III-32})$$

Par conséquent, la participation de la  $j^{ième}$  variable à SPE sera déterminée également :

$$cont_j^{SPE}(k) = \left( \sum_{l=1}^m \tilde{C}_{jl} x_l^*(k) + \tilde{C}_{jl} d(k) \right)^2 \quad (\text{III-33})$$

Dans lequel les participations de l'entières des variables sont affectées par les valeurs par anomalie.

**Contributions à l'indice  $T^2$  :**

Wise et Gallagher [113] proposent d'évaluer la contribution de la variable à l'indice  $T^2$ , donc la participation globale de la variable à la  $i^{ième}$  composante principale normalisée  $\left(\frac{t_i}{\sigma_i}\right)^2$  est définie comme :

$$cont_i(k) = \frac{t_i(k)}{\sigma_i^2} \sum_{j=1}^m p_{ij} x_j(k) \quad (III-34)$$

où  $p_{ij}$  est la  $j^{ième}$  constituante du vecteur propre  $p_i$  et  $\sigma_i = \sqrt{\lambda_i}$ .

On estime la participation de la variable  $x_j$  à cette composante principale standardisée  $\left(\frac{t_i(k)}{\sigma_i}\right)^2$  par :

$$cont_{ij}(k) = \frac{t_i(k)}{\lambda_i} p_{ij} x_j(k) \quad (III-35)$$

La participation intégrale de la variable  $x_j(k)$  à l'indice  $T^2$  au temps  $k$  sera présenté par :

$$cont_j^{T^2}(k) = \sum_{i=1}^l cont_{ij}(k) \quad (III-36)$$

A partir de cette formule de contribution, nous pouvons voir que chaque contribution dépend de l'intersection de la variable considérée avec d'autres variables.

Cependant, la contribution aux différents indices de détection réside dans les amplitudes des variables [56]. La variable avec la valeur la plus élevée est susceptible d'être suspectée d'être l'erreur majeure, conduisant à une mauvaise localisation. En effet, Yoon et MacGregor [94] ont démontré que, dans le cas d'un défaut et quelle que soit la marge d'erreur, la contribution classique ne peut garantir que le capteur défaillant est celui qui a la plus forte contribution.

Pour éviter une fausse localisation, une approche appelée contribution hiérarchique a été proposée [95]. Le principe de cette approche basée sur la division des  $m$  variables en  $n$  blocs et à calculer les contributions des différents blocs. Comparée à l'approche de contribution classique, la contribution hiérarchique donne une indication plus claire de l'ensemble des variables en défaut [23].

### 2.1.2. Localisation par ACP partielles :

Gertler [90] utilise une structuration particulière des résidus appelés ACP partielles ou modèles partiels. L'ACP partielle consiste à réduire le vecteur de données en écartant certaines variables du vecteur de départ. Ainsi, les résidus ne sont sensibles qu'aux imperfections liées aux variables qui forment le vecteur réduit. Le processus comprend la création d'un indice de détection (à l'aide de la métrique SPE) pour une partie de l'ACP. Après un test logique de ces indices par rapport à leurs seuils respectifs, une matrice de caractéristiques expérimentales peut être obtenue. Le principe de cette méthode est explicité par l'algorithme suivant [96] :

#### a- Procédure de structuration des résidus :

Le programme comprend :

- Appliquer l'ACP à la matrice de données pour retenir les variables les plus pertinentes.
- Construire une matrice de caractéristiques théoriques hautement localisées.
- Construire un ensemble de modèles ACP partiels.
- Déterminer le seuil de détection pour chaque modèle partiel.

**Remarque :** La matrice d'incidence ou la matrice des signatures théoriques transforme les sensibilités des résidus liées à l'éventuel défaut [97]. Elle est constituée de 0 pour indiquer l'insensibilité des résidus aux défauts et de 1 pour indiquer la sensibilité.

#### b- Procédure de surveillance en ligne :

Après obtenir les modèle ACP partielles, le test de localisation peut s'effectuer en ligne comme l'illustre la figure (III-1) [96]. Des nouvelles observations sont évalués vis-à-vis l'ensemble structuré comme suit :

- Calculer l'indice de détection pour chaque modèle ACP partielle correspondant les nouvelles observations,
- Comparer les indices de détection à chaque seuil approprié et déterminer la matrice des signatures expérimentales du défaut  $\eta$  suivant :

$$\eta_i = \begin{cases} 0 & \text{Si } e_i < \text{seuil}_i \\ & (i = 1, 2, \dots, P) \\ 1 & \text{Si non} \end{cases} \quad (\text{III-37})$$

– Comparer les caractéristiques expérimentales du défaut avec les colonnes de la matrice de corrélation (matrice des caractéristiques théoriques), la variable par défaut est la variable correspondant à la même colonne de la caractéristique théorique.

L'ACP partielles donne des résultats efficaces, mais souffre du problème de temps, à cause du nombre de modèles utilisés.

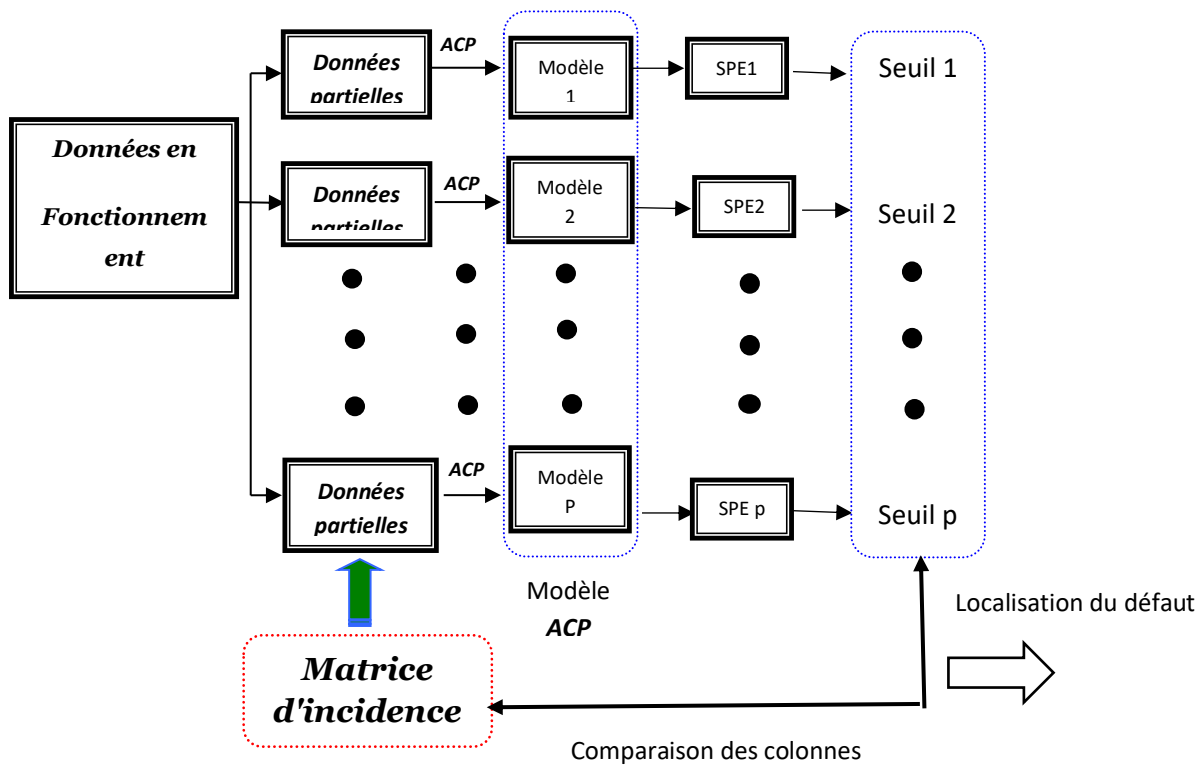


Figure. III.1. Procédure de localisation par ACP partielle structurée.

### 2.1.3. Localisation par la méthode d'élimination :

Cette approche, proposée par Stork [98], consiste à éliminer une variable à la fois de l'ensemble des variables à contrôler et à recalculer l'indice SPE. Par conséquent, en utilisant l'ACP pour décomposer la matrice de données X, où la  $j^{\text{ième}}$  variable  $X_j$  est éliminée, sera donnée par :

$$X_{-j} = T_{-j}P_{-j}^T + E_{-j} \quad (j = 1, 2, \dots, m) \quad (\text{III-38})$$

L'indice  $SPE(k)$  est présenté à l'instant k, par :

$$SPE_{-j}(k) = X_{-j}^T(k)(I_{m-j} - \hat{P}_{-j}\hat{P}_{-j}^T)X_{-j}(k) \quad (\text{III-39})$$

Où  $X_{-j}(k)$  représente le vecteur  $X(k)$  à l'instant  $k$ , après annulation de la  $j^{\text{ième}}$  variable,  $\hat{P}_{-j}$  représente la matrice  $\hat{P}$  du spécimen ACP dont la  $j^{\text{ième}}$  ligne est exclue.

Répétez ce processus en excluant une variable à la fois. La grandeur déterminée par  $Q_r$  évoque la relation entre  $SPE_{-j}$  et la valeur limite correspondante que nous représenterons  $\delta_{\alpha,-j}^2$  [99] donc calculez  $m$  modèles :

$$Q_r = \frac{SPE_{-j}}{\delta_{\alpha,-j}^2} \quad (\text{III-40})$$

La variable exclue, dont la montant de la relation  $Q_r$  est la plus petite, est contemplée comme la variable coupable. Cette méthode permet de localiser les défauts dans l'espace restant. Cependant, sa sensibilité aux erreurs de modélisation peut engendrer de fausses localisations [54].

## 2.2. Méthodes à base d'optimisation des résidus aux défauts :

On distingue deux méthodes, dans cette catégorie:

- la méthode de structuration des résidus,
- la méthode de reconstruction de variables.

### 2.2.1. Localisation basée sur la structuration des résidus :

Gertler et al ont été les premiers à proposer une méthode de cartographie basée sur des structures de résidus obtenues par ACP [89]. La méthode consiste à trouver une transformation  $W$  telle que tout résidu soit changé pour être sensible à un défaut et insensible à un autre, l'objectif est de remporter une signature théorique de chaque défaut pour aptitude localiser les variables d'erreur. Une autre méthode de la structure résiduelle présentée par Huang et al. [96] ont inclus l'utilisation de l'ACP partielle (ACP en tenant une quantité minimale de variables), de sorte que la statistique de détection (SPE dans son cas) acquis afin que toute modèle partiel ne serait sensible qu'à un ensemble spécifique de variables et pas aux autres. Pendant les incidents où un faute altérer l'une des variables, une signature expérimentale est produite en évaluant distincts SPE correspondant à différentes parties du modèle afin d'identifier la variable en défaut. Qing et ainsi de suite. En se fondant sur les travaux de Gertler et al, [100] ont proposé une méthode de structuration résiduelle qui permet de maximiser la sensibilité aux défauts.

La structure résiduelle de l'ACP est similaire à celle minée pour l'isolation des anomalies avec l'espace de parité, lors de l'utilisation d'un modèle de système qui relie sa sortie à son entrée sous forme d'équations [89].

La première étape de la structure résiduelle consiste à définir la matrice théorique des caractéristiques. Cette matrice de caractéristiques théorique transforme la susceptibilité des résidus à divers défauts possibles. Ensuite, en comparant les caractéristiques théoriques et expérimentales de chaque instant, le défaut peut être localisé.

En ACP, le vecteur de mesure au marché régulier est montré par la relation suivante [54] :

$$X^*(k) = \hat{P}\hat{t}^*(k) + \tilde{P}\tilde{t}^*(k) \quad (\text{III-41})$$

Où un astérisque indique que la mesure ne contient pas de défauts. Puisque  $\hat{P}$  et  $\tilde{P}$  sont perpendiculaires, en multipliant cette équation par  $\tilde{P}^T$ , on obtient le vecteur résiduel subséquent, qui indique le vecteur de la dernière composante principale :

$$\tilde{P}^T X^*(k) = \tilde{P}^T \tilde{P}\tilde{t}^*(k) = \tilde{t}^*(k) \quad (\text{III-42})$$

La relation parmi le vecteur résidu primaire  $\tilde{t}(k)$  et le vecteur résidu structuré  $r(k)$  est liée de la manière suivante :

$$r(k) = W\tilde{t}(k) = W\tilde{P}^T X(k) \quad (\text{III-43})$$

Où  $W \in^{m \times (m-l)}$  est la matrice de transformation, et  $m$  et  $l$  sont respectivement la grandeur de variables et la quantité de composantes principales maintenues.

Pour la suite, on note :

$$B = \tilde{P}^T \quad (\text{III-44})$$

La  $i^{\text{ième}}$  ligne de la matrice  $W$ , notée  $w_i^T$ , respecte l'exigence suivante :

$$w_i^T B^i = 0 \quad (\text{III-45})$$

Où  $B^i$  est la matrice qui regroupe les colonnes de la matrice  $B$  qui correspondent aux riens dans la  $i^{\text{ième}}$  ligne de la matrice d'incidence (les variables insensibles aux défauts).

Pour que la localisation devienne possible, il faut que les deux conditions de la transformation soient satisfaites :

-La quantité de zéros par ligne de la table de signature théorique ne doit pas dépasser  $(m - \ell - 1)$ . La matrice  $B^i$  doit satisfaire l'inégalité suivante [89] :

$$\text{rang}(B^i) \leq m - l - 1 \quad (\text{III-46})$$

Aussi, afin de ne pas avoir de zéros indésirables dans l'une des lignes de la matrice structurée, c'est-à-dire pour que les résidus ne soient pas séparés des défauts avec des 1 dans une ligne de la matrice théorique des caractéristiques, condition saine :

$$\text{rang}(B^i \ b_j) = \text{rang}(B^i) + 1 \quad (\text{III-47})$$

En fait, quand deux colonnes de la matrice B sont linéairement dépendantes, les deux résidus structurés relatifs à ces deux colonnes peuvent avoir la même signature (signature dégradée) et par conséquent les défauts ne sont pas isolables [101]. Cependant, même si ces deux conditions sont satisfaites, il est souvent difficile de trouver la matrice des signatures expérimentales souhaitées étant donné que certaines signatures expérimentales sont dégradées, en particulier pour un système de grande dimension. En fait, la matrice de corrélation est choisie en fonction de sa capacité de localisation (forte capacité de localisation), à l'exclusion de la sensibilité des résidus aux anomalies [54]. Pour maximiser cette sensibilité, Qin et al. [95] ont offert la méthode de construction de résidus pour maximiser la sensibilité aux défauts (Structured Residual Approach with Maximized Sensitivity SRAMS).

### 2.2.2. Localisation basée sur le principe de reconstruction :

L'approche est fondée sur le fondement de reconstruction [35] et comporte à incriminer un variable d'être défectueux et à reconstruire ses mesures à partir d'un modèle de calcul et des mesures d'autres capteurs, en répétant le processus pour chaque capteur. Deux approches, aboutissant à la même solution, peuvent être utilisées. Une minimise l'influence des variables sur l'indicateur de détection [28]. L'autre minimise l'influence de défauts sur une observation et permet d'estimer à la fois la direction et l'amplitude du défaut [23], [30]. La localisation du défaut est effectuée en comparant les métriques de détection avant et après la reconstruction. Ce principe peut s'appliquer à divers indicateurs de détection d'une exposition antérieure.

Le vecteur de mesure rétablit est miné pour déterminer un groupe de résidus. Pour conquérir ces distincts résidus, Dunia et al. [35] définit la matrice  $G_j$ :

$$G_j^T = [ \xi_1 \ \xi_2 \ \dots \ g_j \ \dots \ \xi_m ] \quad (\text{III-48})$$

$$\text{Où } G_j^T = \frac{1}{1-c_{jj}} [c_{-j}^T \ 0 \ c_{+j}^T].$$

$G_j$  utilisé pour déterminer le vecteur de mesure reconstruit  $x_j$  à base de la vecteur d'entrée  $x$  :

$$x_j^T = x^T G_j^T = [x_1 \dots z_j \dots x_m] \quad (\text{III-49})$$

Si on note par  $SPE_j$ , le SPE définir ensuite le rétablissement de la  $j^{\text{ième}}$  variable donc on peut écrire :

$$SPE_j = \|\tilde{x} - \tilde{d}_j \tilde{\xi}_j^0\|^2 = \|\tilde{x}\|^2 - \tilde{d}_j^2 = SPE - \tilde{d}_j^2. \quad (\text{III-50})$$

Rappelons que  $\tilde{x} = e$ ,  $\tilde{d}_j$  est la détermination du anomalie dans la direction  $\xi_j$  jeté dans le sous-espace résiduel et que  $\tilde{\xi}_j^0 = \tilde{\xi} / \|\tilde{\xi}\|$ .

$$SPE - SPE_j = \tilde{d}_j^2 \quad (\text{III-51})$$

À base de l'équation (III-51), les défauts peuvent être identifiés en comparant simplement les grandeurs de SPE et  $SPE_j$ .

Par des résidus déterminés avant et après reconstruction, on peut déterminer l'indice de validité du capteur (IVC) :

$$\eta_j^2 = \frac{SPE_j}{SPE} = 1 - \frac{\tilde{d}_j^2}{SPE} \quad (\text{III-52})$$

Où SPE est déterminé avant reconstruction, et  $SPE_j$  est déterminé après reconstruction de la valeur du  $j^{\text{ième}}$  capteur.

### Conditions nécessaires et suffisantes pour la localisation par reconstruction :

Nous disposons présenté que la reconstruction enlever les erreurs d'estimation des variables reconstruites. Alors, si nous supposons que la dimension de l'espace résiduel est  $(m - \ell) = l$ . Donc la formule du vecteur résiduel est :

$$e = p_m t_m \quad (\text{III-53})$$

Où  $t_m$  est la finale composante principale et  $p_m$  est le final vecteur propre. Souvenons-nous  $p_m = [p_{1m} p_{2m} \dots p_{mm}]^T$ , alors tous les résidus sont les mêmes avant le facteur  $p_{im}$ . Par conséquent, les conditions nécessaires à la localisation par reconstruction sont données par :

$$(m - \ell) \geq 2 \text{ et } \xi_j^0 \neq \xi_i^0 \quad \forall i \neq j \quad (\text{III-54})$$

Cette condition stipule que les directions dans lesquelles les défauts se projettent sur le sous-espace restant ne peuvent pas être colinéaires.

### 3. Conclusion :

Ce chapitre est consacré à l'introduction des approches de détection et de localisation des défauts dans le cadre des procédures de diagnostic par analyse en composantes principales linéaires. L'ACP recherche un sous-espace plus étroit que l'espace d'origine et les y projette avec une perte minimale d'informations. Par conséquent, les résultats obtenus permettent de modéliser les relations entre les variables mesurées et d'estimer le comportement de cette dernière variable à partir du modèle PCA défini. Ces relations sont utilisées par après avoir détecté et localisé de défauts.

La détection des pannes est basée sur des métriques de détection : espace restant ; indices SPE et SWE, espace primaire ; indice  $T^2$  et espace global  $\zeta$ .

Différentes méthodes de localisation sont également introduites. Dans un premier temps, nous introduisons le rationnel de la méthode de positionnement des résidus sans optimisation dans le cadre de l'ACP et les différentes approches présentées. Dans cette méthode, il existe trois méthodes. Méthodes utilisant l'ACP partielle, méthodes minant le fondement de contribution et méthodes minant le principe d'élimination. Néanmoins, en le cas des méthodes de l'ACP partielles, il n'est nullement clair si un modèle de l'ACP réduit peut être développé a priori, d'autant davantage qu'il mine SPE quand métrique de détection. La deuxième approche concerne la méthode de calcul de la contribution des variables aux indicateurs de détection. La troisième méthode proposée est d'utiliser le principe d'élimination, c'est-à-dire d'éliminer à tout coup une variable de le groupe des variables à contrôler, puis d'utiliser l'indice de détection à sélectionner pour le calcul. La deuxième approche présentée dans ce chapitre implique l'utilisation de méthodes d'optimisation résiduelle basées sur les défauts. Dans cette approche, deux approches ont été trouvées, une qui exploite les principes de structuration des résidus, et nous soulignons les limites de cette approche. Il convient de noter que ces méthodes recherchent des matrices de signatures théoriques fortement localisées sans considérer les résidus dominants aux différents défauts. La dernière approche proposée utilise le principe de reconstruction qui basé sur la suspicions d'un capteur défaillant et à reconstruire ses mesures à partir du modèle PCA et des mesures d'autres capteurs.

# **Chapitre IV**

## **Principe de fonctionnement d'une turbine à gaz.**

---

## 1. Introduction :

Pour bien vérifier et illustrer les performances de l'approche basée sur l'analyse en composantes principales (ACP) dans le domaine de diagnostic des défauts (détection et localisation de défauts), nous avons utilisé les données fournies par un processus de production de l'énergie électrique à cycle simple (turbine à gaz), qui appartient à la société algérienne de l'électricité et du gaz-production de l'électricité, au sien de la centrale électrique d'ANNABA. OÙ ce chapitre est consacré pour une description générale de la turbine à gaz modèle 6B fabriqué par général électrique (GE).

### Présentation de la Centrale à Turbine à Gaz d'Annaba :

La centrale à turbine à gaz d'Annaba constitue une installation moderne et stratégique dans le paysage énergétique de l'Algérie. Conçue pour répondre à une demande croissante en électricité, elle joue un rôle clé dans l'équilibre du réseau électrique national grâce à sa capacité de démarrage rapide et sa grande flexibilité opérationnelle.

- **Emplacement** : Située dans la région d'Annaba, cette centrale bénéficie d'une position géographique avantageuse, facilitant ainsi son intégration au réseau national et la distribution de l'électricité aux zones industrielles et urbaines environnantes.

- **Contexte industriel** : La ville d'Annaba, reconnue pour son dynamisme économique et industriel, profite de la proximité de cette installation qui contribue significativement à la sécurité énergétique régionale.

- **Principe de base** : La centrale utilise des turbines à gaz qui fonctionnent par la combustion de gaz naturel. L'énergie dégagée par cette combustion est transformée en énergie mécanique, laquelle est convertie en électricité par un générateur.

#### - Avantages technologiques :

- **Démarrage rapide** : Permet une réponse immédiate lors des pics de demande ou en cas de défaillance d'autres sources de production.

- **Flexibilité** : Capacité d'adaptation aux variations de charge, garantissant une exploitation optimale et une meilleure gestion du réseau.

- **Efficacité énergétique** : Grâce à l'intégration de technologies avancées, la centrale affiche une haute efficacité, ce qui contribue à optimiser la production d'électricité et à réduire les coûts opérationnels.

- **Contribution au réseau** : En fournissant une source d'énergie stable et réactive, la centrale renforce la fiabilité du réseau électrique algérien, participant ainsi au développement économique régional.

La centrale à turbine à gaz d'Annaba se distingue par sa capacité à fournir une électricité de haute qualité en assurant rapidité, flexibilité et fiabilité. Son rôle stratégique dans le réseau énergétique national et son potentiel de modernisation en font un atout majeur pour l'avenir énergétique de l'Algérie.

## 2. Description générale de la centrale :

La centrale électrique composée de deux unités, chaque unité est composée des principaux équipements suivants :

- Une turbine à combustion utilisant le gaz naturel et le fuel liquide comme combustible, qui se comporte des équipements suivants :

- Section compresseur :

Nombre d'étages du compresseur : dix-sept (17)

Type de compresseur : compresseur axial

Corps compresseur : à joint horizontal

Type d'aubes à l'entrée du compresseur : modulées

- Section turbine :

Nombre d'étages turbine : trois (3) (à un seul arbre)

Directrices : à aubes fixes

Corps turbine : à joint horizontal

- Section combustion :

Type : à 10 chambres de combustion, flux inversé

Injecteurs : un (1) par chambre de combustion

Bougies : deux (2) à électrodes rétractables

Détecteurs de flamme : quatre (4), aux ultraviolets

- Paliers :

Nombre : deux (2)

Lubrification : à huile sous pression

Palier N° 1 (situé dans le corps d'admission du à trois ensembles : palier elliptique, butées, contrebutées).

Palier N° 2 (situé dans le corps d'échappement)

- Dispositif de démarrage :

Moteur de lancement Moteur de lancement électrique

Convertisseur de couple hydrodynamique à multiplicateur inverseur et vireur hydraulique intégré

- Système combustible liquide :

Combustible utilisé : fuel léger

Système de régulation du combustible : régulation SPEEDTRONC MARK VI

Pompe à combustible liquide : entraînée par le réducteur des auxiliaires. Pompe à engrenages, à débit fonction de la vitesse.

Diviseur de débit.

Vanne d'arrêt du combustible : à commande électrohydraulique

Filtre(s) circuit combustible turbine : deux (2) filtres H.P. à cartouches 5 microns

- Système de lubrification :

Lubrifiant : à base d'hydro-carbure

Capacité du réservoir d'huile : 6500 litres (approximatif)

Pompe à huile principale : pompe à engrenages attelée au réducteur des auxiliaires.

Pompe à huile auxiliaire : pompe verticale centrifuge, de type immergé, entraînée par un moteur à courant alternatif.

Pompe à huile de secours : pompe verticale centrifuge, de type immergé, entraînée par un moteur à courant continu.

Réfrigérant(s) d'huile : deux (2) échangeurs de chaleur eau-air de réfrigération

Filtres principales : deux(02) filtres de type papier accordéon à 5 microns du plein débit avec une vanne de transfert.

- Alimentation huile H.P.

Pompe principale : entraînée par le réducteur des auxiliaires (Pompe à cylindrée variable).

Pompe hydraulique auxiliaire : entraînée par le moteur électrique 88 HQ.

- Système de refroidissement :

Entraînée par le réducteur des auxiliaires (en circuit fermé).

- Système d'air d'atomisation :

Compresseur principal : Compresseur centrifuge, entraîné par le réducteur des auxiliaires.

Compresseur auxiliaire : entraîné par moteur de lancement de la turbine, par l'intermédiaire d'un système de poulie courroie.

Réfrigérant : échangeur de chaleur air-eau.

Filtre à air séparateur.

- Réducteur des auxiliaires :

Réducteur de vitesse intégré à l'alternateur.

Rapport de démultiplication 5100/3000 t/mn.

- Régulation :

Système de régulation SPEEDTRONIC MARK VI.

- Protection :

Sur température, vibrations, détection de flamme.

### **3. Turbine à gaz :**

#### **3.1. Généralités sur le groupe thermique turbine à gaz :**

Le groupe thermique conçu pour la plupart des installations est constitué d'une turbine à gaz monocycle "mono-arbre" pour un fonctionnement continu et entraînant un alternateur. La combustion du mélange air-carburant est utilisée pour générer la puissance nécessaire à l'entraînement de l'arbre du compresseur, de certains équipements auxiliaires et principalement de l'alternateur.

En effet, les groupes thermiques à turbine à gaz représentent une technologie clé dans la production moderne d'énergie, en raison de leur flexibilité et de leur rapidité de démarrage. Fonctionnant sur le principe du cycle de Brayton, ces systèmes combinent la compression de l'air, la combustion de carburant et l'expansion dans la turbine pour convertir l'énergie thermique en énergie mécanique, qui est ensuite transformée en électricité par un générateur. Leur conception intègre des matériaux résistants aux hautes températures et des technologies avancées de gestion des flux d'air, permettant d'optimiser le rendement énergétique tout en minimisant les émissions polluantes. Ces installations se distinguent par leur capacité à répondre efficacement aux pics de demande, ce qui les rend particulièrement adaptées à la gestion des fluctuations du réseau électrique, ainsi qu'à la fourniture d'énergie de secours dans des contextes industriels ou urbains. L'évolution constante des technologies et l'automatisation des processus de surveillance et de maintenance contribuent également à améliorer leur performance et à prolonger leur durée de vie, en assurant une exploitation sécurisée et fiable. Ainsi, dans le cadre des stratégies de transition énergétique, les groupes thermiques à turbine à gaz jouent un rôle déterminant en offrant une solution à la fois réactive, efficace et respectueuse de l'environnement.

#### **3.2. Principe de fonctionnement de la turbine à gaz :**

Une fois le système de démarrage turbo lancé et l'embrayage enfoncé, l'air environnant est absorbé, épuré et comprimé en 17 étages du compresseur principal. Afin de prévenir le compresseur de pomper lors du lancement, la vanne d'aspiration du 11<sup>ème</sup> étage est ouverte et les aubes directrices (IGV) à l'entrée du compresseur sont en position fermée.

Au régime nominal, la vanne d'extraction du 11ème étage se ferme automatiquement, tandis que la palette réglable (IGV) est dans sa position normale de fonctionnement et s'est légèrement ouverte pour atteindre l'angle intermédiaire (cas de modulation IGV).

L'air comprimé issu du compresseur enfonce dans l'espace annulaire entourant les dix chambres de combustion et de là pénètre entre le carter intermédiaire et les tubes à flamme.

Des injecteurs dirigent le carburant chez chacune des dix chambres de combustion, où il se mixte à l'air. Utilisez deux bougies rétractables pour l'éclairage (mais une seule suffit).

Lorsque l'une des deux bougies installées sur ces chambres de combustion s'allume, la combustion se propage aux autres chambres de combustion par des tubes interconnectés qui les joignent parmi elles au niveau de la zone de combustion. A environ 50% de la vitesse collective de la turbine, la compression dans la chambre de combustion est suffisante pour rétracter l'électrode de la bougie d'allumage pour patronner de la propagation de la flamme.

Les gaz brûlants de la chambre de combustion traversent des pièces de transition imbriquées à l'arrière de tout tube à flamme, puis traversent trois étages de turbine et s'y dilatent. Tout étage est cédé d'un collectivement de pales figés et d'une disposée de pales mobiles. En la rangée d'aubes adjacente, une portion de l'énergie cinétique de l'écoulement est transformée en action nécessaire, qui est transmis au rotor de la turbine sous l'aspect de couple mécanique.

Une fois que les gaz d'échappement ont traversé les aubes du troisième étage, ils franchissent le diffuseur, lequel comporte en une série de chicanes ou d'aubes, qui convertissent la direction centrale des gaz en une direction radiale, réduisant ainsi les pertes de sortie. Le gaz est ensuite envoyé vers le cadre d'échappement. Le roulement de l'arbre qui en résulte emmène le rotor de l'alternateur et certains équipements accessoires.

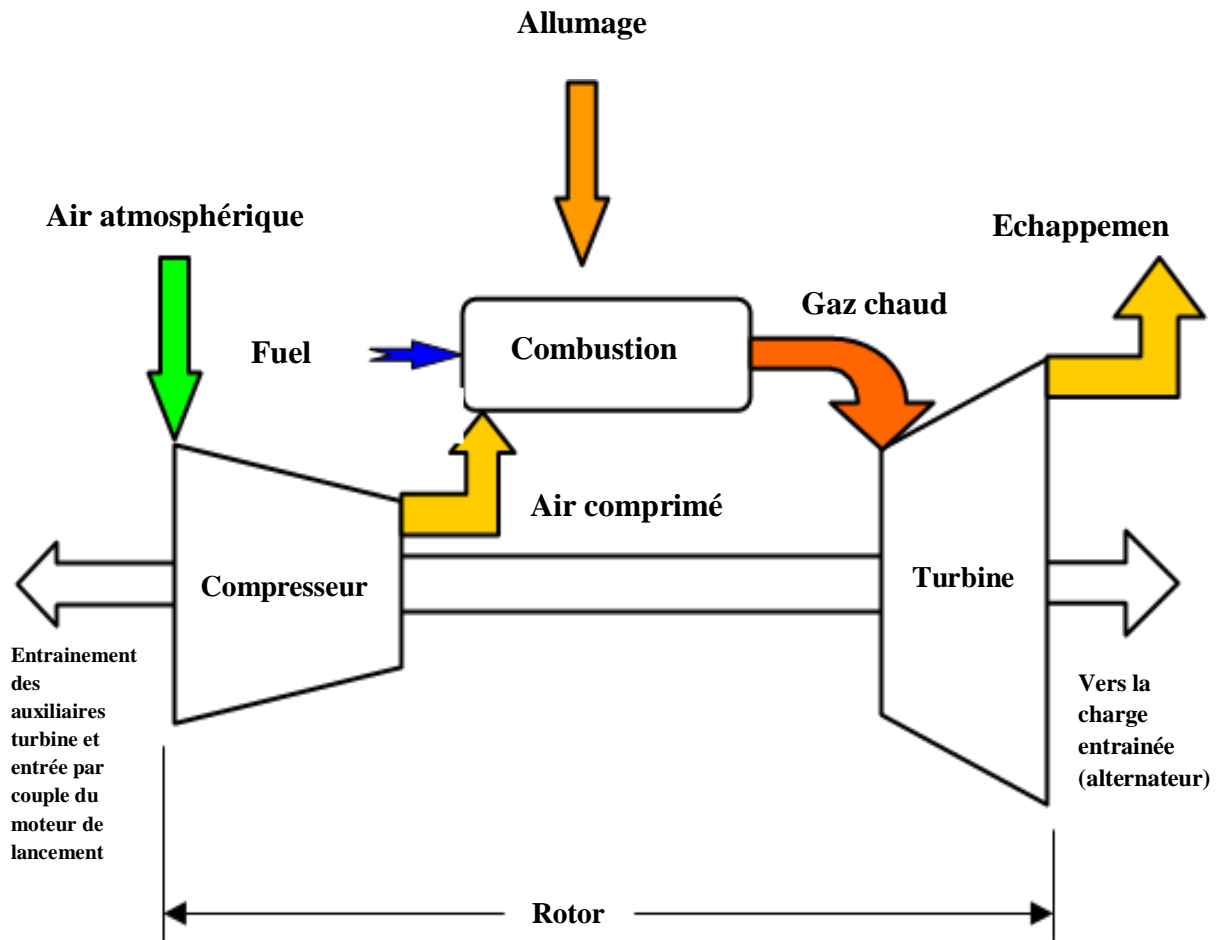


Figure .IV.1.principe de fonctionnement d'une turbine à gaz.

### 3.3. Description des principaux composants de la turbine à gaz :

Le groupe turbo alternateur est composé d'une turbine à combustion entraînant un alternateur pour fournir la puissance électrique à 50 Hz. La puissance d'un groupe est d'environ 40 MW électrique pour un fonctionnement au gaz naturel.

La turbine à combustion est constituée d'un compresseur et d'une turbine de détente (alimentée en gaz chaud par un ensemble de chambres de combustion) à 3 étages sur le même arbre.

Les rotors compresseur et turbine sont constitués de disques assemblés par bridage, l'ensemble est supporté par deux paliers.

Le démarrage est assuré par un moteur électrique, qui entraîne au démarrage le train d'arbres par l'intermédiaire d'un convertisseur de couple et d'un réducteur, laquelle emporte également une pompe reliée à l'auxiliaire.

Le compresseur aspire l'air de combustion à travers un filtre à air relié au compresseur par une gaine d'admission équipée de silencieux. L'air sortant du compresseur alimente les chambres de combustion où le mélange est réalisé avec le carburant injecté par des buses. Deux bougies produisent les étincelles d'allumage du mélange. Les gaz chauds produits sont guidés par des pièces de transition jusqu'à la roue motrice de la turbine. La température élevée de la combustion produit une augmentation importante du volume du mélange d'air en proportion du débit de combustible introduit dans la chambre de combustion. Cette augmentation du volume d'air chaud provoque un accroissement de pression et de vitesse du gaz à l'entrée de la turbine.

Ainsi, le contrôle du débit de carburant permet de contrôler le débit du mélange d'air chaud et donc la puissance mécanique récupérée par détente dans l'étage de turbine. Chaque étage de turbine est constitué d'une rangée d'aubes fixes (stator) suivie d'une rangée d'aubes mobiles (rotor), pendant toute rangée d'aubes immobiles l'énergie cinétique du flux du gaz brûlé accroit à mesure que la compression diminue est converties en mécanique énergie.

La turbine à combustion est installée dans un compartiment acoustique pour réduire le niveau sonore de la turbine nue. Une ventilation évacue les calories produites pendant le fonctionnement.

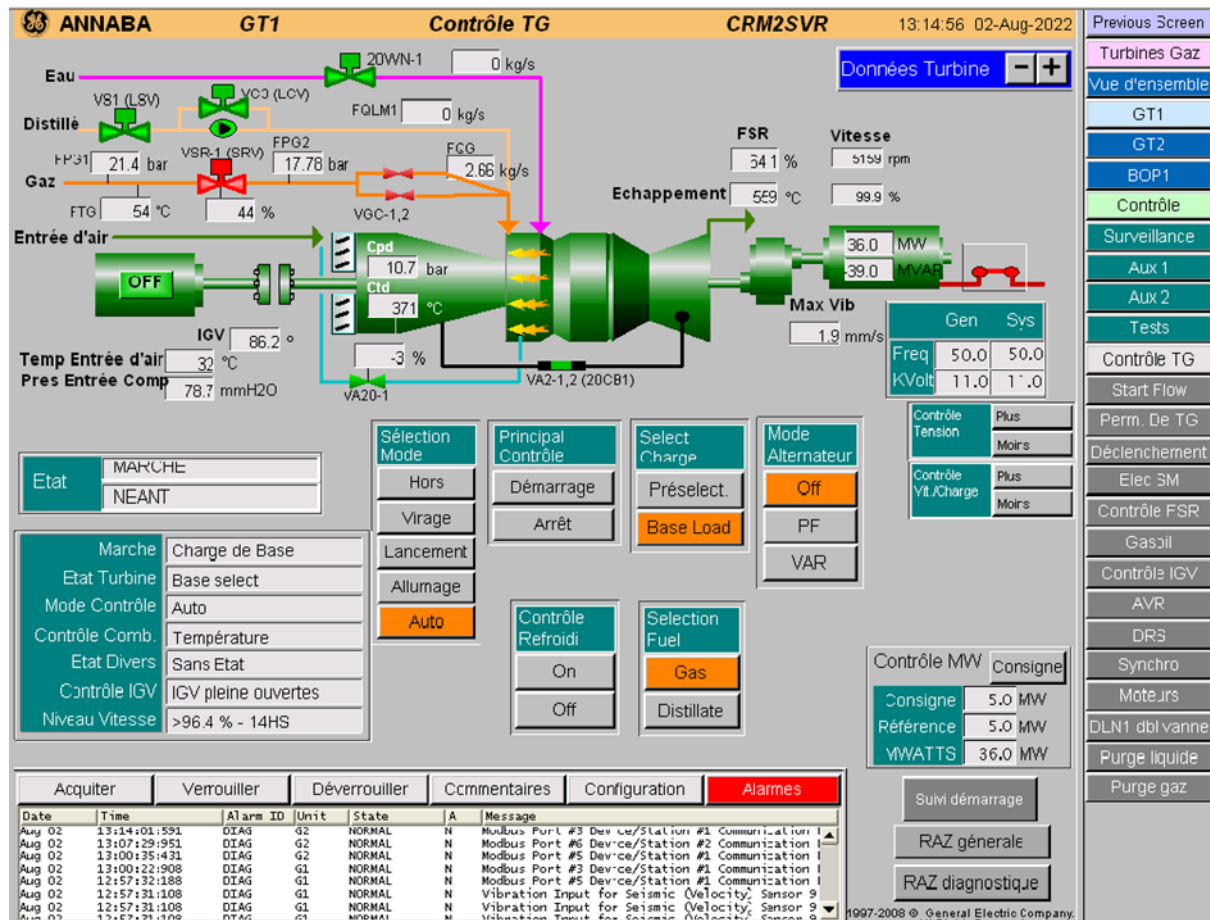


Figure .IV.2. Contrôle TG.

### 3.3.1. Section compresseur :

La partie de compresseur axial se transige d'un rotor et d'une suite de carters. Le organisme principal se compose d'aubes orientables, de 17 étages d'aubes de rotor et de stator et de deux disposées d'aubes directrices immobiles, appelées EGV.

En un compresseur, l'air est entraîné en circulation par une disposée d'aubes mouvants circulaires (rotors), dont la vitesse augmente. Ensuite, en passant à travers une disposée d'aubes fixes (le stator), la rapidité de l'air est réduite et la compression augmentée.

Le rotor du compresseur se compose de quinze disques, de deux arbres et de tirants. Après assemblage, le rotor est équilibré dynamiquement avec une très grande précision.

Le rotor du compresseur et les aubes du stator ont une conception à silhouette aérodynamique pour une compression active de l'air à des vitesses externes élevées. Ils sont fixés au disque par des pieds de modèle "queue d'aronde".

L'ensemble de la section compresseur se compose de trois portions essentielles :

- Corps d'admission
- Corps de compresseur
- Échappement du compresseur

À l'égard de le carter de turbine et le cadre d'échappement, ces éléments forment la composition capitale de la turbine à gaz. Ils maintiennent l'alignement du rotor avec les roulements et forment une enceinte pour le flux thermique.

Pour une efficacité maximale, le perçage du corps se fait avec des tolérances très serrées afin d'obtenir un jeu minimum en bout de pale lors du fonctionnement.

### **3.3.2. Section chambres de combustion et tubes d'interconnexion :**

Le dispositif de combustion est à contre-courant et constitué de 10 chambres de combustion avec les éléments suivants : tube à flamme, écran antiradiation (manchon de flux), pièce de transition et tubes d'interconnexion. Les bougies d'allumage, les capteurs de flamme et les injecteurs de carburant.

Les gaz brûlants principaux de la combustion du combustible dans la chambre de combustion sont utilisés pour entraîner une turbine. Selon le dispositif à contre-courant, l'air sortant du compresseur contourne la pièce de transition et pénètre dans l'anneau entourant chacun des 10 tubes à flamme.

L'air comprimé entourant le tube à flamme passe radialement à travers ce dernier déflecteur à travers une série d'ouvertures et entre en contact avec l'anneau soudé sur le déflecteur dans le tube à flamme. Ces anneaux ou anneaux de soudure à l'argent sont utilisés pour guider l'air le long de la paroi interne du tube à flamme, créant un film mince qui protège la paroi interne du tube des gaz de combustion chauds. Le carburant est introduit dans chaque chambre de combustion par des injecteurs.

Les chambres sont numérotées dans le sens inverse des aiguilles d'une montre lorsqu'elles sont vues dans le sens du flux d'air ou dans le sens du flux. La chambre supérieure est le numéro 10.

Les dix chambres sont jointes entre elles par des tuyaux d'interconnexion duquel l'objectif est de distribuer la flamme d'une chambre contenant les bougies aux autres chambres qui ne sont pas encore allumées.

L'air sortant du compresseur axial est dirigé du séparateur du compresseur axial vers la chambre de combustion. L'air va et vient à l'extérieur du tube à flamme vers le capuchon du tube à flamme. Il entre dans la zone de réaction de la chambre de combustion à travers des turbulateurs situés sur le tube lui-même ou l'injecteur et à travers une série de trous calibrés percés dans le couvercle et le tube lui-même.

Les gaz chauds se propagent ensuite vers les zones de calme et de dilution, où un apport d'air supplémentaire est assuré. Ces trous de dilution permettent le passage du bon volume d'air à refroidir pour limiter la température des gaz chauds à l'entrée du premier directeur. À l'intérieur de l'ensemble du tube à flamme et du capot, des trous de refroidissement assurent un film d'air relativement frais le long de la paroi du capot du tube à flamme.

Les 10 chambres de combustion sont identiques à l'exception de celles équipées de bougies ou de détecteurs de flamme.

### **3.3.3. Section turbine :**

Pour permettre de maintenir une température de fonctionnement raisonnable et donc une longévité plus importante, le rotor de la turbine doit être refroidi.

C'est dans les trois étages de la turbine que l'énergie est convertie en énergie mécanique sous allure de gaz sous pression produit par le compresseur et le dispositif de combustion (voir Figure IV.3).

Chaque étage de turbine est constitué d'un rail et d'une roue. La partie turbine se compose d'un rotor, d'un carter, d'un rail de guidage, d'un segment de carénage, d'un cadre d'échappement et d'un diffuseur d'échappement.

Le refroidissement s'effectue au moyen d'un débit d'air relativement frais extrait du compresseur axial. Cet air est acheminé par un conduit central au centre du rotor puis est inséré dans chaque espace aménagé situé entre les parties fixes et le rotor. Ces espaces sont appelés généralement « espaces inter-roues ».

Le corps turbine et le cadre d'échappement constitue les organes principaux du stator de la turbine à gaz. Les directrices, les segments de protection, le palier n°2 et le diffuseur d'échappement sont tenus en place par ces deux organes principaux. Il assure la tolérance et la position relative des rails de guidage par rapport aux aubes de la turbine, facteurs clés des performances de la turbine. Les gaz chauds canalisés dans le corps turbine provoquent

l'échauffement de celui-ci. Pour éviter toute modification importante du corps turbine, donc minimiser tout risque de défaut d'alignement ou de niveau de vibration, il est absolument indispensable de mettre un système de refroidissement efficace de manière à limiter le corps turbine à une température acceptable. Cette protection thermique est assurée au moyen d'isolants, de dispositifs de refroidissement ainsi que d'un habillage isolant multicouches. La partie cylindrique du corps est refroidie par de l'air en provenance de deux ventilateurs externes.

La turbine à gaz et ses auxiliaires sont montés sur un socle en acier mécano-soudé. Ce socle supporte également les caissons d'aspiration et d'échappement. L'extrémité avant du socle, sous le compartiment des auxiliaires, fait office de réservoir d'huile de lubrification. Un collecteur principal d'huile de lubrification est logé dans une cavité de section rectangulaire située à gauche du socle. Cette cavité s'étend du réservoir d'huile à l'extrémité arrière du socle et est utilisée pour le retour d'huile. Les raccords d'alimentation d'huile et de drainage s'effectuent au niveau de l'extrémité arrière du socle. Le montage de la turbine sur le massif est facilité par la présence de semelles usinées à la base du socle.

La turbine est montée sur son socle au moyen de supports verticaux. Le support avant est situé au niveau du corps du compresseur, et les 2 "pattes arrières" se situent de part et d'autre du corps de la turbine. Les supports de type "pattes" garantissent le positionnement axial et vertical de la turbine.

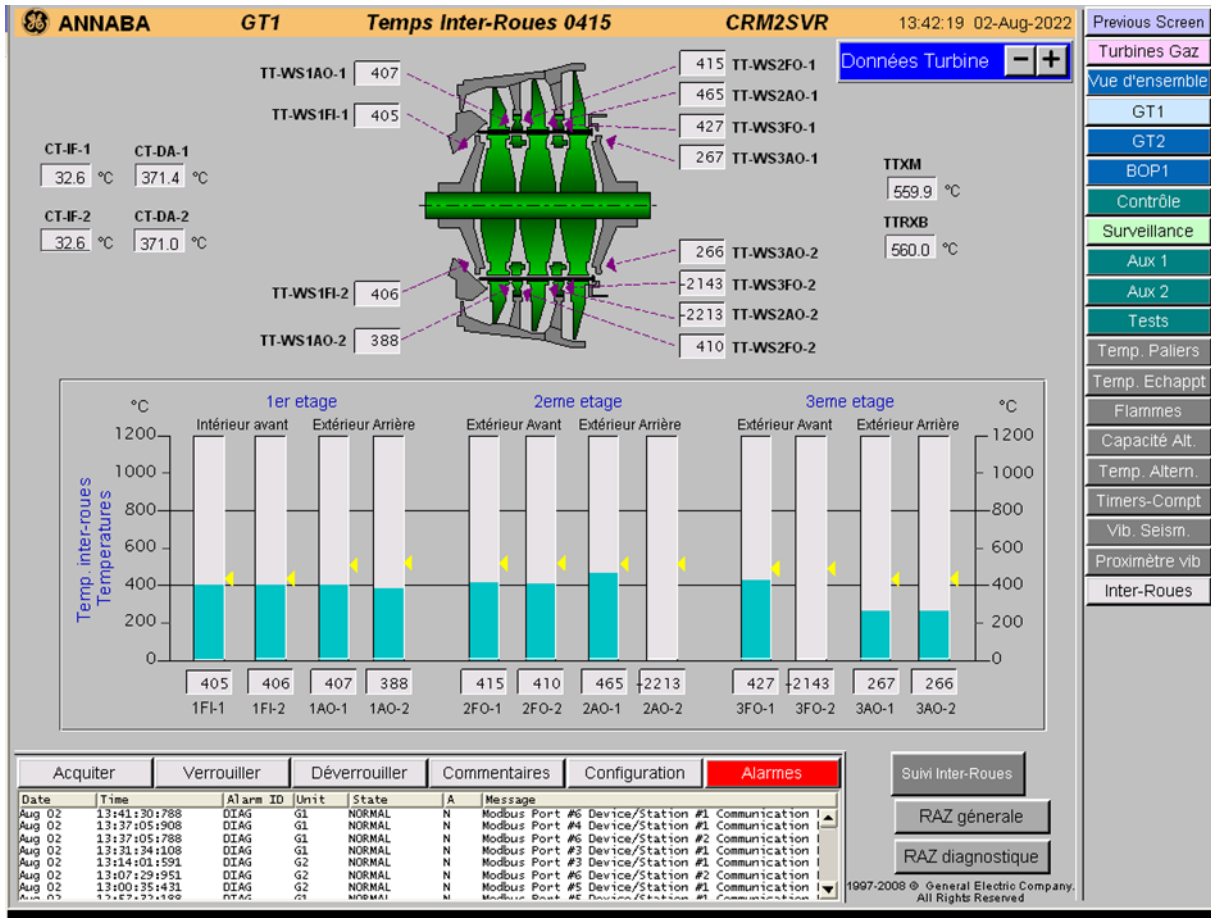


Figure .IV.3. Température de la turbine.

### 3.3.4. Section cadre d'échappement et diffuseur :

Le cadre d'échappement est boulonné à la face arrière du corps turbine. Du point de vue structurel, le cadre se compose de deux cylindres concentriques reliés par une série de 10 entretoises radiales.

Ces entretoises se trouvent dans le passage des gaz chauds. Elles doivent être maintenues à une température constante pour ne pas perturber le centrage du rotor par rapport au stator. La stabilisation en température se fait en protégeant les entretoises des gaz d'échappement à l'aide d'un carénage métallique mécano-soudé installé dans le diffuseur. Ce carénage sert également de refroidisseur d'air ; l'air de refroidissement du corps turbine s'écoule vers des orifices du cadre d'échappement qui font face à des orifices dans le corps turbine. Cet air s'écoule ensuite dans l'espace formé entre les entretoises et le carénage afin de maintenir la température de ces entretoises à une valeur correcte.

Le diffuseur d'échappement se situe entre les cylindres interne et externe du cadre. Les gaz s'échappant du 3ème étage turbine entrent dans le diffuseur où leur vitesse se trouve réduite. A la sortie du diffuseur, une série d'aubes annulaires et fixes permettent de diriger les gaz radialement dont une partie traverse des sections de tube où sont installés les thermocouples d'échappement (Figure .IV.4).

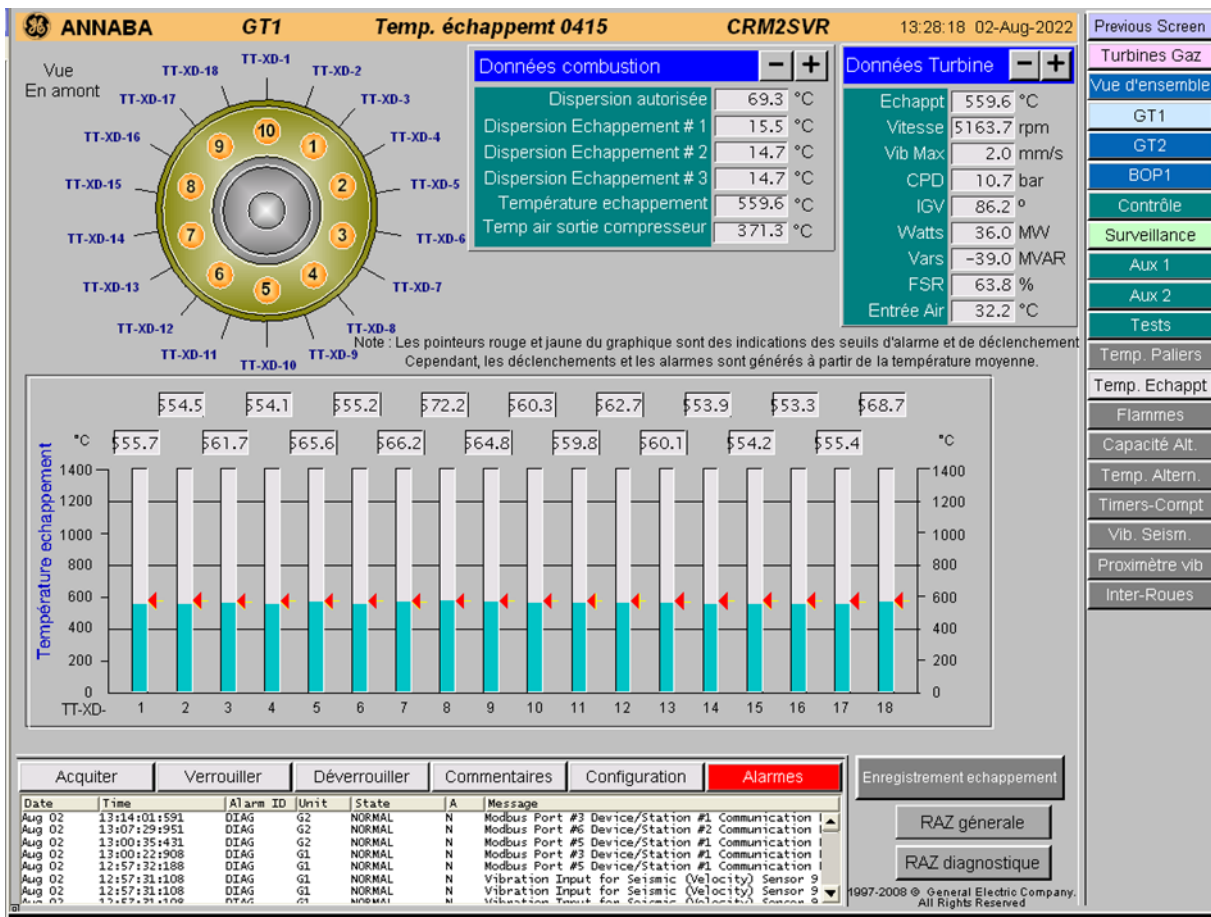


Figure .IV.4. Température d'échappement.

### 3.3.5. Paliers :

La turbine à gaz est équipée de deux paliers importants qui supportent le rotor de la turbine. Les paliers et les ensembles d'étanchéité sont incorporés dans deux bâtis : l'un au niveau du corps d'entrée du compresseur et l'autre au niveau du cadre d'échappement. Les deux paliers sont lubrifiés sous pression avec de l'huile en provenance du réservoir d'huile situé dans le socle de la turbine. Quand l'huile de graissage pénètre dans le corps de palier, elle s'écoule dans une rainure annulaire entourant le coussinet inférieur. De cette rainure, le liquide coule dans des ouvertures usinées dans le coussinet au niveau du plan de joint horizontal. De chaque côté du

palier, des labyrinthes d'étanchéité évitent à l'huile de s'échapper le long du rotor turbine (voir figure .IV.5).

Ces labyrinthes formés de déflecteurs (ou dents) sont montés aux extrémités de paliers de manière à contrôler toute fuite d'huile. Une surface lisse est usinée sur l'arbre et les anneaux d'étanchéité sont montés de façon à ce qu'un jeu faible existe entre les dentures et l'arbre.

Les joints sont conçus avec une double rangée de dentures séparées par un espace. L'air d'étanchéité sous pression est admis dans cette espace et empêche l'huile de lubrification de s'écouler le long de l'arbre vers l'extérieur des paliers. Une partie de l'air est mélangée à l'huile et retourne au réservoir d'où il est évacué grâce à un évent.

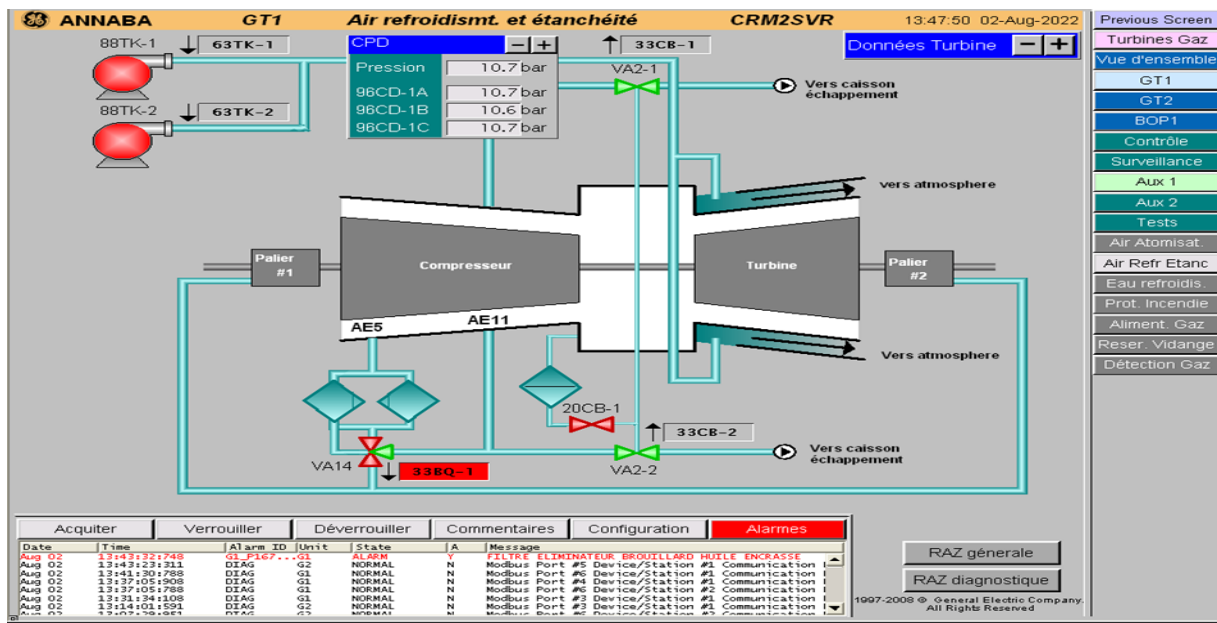


Figure .IV.5. Étanchéité des paliers

### 3.3.6. Accouplements :

Les accouplements sont utilisés pour transmettre le couple du moteur de démarrage depuis le réducteur des auxiliaires jusqu'à la ligne d'arbre, et de transmettre la puissance de l'arbre de la turbine au réducteur principal côté alternateur.

#### Accouplement des auxiliaires :

Un accouplement cannelé lubrifié sert à raccorder le réducteur des auxiliaires à l'extrémité avant de l'arbre du compresseur. Pour transmettre le couple, il comporte à chaque extrémité, un moyeu pourvu d'une denture mâle qui s'engrène dans une denture femelle usinée à l'intérieur

de chaque manchon. Les dents mâles peuvent coulisser d'avant en arrière dans la couronne dentée femelle permettant ainsi la compensation de trois défauts d'alignement : défaut angulaire, défaut de parallélisme, ou bien une combinaison des deux. A chaque extrémité, des joints toriques permettent l'étanchéité du système.

**Accouplement de puissance :**

Un accouplement rigide et creux raccorde l'arbre turbine au réducteur de vitesse. Chaque extrémité de l'accouplement est fixé à l'aide de brides d'un côté sur l'arbre arrière turbine et de l'autre sur l'arbre principal du réducteur de vitesse.

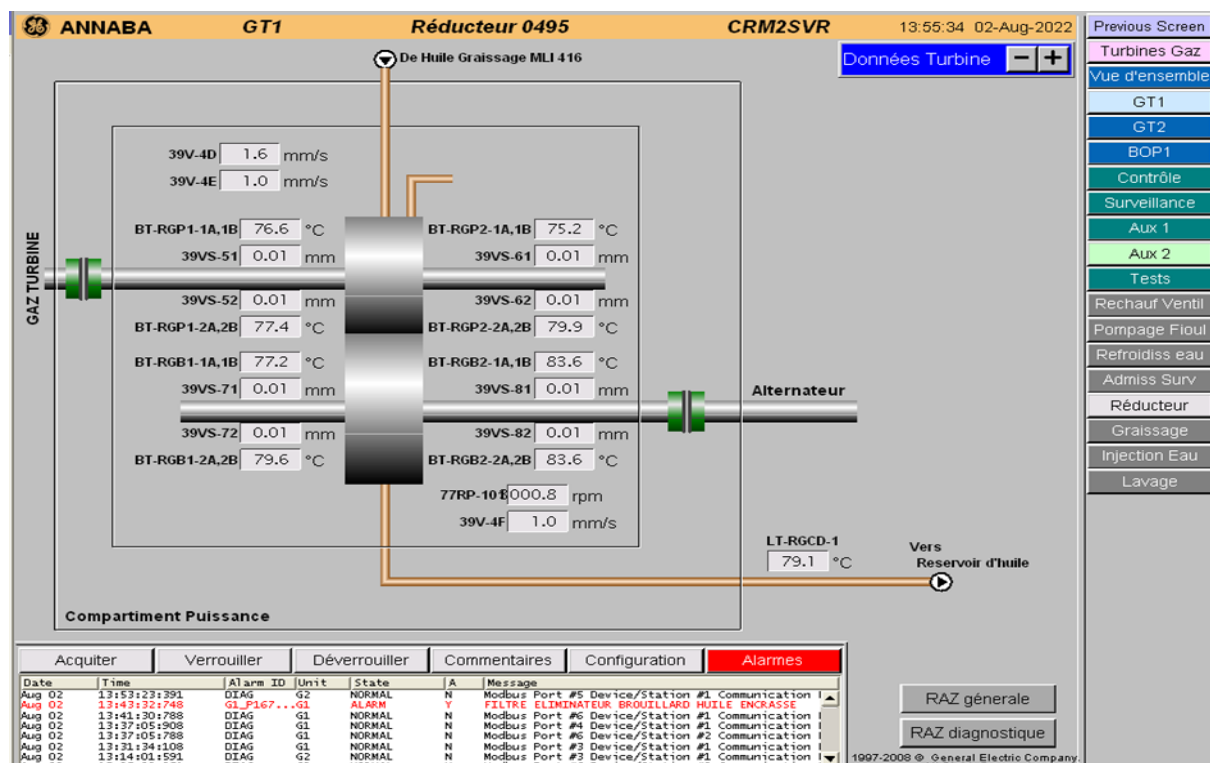


Figure .IV.6. Réducteur de puissance.

**3.3.7. Compartiments :**

Des ensembles bien délimités du groupe turbine-alternateur sont contenus dans des enceintes appelées « compartiments ». Ces compartiments sont prévus pour supporter toutes les conditions climatiques, et conçus pour en faciliter l'accès. Ils assurent une bonne protection thermique et acoustique. Les parois du compartiment sont constituées par des panneaux démontables, des portes et un toit thermiquement isolé, une structure soudée sert de support à ces différentes parties. Les panneaux sont isolés et tenus en place par des boulons. Les portes sont tenues fermées hermétiquement par de solides verrous. Les joints entre panneaux et

ossature-supports assurent l'étanchéité aux intempéries. Inspection et maintenance sont facilitées car les portes permettent un accès facile pour le personnel et les panneaux démontables facilitent l'accès pour les inspections majeures et l'entretien courant.

Il y a un caisson d'aspiration entre les compartiments des auxiliaires et turbine et un caisson d'échappement entre les compartiments turbine et alternateur. Ainsi dans ce package turbine à gaz et alternateur, il y a une séquence en ligne des divers compartiments, séquence alternée par le caisson d'aspiration et celui d'échappement. Ces compartiments comprennent la turbine à gaz, le réducteur de puissance, l'alternateur, les auxiliaires alternateur et l'armoire de coupure de l'appareillage électrique.

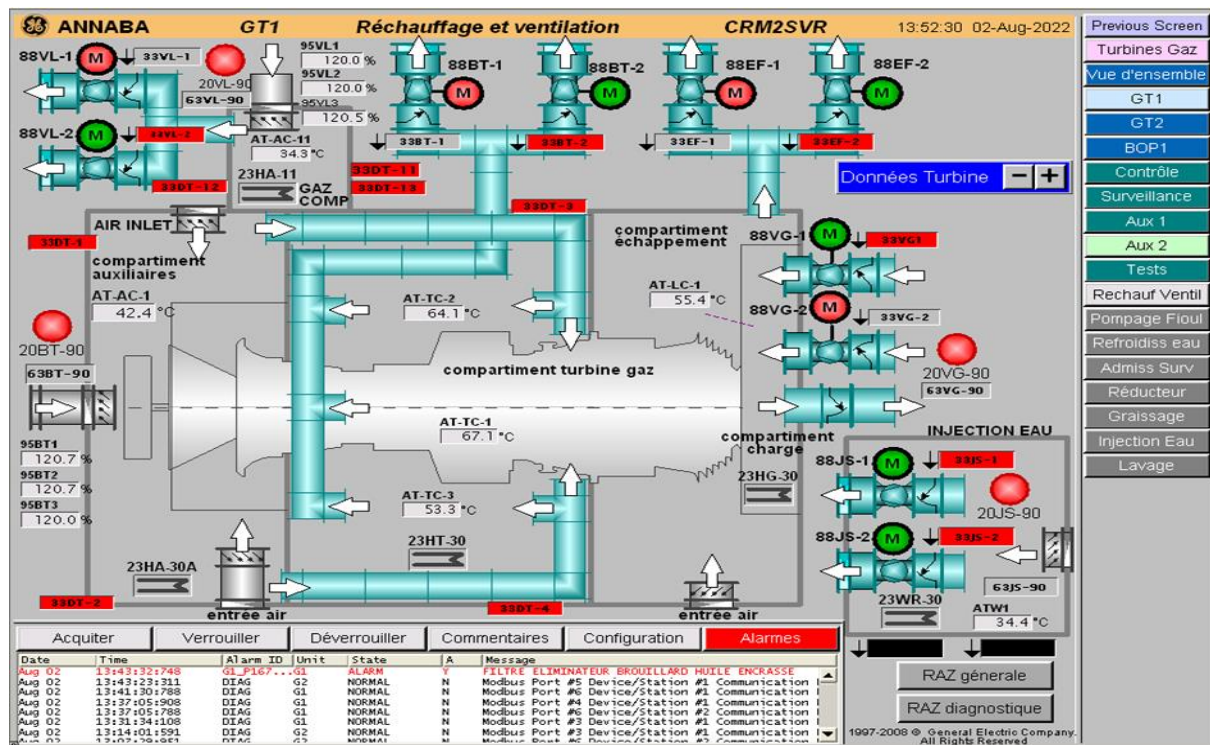


Figure .IV.7. Turbocompresseur compartiment.

### 3.3.8. Section admission et échappement :

Avant que l'air atmosphérique n'entre dans la turbine, il doit être traité pour répondre aux conditions environnementales et permettre à la machine de fonctionner comme prévu. Le système d'extraction est fabriqué pour répondre à ces questions. De plus, les sons à haute fréquence dus aux pales du rotor du compresseur à l'accès de l'appareil doivent être amoindris (Fig. IV.8). Ce système constitue d'une enveloppe, assidue de silencieux du modèle « à baffles

parallèles », ensuite d'un grillage localisé dans le coude d'arrivée d'air en aval duquel l'air abouti le caisson d'aspiration de la turbine à gaz.

À la partie d'échappement, les gaz usés pour emmener la turbine sont réacheminés pour être trouvé expulsés à l'atmosphère, soit conduits vers une chaudière de récupération. La murette du caisson d'échappement contraire au diffuseur est remontée d'une série de thermocouples acceptant de mesurer la température des gaz d'échappement. Ces thermocouples adressent des signaux au dispositif de régulation et de protection en température. La géométrie du caisson d'échappement est celle d'une boîte ouverte, la plupart du temps, au sommet et fixée à son extrémité avant au socle de la turbine. Un isolement approprié du caisson permet une protection acoustique et thermique. La liaison entre le caisson d'échappement et le conduit suivant est assurée par une gaine servant aussi de joint de dilatation. La gaine d'échappement est équipée d'un silencieux, suivi d'un autre joint de dilatation, avant que les gaz ne soient rejetés soit à l'atmosphère, soit vers une chaudière de récupération.

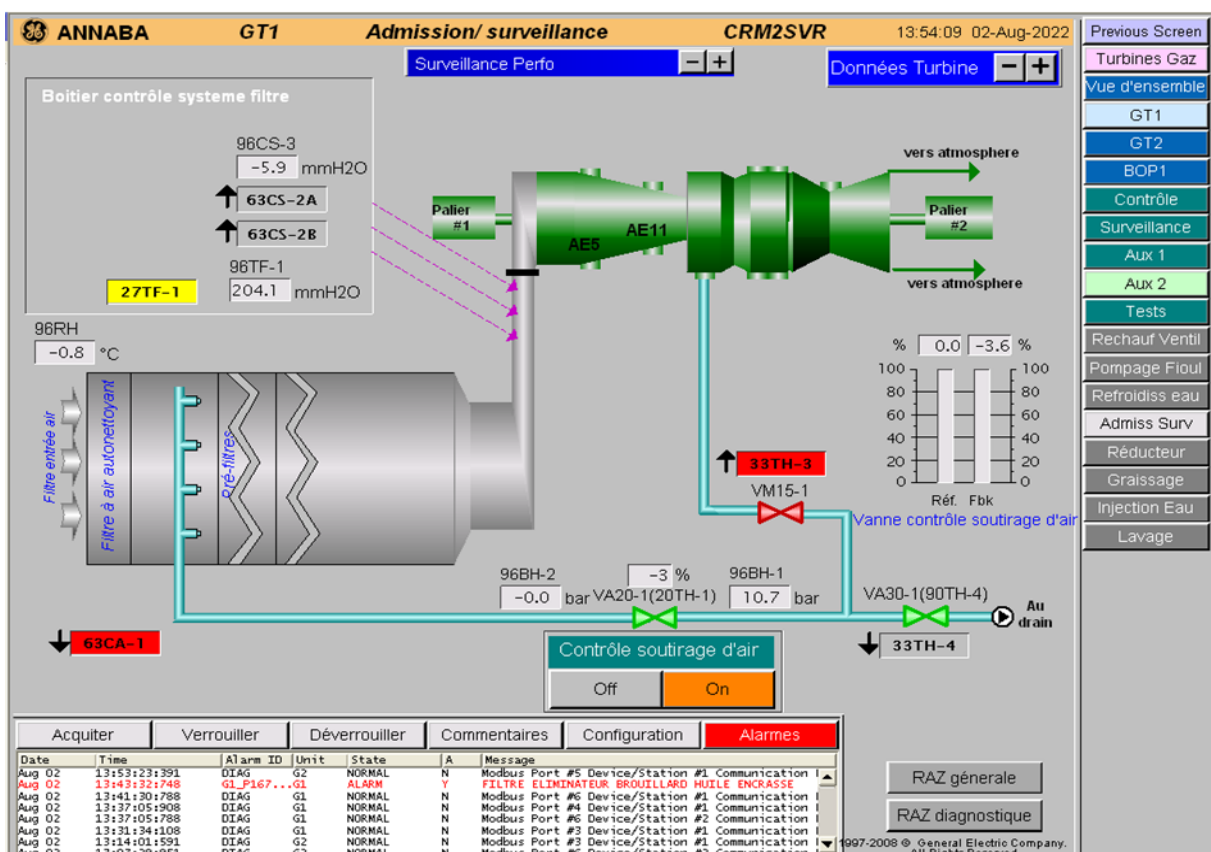


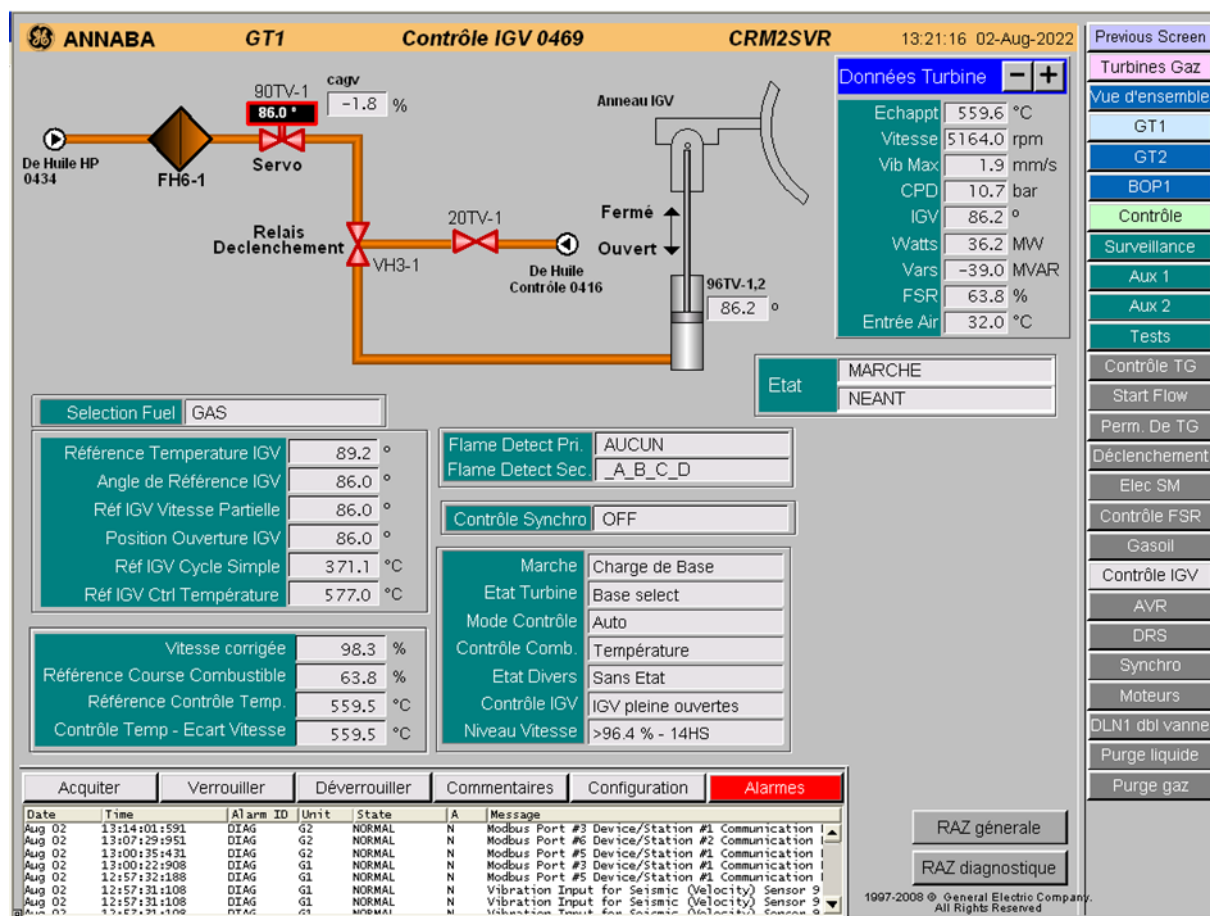
Figure .IV.8. Admission compresseur.

**3.4. Auxiliaires turbine à combustion(TAC) :**

**3.4.1. Aubages à inclinaison variables (IGV) :**

Des aubes à inclinaison variables sont installées à l'aspiration du compresseur pour prévenir les pulsations de celui-ci durant les phases transitoires de variations de vitesse en démarrage et en cours d'arrêt et également pour régler la températures échappement durant le fonctionnement en charge partielle en faisant varier le débit d'air (Figure .IV.9).

Le système d'inclinaison des aubes est entraîné par un servomoteur hydraulique asservi en position par le système de contrôle commande de la turbine.



**Figure .IV.9.** Contrôle air d'admission compresseur.

**3.4.2. Système de graissage :**

Le système de graissage fournit l'huile nécessaire à la lubrification des paliers du groupe turbo alternateur, au réducteur des auxiliaires et au convertisseur de couple. Le système est composé d'une cuve à huile équipée d'une pompe plein débit à courant alternatif, une pompe entraînant par moteur à courant continu de secours, les réfrigérants d'huile, les filtres, un régulateur de

pression et une soupape de sécurité. Une résistance de chauffage immergée dans la cuve permet de réchauffer l'huile avant le démarrage de la turbine à gaz. Cette résistance est enclenchée pour une température d'huile inférieure à 18°C, la mise en service de la résistance démarre également la pompe de graissage entraînée par moteur à courant alternatif afin d'assurer une homogénéisation du réchauffage. Une température d'huile dans la cuve inférieure à 15°C empêche le démarrage de la turbine à gaz.

En fonctionnement normal, le graissage est assuré par une pompe attelée à la ligne d'arbre. La pompe à courant alternatif est utilisée pour couvrir les marches transitoires telles que les démarrages, les arrêts ainsi que la période de virage.

### 3.4.3. Éliminateur de brouillard d'huile :

Un éliminateur de brouillard d'huile filtre la mise à l'évent de la cuve à huile de graissage. Les buées d'huile sont aspirées par une moto ventilateur et passe à travers un filtre séparateur retenant les fines particules d'huile. Ces particules retournent par gravité dans la cuve à huile.

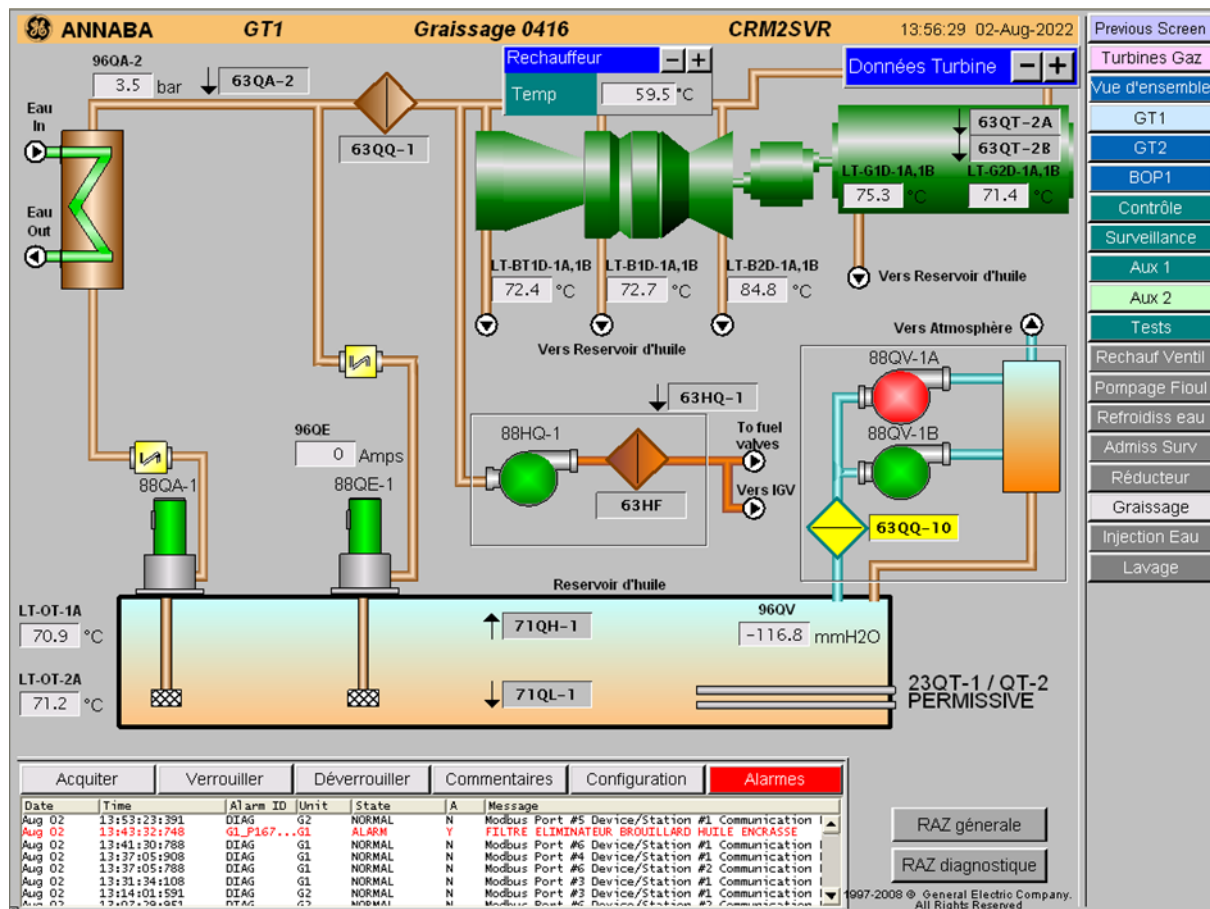


Figure .IV.10. Système de graissage.

#### **3.4.4. Système hydraulique de commande et de sécurité :**

Un circuit hydraulique alimente en fluide moteur les différents actionneurs de la Turbine à combustion (vannes du circuit combustible et IGV). Le fluide est généré par une pompe attelée durant le fonctionnement normal et par une motopompe à courant alternatif lors de la période de démarrage. Des tiroirs hydrauliques sur l'alimentation des servomoteurs mettent celle-ci à la vidange lors d'une action de déclenchement. Ces tiroirs de sécurité sont actionnés par un circuit dérivé du circuit graissage qui est mis à la vidange par une électrovanne lors d'une action de déclenchement turbine ou à l'extinction des flammes lors d'un arrêt normal. L'action de fermeture des vannes à commande hydraulique est très rapide.

#### **3.4.5. Mesure des vibrations :**

Le système de protection vibratoire du groupe turbo alternateur est réalisé par des capteurs de vibrations sismiques installés sur chaque palier TAC et Alternateur. L'excès d'un seuil déterminer comparé à une autre mesure d'un même groupe provoque un déclenchement TAC.

Un système d'acquisition vibratoire Bently Nevada basé sur des mesures de déplacement d'arbre (mesures de vibrations relatives par capteurs sans contacts montés en X, Y) met à disposition pour analyse extérieure les signaux de mesures de vibrations (signaux originels non filtrés des capteurs ou signaux 4-20 mA représentant les amplitudes ou les phases vibratoires suivant le paramétrage des mesures). Ces signaux de mesure seront transmis via une interface spécifique (TDXnet) vers un PC d'analyse vibratoire (System ONE) installé dans la salle de contrôle.

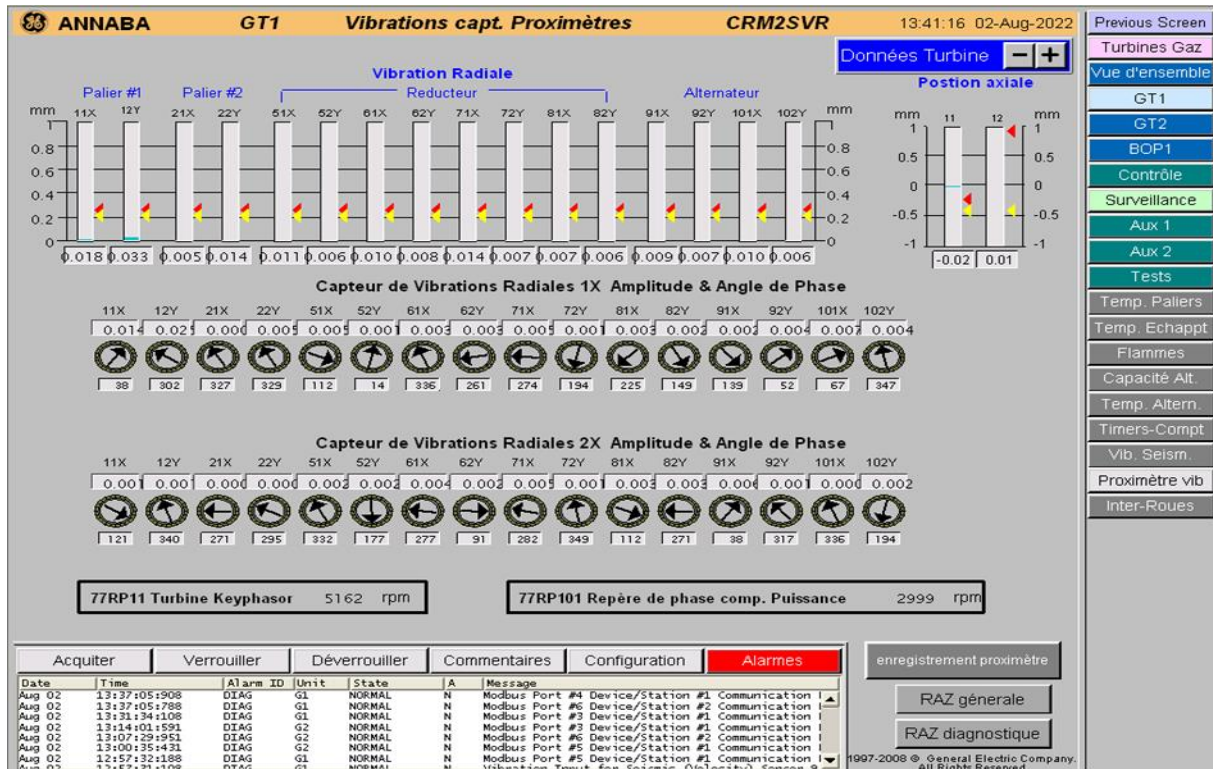


Figure .IV.11. Contrôle vibration.

### 3.4.6. Alimentation combustible gaz :

Pour assurer une bonne combustion, le gaz doit être exempt de poussière ou de condensats.

Le gaz naturel arrive du poste gaz séparé de ses condensats et réchauffé pour alimenter le module regroupant les vannes réglantes de la cabane gaz (voir figure .IV.11). Une vanne d'isolement automatique en sortie du séparateur alimentant la turbine à gaz est forcée en fermeture sur une détection de feu de la turbine à gaz ou sur une détection de fuite gaz dans le compartiment turbine une action d'arrêt d'urgence de la turbine à gaz, ou d'un arrêt normal.

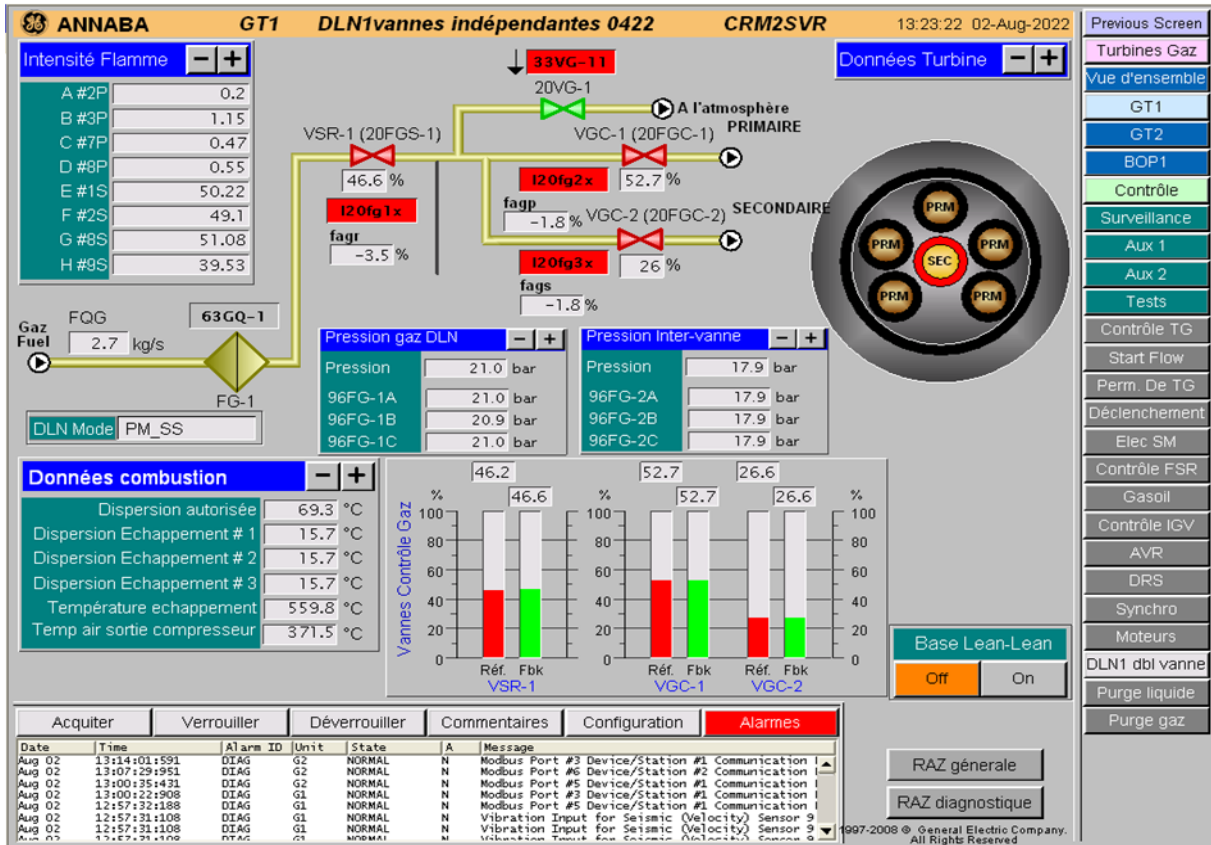


Figure .IV.12. Système de combustion gaz.

### 3.4.7. Aspiration d'air :

Afin de limiter l'encrassement du compresseur turbine, l'air atmosphérique de combustion est filtré par un arrangement de filtres (pré filtre + coalesceur + filtre autonettoyant haute efficacité) installés dans une super structure surélevée. L'entrée d'air est protégée contre la pluie par des plans inclinés afin de rendre plus efficace la filtration (Figure .IV.8).

Le filtre autonettoyant utilise des cartouches filtrantes cylindriques et coniques lesquelles sont nettoyées périodiquement par injection d'air comprimé.

### 3.4.8. Circuit de réfrigération :

Le circuit de réfrigération évacue les calories produites par l'alternateur et la turbine à combustion (circuit d'huile de graissage et pattes d'appuis de la machine) pendant le fonctionnement. Le circuit est une boucle d'eau glycolée en circuit fermé, la circulation d'eau est assurée par une pompe attelée à la TG et cette eau est refroidie dans une batterie d'aéros-réfrigérants (4 modules de 3 moto-ventilateurs).

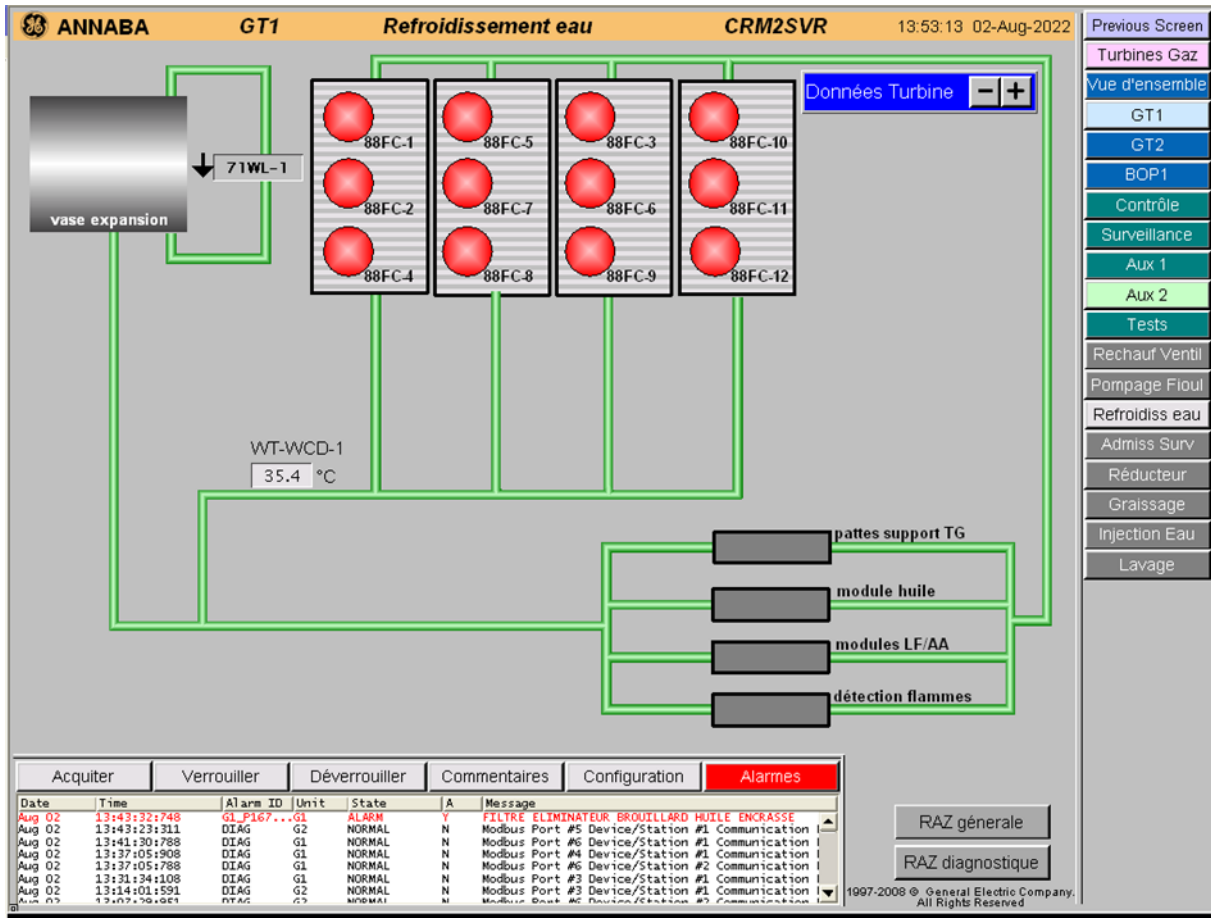


Figure .IV.13. Système de refroidissement d'eau.

Le circuit d'eau de refroidissement est un circuit fermé, doucement sous pression, créé pour riposter aux questions de dissipation thermique du circuit de lubrification, du système d'air d'atomisation, des supports de la turbine et des bâtis des détecteurs de flamme.

Ce circuit mine une solution mouillée d'éthylène glycol ; il est donc en mesure de marcher tout au long de l'année.

Durant la durée froide, une solution aqueuse d'éthylène glycol doit être fournie au système de refroidissement. En phase chaude, il est indispensable d'alimenter le dispositif avec une solution spécifique. Dans la description qui suit, cette solution est appelée eau de refroidissement.

En service, l'eau de refroidissement est aspirée par une pompe centrifuge entraînée par un arbre du réducteur des auxiliaires. La pompe possède un joint mécanique refroidi par le fluide pompé. Le fluide destiné à cet effet passe dans un séparateur de particules abrasives afin de s'assurer que le joint soit noyé dans du fluide propre. Le débit dans la ligne de refroidissement du joint

est le résultat d'une différence de pressions entre le côté d'aspiration (joint) et le côté de refoulement. Le carter de la pompe est équipé d'un évent et d'un robinet de vidange.

La pompe envoie l'eau de refroidissement dans les échangeurs thermiques de l'huile et, en parallèle dans les supports arrière de la turbine. Après avoir absorbé la chaleur rejetée par ces éléments, le fluide passe par le système de refroidissement de l'installation afin d'être refroidi.

Le toit du compartiment auxiliaire contient une cuve d'expansion off base. Le réservoir est équipé d'un raccord avec un capteur de pression. Ce capteur protégera le système des surpressions dues à l'expansion normale en mettant la surpression à la pression atmosphérique.

Les bâtis des détecteurs de flamme sont refroidis pour prolonger la durée de vie de ceux-ci.

Les enveloppes du liquide réfrigérant sur les bâtis des détecteurs de flamme fournissent une coupure thermique dans la conduction de la touffeur du logement de cellule de combustion à l'instrument de détecteur de flamme.

#### **3.4.9. Dispositif de lancement :**

La turbine à gaz ne pouvant pas lancer par elle-même, elle doit être emportée par un mécanisme de démarrage pour arriver une vitesse d'auto-sustentation. Cette situation est garantie par un moteur électrique accolé à un convertisseur de couple pour fournir le couple de lancement indispensable au démarrage de la turbine. Au démarrage, la turbine est engagée par un moteur électrique, un convertisseur de couple et une boîte de vitesses auxiliaire. Le dispositif d'embrayage et son cylindre à huile sont campés sur le réducteur auxiliaire. Le réducteur auxiliaire est relié en constance à l'arbre de la turbine à gaz par un accouplement. Le réducteur auxiliaire emporte la pompe de lubrification principale, la pompe à huile haute pression et la pompe à eau de refroidissement.

#### **3.4.10. Convertisseur de couple et vireur hydraulique :**

Cet ensemble se compose d'un convertisseur de couple, du mécanisme de virage hydraulique et de la transmission de sortie. Une petite pompe entraînée par le moteur fournit de l'huile de lubrification de la turbine au convertisseur de couple pendant la phase de lancement. Le circuit est mis sous pression par un diaphragme placé dans la conduite de refoulement. Le système de transmission et le mécanisme de virage sont lubrifiés par de l'huile sous pression venant du circuit du convertisseur. Le retour d'huile à la cuve de la turbine se fait par gravité et le circuit

du convertisseur est vidangé pendant la mise à l'arrêt afin de décharger le convertisseur pour la phase de démarrage du moteur.

Le convertisseur de couple se compose d'un rotor pompe entraîné par un moteur qui fournit de l'huile à une turbine hydraulique connectée à l'arbre d'entrée de la transmission de sortie. Le rotor de la pompe exige une puissance fixe à une vitesse fixe, indépendamment de la charge de sortie. La puissance absorbée par le rotor de la pompe varie comme le cube de la vitesse d'entrée.

Le mécanisme de virage hydraulique est un système rotatif du type à biellettes connecté à un embrayage unidirectionnel type galet-rampe à l'arbre d'accès de la transmission de sortie. La transmission de échappement relie le mécanisme de virage depuis la sortie du convertisseur de couple au système d'embrayage.

Le système de virage se compose des éléments suivants : ensemble d'entraînement mécanique et embrayage unidirectionnel et, dans le convertisseur de couple, module de la vanne de commande, pompe et vanne de décharge.

Le fonctionnement du système, pour le cycle de refroidissement, est automatiquement commandé par le panneau de commande électronique. Toutes les 3 minutes, le mécanisme de virage effectue un cycle complet. Ce cycle se termine dans la position d'attaque afin de verrouiller l'embrayage dans la position d'engagement avec les dents du système d'embrayage en contact.

#### **3.4.11. Système d'air de refroidissement et d'étanchéité :**

Le dispositif d'air de refroidissement et d'étanchéité offre le écoulement d'air important, qui est prélevé sur le compresseur axial de la turbine à gaz, pour alimenter le rotor de la turbine et d'autres composants du stator pour refroidir ces composants pendant le mouvement normal. Quand la turbine à gaz est en marche, de l'air est prélevé sur les deux niveaux du compresseur axial ainsi que sur l'expulsion du compresseur. Cet air est employé pour garantir les activités de refroidissement et d'étanchéité suivantes :

- Etanchéité des paliers de la turbine et de la veine des gaz chauds.
- Refroidissement du rotor de la turbine.
- Refroidissement des éléments statiques de la turbine.
- Alimentation en air comprimé des vannes pneumatiques.

L'air extrait du 5ème et du 11ème étage du compresseur axial et de l'échappement est utilisé pour l'étanchéité des paliers et pour le refroidissement des pièces internes de la turbine. Il est également utilisé après filtrage pour alimenter en air propre les vannes pneumatiques.

Un débit d'air de refroidissement est extrait du 16ème étage. Il permet une circulation interne d'air de refroidissement au centre du rotor. L'air de pilotage des vannes pneumatiques est prélevé de l'échappement compresseur.

Un débit d'air de refroidissement est extrait du 13ème étage. Il permet le refroidissement de la directrice du 2ème étage.

### **3.5. Caractéristiques et description de l'alternateur :**

Le type d'alternateur est un générateur sans balais de type BDAX7-290ERHN pour utilisation avec un entraînement turbine à gaz GE type Frame 6B.

#### **3.5.1. Stator :**

Le noyau est intégré dans un bâti en acier préfabriqué et se compose de tôles fragmentées en acier silicone à faibles pertes, isolées par une couche de peinture des deux côtés. Il est maintenu fermement en place entre deux plaques lourdes, calées sous pression. Il se divise en sections courtes par des conduits de ventilation radiaux formés de doigts qui s'étendent du sommet de chaque dent jusqu'à l'arrière du noyau et qui sont soudés à une tôle épaisse sur un côté du conduit. Les tôles sont maintenues alignées par des clavettes à queue d'aronde boulonnées dans la carcasse stator.

#### **3.5.2. Rotor :**

Le rotor se compose d'une pièce en fer forgé en alliage massif. L'enroulement est maintenu dans les encoches par des cales. Les encoches aménagées dans les dents assurent des passages d'air longitudinaux communiquant avec l'entrefer par des ouvertures entre les cales.

L'enroulement se compose de bobines multi tours faites d'une bande de cuivre enroulée sur le bord. Les enveloppantes sont maintenues par des chapeaux d'extrémité non magnétiques rétrécis à chaud sur un ergot sur le corps du rotor et renforcées par des cales d'épaisseur liées avec de la résine synthétique.

### 3.5.3. Caractéristiques nominales de l'alternateur :

- Tension aux bornes.....11000 Volts
- Fréquence..... 50 Hz
- Vitesse.....3000 tr/min
- Facteur de puissance.....0,9 en retard
- Standard.....IEC 60034-3
- Liquide de refroidissement..... L'eau à 25°C
- Puissance nominale.....48555 kVA (43700 kW)

### 3.5.4. Caractéristiques et description de l'excitatrice :

Le système d'excitation est de type THYNE4, il comporte la totalité du circuit de puissance ainsi que des fonctions de commande et de régulation numériques. Leurs principaux rôles sont :

- Produit et régule la tension de l'alternateur lorsqu'il n'est pas couplé au réseau.
- Produit et régule la puissance réactive lorsqu'il est couplé au réseau.

La tension d'excitation de l'alternateur est fournie par un transformateur de type sec monophasé. La tension générée est réglée par l'intermédiaire d'un pont redresseur monophasé. Le système d'excitation alimente l'inducteur de l'excitateur à diodes tournantes.

La partie régulation a pour fonction de réguler la tension du stator de l'alternateur en ajustant son courant d'excitation. Le courant d'excitation est contrôlé en permanence par le contrôleur de courant. Les fonctions du système de régulation consistent à :

- Ajuster la tension du stator de l'alternateur.
- être actif pour la stabilité de l'évacuation de l'énergie vers le réseau.
- Avoir un bon temps de réponse aux en cas des pannes.
- Maintenir l'alternateur dans sa plage de stabilité.

Le régulateur de tension est constitué de deux boucles de contrôle en connexion maître-esclave. Le régulateur maître est un régulateur de tension. Il contrôle la tension de l'alternateur qui dépend de la valeur de consigne du canal automatique. C'est un régulateur PID avec rétroaction de l'étage intégrateur interne.

Le régulateur esclave est un régulateur de courant d'excitation à caractéristique P(I). Grâce à cette structure à deux boucles, il est possible d'obtenir une vitesse de contrôle élevée et une grande stabilité dans tous les modes de fonctionnement et pour toutes les charges.

### **3.6. Démarrage turbine à gaz :**

#### **3.6.1. Mise en virage :**

Cette opération consiste à mettre en service le virage de la ligne d'arbre suite à un arrêt complet de la turbine à gaz.

##### **❖ Les séquences de virage :**

- Contrôle de refroidissement : Activé (le refroidissement est sélectionné).
- La pompe à huile auxiliaire 88QA démarre, la pression d'huile s'établit.
- Le ventilateur de l'éliminateur de brouillard d'huile 88QV démarre.
- Le moteur de virage hydraulique démarre 88HR et la vanne d'embrayage est activée. L'embrayage est engagé avec l'arbre.

La ligne d'arbre tourne de 1/8 de tour toutes les 3 minutes et la turbine gaz est prête à être démarrée. L'embrayage reste fermé automatiquement entre les cycles.

##### **❖ Les conditions initiales sont :**

- Fin des travaux sur la turbine à gaz.
- Ligne d'arbre à l'arrêt complet ou en séquence de refroidissement.
- Aucune alarme sur les armoires de contrôle-commande.
- Détection gaz et protection incendie opérationnelles.
- Armoires de contrôle-commande sous tension et opérationnelles.
- Equipements de puissance disponibles et opérationnels.
- Fluides disponibles (huile, eau), niveau corrects.
- Combustible disponible (gaz).
- Permissifs de démarrage correct.
- Réseau électrique disponible.

Quand la turbine gaz est restée en arrêt pendant plus de deux jours sans virage, il est recommandé de démarrer les auxiliaires en premier et de laisser la turbine en virage automatique pendant quelques cycles comme. Après quelques minutes, la séquence normale de démarrage peut être lancée.

### 3.6.2. Les séquences de démarrage :

- Mode sélec : Auto, le mode automatique est sélectionné.
- Commande démarrage : Les alarmes visuelles du compartiment turbine clignotent pour indiquer le démarrage imminent des composants suivants:
  - La pompe à huile de lubrification de secours 88QE passe à la séquence d'essai.
    - Réalisation test de la ventilation compartiment turbine (démarrage 88BT, puis s'arrête).
    - La ventilation du compartiment turbine fonctionne (démarrage 88BT).
    - Réalisation test de la ventilation compartiment gaz (démarrage 88VL, puis s'arrête).
    - La ventilation du compartiment gaz fonctionne (démarrage 88VL).
    - Démarrage de la pompe à huile auxiliaire 88QA, la pression d'huile s'établit.
    - Démarrage du ventilateur de l'éliminateur de brouillard d'huile 88QV.
    - Démarrage de la pompe à huile haute pression 88HQ.
    - Démarrage du moteur de lancement 88CR.
- 14HR
  - L'arbre commence à tourner, le signal "vitesse zéro" détecte le début de la rotation.
  - La séquence de virage hydraulique s'arrête.
- 14HT
  - Le test d'étanchéité est activé.
  - La ventilation du compartiment échappement 88EF fonctionne.
  - La ventilation du compartiment de l'alternateur 88GV fonctionne si la température du package est élevée.
  - Le premier groupe de réfrigérants démarrent.
  - Le deuxième groupe de réfrigérants 88FC démarrent par la suite en fonction de la température de l'huile de lubrification ou de l'eau de refroidissement.
  - Le cycle de purge de la gaine d'échappement est activé (3mm)
  - La séquence d'allumage est activée après le cycle de purge.
  - Les transformateurs d'allumage sont sous tension.
  - Les vannes de combustible s'ouvrent.
- 28FD
  - La présence de flamme est détectée dans les chambres de combustion
  - La ventilation du compartiment puissance 88VG est active.
  - Après allumage, le débit de combustible est maintenu à sa valeur de réchauffage pendant une minute.
  - Le débit de combustible augmente progressivement pour accélérer la vitesse d'arbre.
- 14HA
  - Le seuil de vitesse d'accélération est atteint.
- L14HC
  - Le seuil de vitesse d'auto sustentation est atteint.
  - Le moteur de lancement 88CR s'arrête.
- 14HS
  - Fermeture vanne anti-pompage compresseur.
  - La pompe à huile auxiliaire 88QA s'arrête.

- La pompe à huile haute pression 88HQ s'arrête.
- Le ventilateur de refroidissement du cadre d'échappement 88TK1, 2 démarre.
- Amorçage excitation.
- L'alternateur atteint le voltage nominal.
- Turbine à vitesse nominale.

Le graissage de la ligne d'arbre est assuré par la pompe à huile attelée. La turbine à gaz est à vitesse nominale, l'alternateur est excité à tension nominale, le groupe turbo-alternateur est prêt à être couplé au réseau pour fournir de l'énergie électrique.

### 3.6.3. Excitation alternateur :

- Contrôler la tension et le courant d'excitation  $U_{exc}$  et  $I_{exc}$ .
- Contrôler les tensions à la borne de l'alternateur U12, U23, U 31.
- Contrôler les courants de stator alternateur I1, I2, I3.
- Contrôler la fréquence alternateur.

**L'opérateur peut choisir un des modes alternateur suivant :**

- **Off:** Tension automatique géré par l'alternateur.
- **PF:** Facteur de puissance automatique réglé sur la valeur choisie par l'opérateur.
- **VAR:** Puissance réactive automatique réglé sur la valeur choisie par l'opérateur.

### 3.6.4. Couplage :

Cette opération consiste à synchroniser le turbo-alternateur avec le réseau pour la production de puissance électrique.

#### ❖ Les conditions initiales sont les suivantes :

- Turbine à vitesse nominale.
- Alternateur excité à la tension nominale.
- Réseau disponible (présence de tension).

#### ❖ Séquence de synchronisation :

- Mettre la commande contrôle synchro en Auto.
- Synchronisation mode Auto.
- Permissif synchronisation Auto.
- Fermeture disjoncteur de groupe.

### 3.6.5. Prise de charge :

Cette opération consiste à ajuster la puissance active.

#### ❖ Les conditions initiales sont les suivantes :

- Le groupe turbo-alternateur est synchronisé avec le réseau.
- Réseau disponible pour évacuer l'énergie.

**L'opérateur peut sélectionner l'un des modes de charge suivants :**

- **Préselect** : La charge atteint une puissance présélectionnée conformément à la pente de charge définie par le Speedtronic.

Une action sur les boutons poussoirs Vitesse (+ / -) annule la sélection du mode présélection (Préselect).

- **Base load** : La charge augmente jusqu'à ce que la charge de base soit atteinte conformément à la pente de charge définie par le Speedtronic.

Une action sur les boutons poussoirs Vitesse (+ / -) annule la sélection du mode Charge de Base.

- **Manuel** : Une action sur les boutons poussoirs Vitesse (+ / -) permet à l'opérateur d'ajuster la charge.

#### ❖ Les séquences de prise de charge

- Prise de charge auto charge minimale.
- Ordre prise de charge.
- DLN1 mode primaire (régime stabilisé).
- DLN1 mode « Lean Lean » environ 55%.
- DLN1 transfert de LL au secondaire (mode transitoire).
- DLN1 transfert de secondaire en premix 60% (mode transitoire).
- DLN1 mode premix stabilisé (PMSS) 79% (régime stabilisé).
- TG charge en base régulation de température.

Le groupe fournit la puissance demandée par l'opérateur.

### 3.7. Arrêt du groupe en mode gaz :

Cette opération consiste à arrêter le groupe turbo-alternateur, avant de commencer, il faut prévenir le personnel de l'arrêt du groupe.

#### Les conditions initiales sont les suivantes :

1 - Groupe synchronisé sur le réseau.

Ou

2 - Turbine à pleine vitesse sans charge.

#### 3.7.1. Les séquences d'arrêt normal

- TG en charge de base.
- DLN1 mode premix stabilisé (PMSS).
- Ordre d'arrêt.
- Baisse point de consigne.
- Baisse de charge.
- DLN1 mode Lean Lean.
- DLN1 mode primaire.
- Retour de charge détecté.
- Ouverture disjoncteur groupe.

- FSR minimum valeur.
- 14 HS baisse de la vitesse L14HS = 0
  - Arrêt ventilation de refroidissement corps turbine.
  - Ouverture vanne anti-pompage compresseur.
  - Démarrage pompe à huile principal.
  - Correction de la vitesse par la température ambiante CTIM.
  - Fermeture IGV de 42 à 34 degré.
- 14HA niveau vitesse L14HA = 0
  - Retombée de la chaîne de sécurité.
    - Vanne d'arrêt gaz non alimentée.
  - Perte flamme détectée.
- 14HM baisse de la vitesse.
- Arrêt ventilation Compartiment réducteur.
- Ouverture vanne d'évent.
- Température basse inter-roue détectée.
  - Arrêt ventilation Compartiment TG.
- 14HR arrêt ligne d'arbre détecté.
- Démarrage du vireur.
- Clutch alimenté.
- Vanne IGV non alimentée.
- Temporisation du virage.
- Ordre arrêt.
- Arrêt TG.
- Arrêt pompe à huile principale.

La turbine à gaz est dans la séquence de refroidissement, la ligne d'arbre tourne 1/8 de tour toutes les 3 minutes. L'embrayage reste automatiquement enclenché entre les cycles. La séquence de démarrage est possible à tout moment.

#### 4. Conclusion :

En ce partie nous avons montré le fondement de fonctionnement de la turbine à gaz et la description de leur principaux composants, pour bien illustré l'importance et la complexité de cette procès. Où la turbine à gaz nécessite un système de surveillance et détection de défaillances performant et robuste, pour permet garantir la sécurité du personnel et l'installation industrielle, pour cela nous avons choisi la turbine à gaz comme exemples d'application de l'analyse en composante principale(ACP) dans le domaine de détection des défauts.

# **Chapitre V**

## **Diagnostic de défauts par ACP linéaire et non linéaire d'une turbine à gaz.**

---

### **1. Introduction :**

Les turbines à gaz contribuent largement aux moteurs actuels. Leur légèreté les rend largement utilisés dans l'aviation, tandis qu'en haute puissance (production d'électricité), ils se distinguent par leur aptitude au cycle combiné ou à la cogénération très efficace.

Cependant, le diagnostic et la détection de défauts d'une turbine à gaz est très important, pour éviter les pannes complexes et réduire le temps de remise en service. En effet, améliorer leur disponibilité et optimiser le coût de maintenance.

En cette partie, nous basons sur l'application des approches proposées précédemment sur la turbine à gaz. Le système considéré comprend un turbocompresseur entraîné un alternateur. Après la modélisation et la mise en équation du système d'une turbine à gaz, on s'attache à la détection de défauts affectant ce système par la méthode d'ACP à base de réseau neurone. Enfin, une étude comparative est réalisée concernant le diagnostic par ACP linéaire et le diagnostic par ACP non linéaire.

### **2. Travaux de recherche dans le domaine du diagnostic pour les turbines à gaz :**

Dans le domaine du diagnostic de la turbine à gaz, plusieurs approches, fondées sur la notion de redondance des informations. Dans des travaux antérieurs d'autres chercheurs, des techniques de détection de défauts à vraisemblance généralisée basées sur plusieurs méthodes ont été développées, ce qui montre l'importance de cette dans un processus industriel, où nous avons quelques articles basés sur l'application des méthodes dans la détection de défauts d'une turbine à gaz :

Barrera et al [102], ont proposé une méthode de FDD (Détection et diagnostic des défauts) de machines industrielles, telles que les turbines à gaz. Leur approche exploite les données générées par les machines industrielles pour former des architectures basées sur l'apprentissage automatique, combinant plusieurs algorithmes avec des encodeurs automatiques et des fenêtres coulissantes. Leur solution proposée permet une détection précoce des défauts et a été testée avec des données réelles provenant d'environnements de travail réels. Pour construire leur solution, ils analysent d'abord mathématiquement le comportement de la turbine à gaz. Ils ont ensuite développé une architecture capable de détecter lorsque les turbines à gaz présentent un comportement anormal. Les plus grands avantages de leur proposition sont que un : elle ne

nécessite pas de données d'interférence existantes, qui peuvent être difficiles à obtenir, deux : elle n'est pas limitée aux processus avec des fenêtres temporelles spécifiques, et trois : elle fournit des informations critiques en temps réel. Le temps de surveillance du personnel, car la future maintenance prédictive génère des données précieuses. Il convient de souligner que s'ils illustrent leur approche en utilisant une turbine à gaz comme exemple, leur approche peut être appliquée à d'autres problèmes FDD dans des processus industriels complexes et à durée variable qui peuvent bénéficier des avantages susmentionnés.

Liu et al [103], où annonce que la principale difficulté de la détection d'anomalies fondée sur les données des turbines à gaz est que les données de surveillance ne comprennent qu'un très petit nombre d'échantillons anormaux et la grande majorité des échantillons normaux. Pour résoudre ce problème, leur étude développe un nouveau cadre de détection d'anomalies semi-supervisé (CSiamese), qui utilise uniquement des échantillons normaux pour optimiser les paramètres du cadre, dans le but ultime d'améliorer les performances de détection d'anomalies. Tout d'abord, un auto-encodeur convolutif est utilisé pour apprendre une représentation reconstruite des échantillons d'entrée. Deuxièmement, un réseau Siamese (réseau neuronal siamois) est choisi pour apprendre la similarité entre l'entrée mesurée et sa représentation reconstruite dans des conditions bruyantes. De plus, en améliorant la perte contrastive, c'est-à-dire la perte triangulaire, une nouvelle fonction de perte est développée qui réduit le risque d'effondrement de la solution de réseau Siamese (réseau neuronal siamois) lors de l'utilisation uniquement d'exemples positifs. Troisièmement, l'approximation du maximum d'apparence est utilisée pour définir un seuil de détection approprié pour séparer les échantillons anormaux des échantillons normaux. Enfin, l'efficacité du CSiamese développé est évaluée à l'aide de données de surveillance de turbines à gaz réelles.

Waleligne et al [104], leur étude examine la précision de différents algorithmes de classification d'apprentissage automatique sur les tâches de détection et d'isolation des pannes de turbine à gaz à l'assiste de trois techniques de lissage de données différentes. Un modèle de performance de turbine à gaz est développé en tenant compte des aubes directrices d'entrée variables et de l'air de prélèvement. Six composants principaux d'un moteur à turbine à gaz sont injectés de saleté et d'érosion. Générez des données d'erreur et de non-erreur à partir du modèle de performance étendu. Sur la base de l'analyse de sensibilité, 12 paramètres mesurés et 11 824 points de données ont été sélectionnés pour développer le modèle de détection et d'isolation des anomalies. Les données erronées et non erronées ont été équilibrées, lissées, corrigées et

normalisées. Enfin, l'exactitude de la répartition de la technique d'apprentissage automatique est analysée. Les résultats montrent que les classificateurs K-Nearest Neighbor, Neural Network et Decision Tree ont tous une précision de classification d'environ 99 % selon les trois techniques de lissage des données. Nous observons également que SVM (Support Vector Machine) prend plus de temps à calculer, tandis que K-Nearest Neighbors affiche le moins de temps. Enfin, l'étude prouve que K-Nearest Neighbors est la meilleure technique de classification moyennant la détection et l'isolation des anomalies des turbines à gaz.

Dans cette section, nous avons distingué que la majorité des études concernant la détection de défauts d'une turbine à gaz se concentrent sur l'utilisation de plusieurs méthodes analytiques (modélisation), où montre une efficacité remarquable dans le domaine de diagnostic. Pour cela nous avons choisi la modélisation par l'ACP dans la détection du défaut d'une turbine à gaz.

### 3. Variables utilisées pour construire le modèle ACP :

Pour construire le modèle ACP, nous avons utilisé 36 variables essentielles, les mesures sont prises au cours du fonctionnement normal de la turbine à gaz, voir le tableau .V.1. Les données existent collectées à partir d'un système de contrôle et surveillance (DCS) et échantillonnées à une fréquence d'une minute avec 23 000 observations au cours de quatre années de fonctionnement de la machine. Noter que la majorité des variables sont présentées dans les figures du chapitre précédent.

|       |    |   |
|-------|----|---|
| AAT   | 1  | Température de l'air d'atomisations principales |
| AFPDB | 2  | Pression entrée compresseur                     |
| AFQ   | 3  | Débit massique air admission compresseur        |
| BBMAX | 4  | Vibration maximum turbo-alternateur             |
| BBMAX | 5  | Vibration maximum turbine à gaz                 |
| CMHUM | 6  | Humidité  |
| CPD   | 7  | pression sortie compresseur                     |
| CPR   | 8  | Taux de compression de compresseur              |
| CSGV  | 9  | Angle IGV en degré                              |
| CDT   | 10 | Température décharge compresseur                |
| CTIM  | 11 | Température admission compresseur               |

|          |    |   |
|----------|----|---|
| DF       | 12 | Fréquence alternateur   |
| DPF      | 13 | Facteur de puissance  |
| DV       | 14 | Tension alternateur en %  |
| DVAR     | 15 | Puissance réactive alternateur                                      |
| DVX      | 16 | Tension alternateur   |
| DWATT    | 17 | Puissance active alternateur  |
| FPG2     | 18 | Pression combustible inter-vanne                                    |
| FQG      | 19 | Débit massique combustible gaz                                      |
| FTG      | 20 | Température combustible gaz   |
| LTB1D1   | 21 | Température purge huile de lubrification palier 1 turbine           |
| LTB2D1   | 22 | Température purge huile de lubrification palier 2 turbine           |
| LTOT     | 23 | Température réservoir d'huile de lubrification                      |
| LTTH     | 24 | Température collecteur huile de lubrification                       |
| PAT      | 25 | Température air de purge combustible                                |
| GAP2     | 26 | Pression collecteur huile de lubrification                          |
| TNH      | 27 | Vitesse de rotation d'arbre   |
| TNRCOR   | 28 | Vitesse de rotation d'arbre en %                                    |
| TTWS1AO1 | 29 | Température inter-roues première étage Arrière admission turbine    |
| TTWS1FI1 | 30 | Température inter-roues première étage Avant admission turbine      |
| TTWS2FI1 | 31 | Température inter-roues deuxième étage Avant échappement turbine    |
| TTWS3AO1 | 32 | Température inter-roues troisième étage Arrière échappement turbine |
| TTXM     | 33 | Température échappement turbine médian                              |
| TTXP1    | 34 | Premier écart réel contrôle combustion                              |
| WTAD     | 35 | Température évacuation eau de refroidissement                       |
| WTTL1    | 36 | Température eau de refroidissement patte TG                         |

**Tableau. V.1** : Description variables de la turbine à gaz.

### 3.1.Prétraitement des données :

Les référentiels de mesure sont mis à disposition car ils contiennent un tas de valeurs manquantes. Celles-ci peuvent être causées par plusieurs raisons :

- panne de la chaîne d'instrumentation,
- indisponibilité de la machine,

– mesures inacceptables pour le système (mesure absurde).

Ces mesures aberrantes (manquantes) sont des défauts de mesure et posent des problèmes pour les traitements ultérieurs, pour cela il est recommandé d'éliminer.

Selon la durée sans mesure, il existe plusieurs solutions :

– Dans le cas d'une série de plusieurs points de mesure, remplacer les valeurs manquantes par une simple interpolation linéaire, donc remplacé par une estimation ou une reconstruction à partir de mesures d'autres variables,

– Si les mesures manquantes représentent une suite de mesures sur nombreux jours ou peu de variables (notre cas), il est meilleur d'écarter toutes les données représentant à cette phase pour l'intégralité des variables.

De plus, le choix du modèle de génération résiduelle est arbitraire et ne tient probablement pas compte de la corrélation entre certaines variables. Pour cela, nous utilisons l'ACP, puisque cette approche tient en compte toutes les corrélations parmi les variables. Par conséquent, l'utilisation de l'analyse en composantes principales nécessiterait nous accepter de plus rendre compte des changements dans la nature des dépendances entre les variables.

Notez que le prétraitement des données est essentiel, incluant donc le centrage et la réduction des variables. Cela est fait afin d'empêcher certaines variables d'apparaître supérieures dans l'analyse simplement en raison de leur ampleur par rapport à d'autres variables, ce qui est également connu sous le nom de normalisation des données.

#### **4. Application de l'ACP linéaire :**

En cette partie, nous allons montrer l'application de l'ACPL à la détection d'anomalies d'une turbine à gaz conçues pour entraîner un alternateur. Dans cette application 36 variables ont été considérées.


##### **4.1.Détermination le nombre optimale de composantes principales :**

Pour définir la structure d'un modèle ACP, un critère de variance non reconstruite doit être utilisé afin de définir le nombre de composantes à conserver dans le modèle. Le tableau (tab.V.2) montre la variance non reconstruite pour différentes variables ( $i$ ) et pour différentes valeurs de  $l$ , et le graphique (Fig. V.1) montre la variation du critère de variance non reconstruite en fonction du nombre de composants. Donc, afin de que notre application soit

faible, un modèle ACP à sept composantes a été maintenu, qui expliquait 91 % des dépendances entre variables.

|     | $\ell$ (nombre de composantes principales) |        |        |        |        |        |        |        |        |
|-----|--|--------|--------|--------|--------|--------|--------|--------|--------|
|     | 3  | 4      | 5      | 6      | 7      | 8      | 9      | 10     | 11     |
| vnr | 12,787                                     | 11,897 | 11,659 | 11,623 | 11,143 | 11,298 | 11,181 | 11,589 | 12,194 |

**Table. V.2 :** Variance des erreurs de reconstruction des différentes variables.




**Figure. V.1 :** Evolution de la variance non reconstruite en fonction de  $\ell$ .


Pour obtenir un chiffre idéal de composantes principales retenu dans le spécimen d'ACP, on a choisi l'approche de la variance non reconstruite, dont la figure (V.1) montre la variation de la variance de reconstruction en fonction du nombre de composantes principales, ce résultat indique que les sept initiales composantes principales sont satisfaites pour construire le modèle ACP.

#### 4.2.L'évolution des mesures de variables et leurs modèles basées sur l'ACPL :


Les trois figures (V.2), (V.3) et (V.4) présentent, respectivement, les mesures et leurs estimations modélisées par l'analyse en composantes principales linéaire (ACPL) des variables suivants : Température de l'air d'atomisations principales (AAT), et la pression sortie compresseur (CPD).



**Figure. V.2 :** Mesure et estimation de la température de l'air d'atomisations principales (AAT) par le modèle ACP linéaire.



**Figure.V.3 :** Mesure et estimation du débit massique air admission compresseur (AFQ) par le modèle ACP linéaire.




**Figure. V.4 :** Mesure et estimation de la pression sortie compresseur (CPD) par le modèle ACP linéaire.

Compte tenu de la nature du processus de modélisation, les conclusions remportées sont très satisfaisants avec le modèle ACP conquis. En fait, nous avons évalué la majorité des pics dans les variables X3 (AFQ) et X7 (CPD), qui sont dominantes pour la procédure d'alarme. Aussi, il est plus difficile à modéliser dans le cas de la variable X1 (AAT), mais l'estimation de cette quantité reste correcte aussi bien pour les valeurs basses que pour les valeurs hautes.

#### **4.3.L'évolution de l'indice de détection cas sans défaut :**

La figure (V.4), illustre le changement de l'indice de détection (test statistique) SPE filtré à partir de données représentant le fonctionnement normal (sans défaut) de la turbine à gaz, où la ligne rouge montre le seuil de détection pour le test SPE filtré, qui modélisé par l'analyse en composantes principales linéaire (ACPL).



**Figure. V.5.** Evolution de l'indice de détection SPE filtré "cas sans défaut".

Nous avons choisi le test statistique SPE filtré comme notre indice de détection, à cause de sa simplicité d'exploitation plus leur efficacité dans le domaine de diagnostic d'une turbine à gaz.

#### 4.4. Détection de défauts par ACP linéaire :

Pour tester et vérifier l'efficacité du modèle ACPL dans le domaine de diagnostic (détection de défauts), nous avons collecté une base de données concernant quatre défauts réels qui sont affecté la turbine à gaz (modèle 6B, GE).

En se fondant sur le modèle ACPL auparavant obtenu, les quatre figures (V.5), (V.6) et (V.7) qui présentent respectivement, le changement de l'indice de détection SPE filtré en existence des quatre scénarios de défauts :

- déclenchement de la turbine à gaz par baisse pression gaz (combustible), due à un défaut au niveau de la vanne régulatrice de la pression de gaz (défaut N°1).
- déclenchement de la turbine à gaz par défaut électrique (maximum de courant 51TP), apparaitre après un déséquilibre au niveau des trois phases connecté entre le transformateur principale et le poste de transport de l'énergie électrique (défaut N°2).
- déclenchement de la turbine à gaz par défaut compresseur gaz (qui assure l'alimentation en gaz à la turbine), due à une variation excessive de la température d'huile (problème au niveau vanne thermostatique du circuit de refroidissement d'huile (défaut N°3)).




Figure. V.6. Evolution de l'indice de détection SPE filtré par le défaut N°1.





Figure. V.7. Evolution de l'indice de détection SPE filtré par le défaut N°2.



**Figure. V.8.** Evolution de l'indice de détection SPE filtré par le défaut N°3.

D'après les figures au-dessus, on remarque que l'indice de détection (courbe noire) présente un grand dépassement par rapport au seuil de détection (ligne rouge) calculé par le modèle ACP au bon fonctionnement, ce qui permet de détecter qu'un état de fonctionnement inhabituel de la turbine est survenu. Donc présence de défauts sur la turbine à gaz.

### 5. Application de l'ACP non linéaire (ACPNL) :



En cette partie, nous allons montrer l'application de l'ACPNL à la détection d'anomalies d'une turbine à gaz conçues pour entraîner un alternateur. Dans cette application 36 variables ont été utilisées pour la modélisation du système.

Dans le cas de l'ACPNL, nous avons choisi l'approche de l'ACPNL par réseau neurone à cinq couches, où l'architecture du réseau est [36-78-7-78-36] avec des fonctions non-linéaires tangente-sigmoïdale dans les couches cachées, plus nous avons étudié autre architectures aux titre comparative comme [36-78-3-78-36] et [36-28-7-28-36] . Pour les limites d'avertissement et d'action, le seuil prédéfini de signification est choisi :  $\alpha = 0.05$ .


#### 5.1.L'évolution des mesures de variables et leurs modèles basées sur l'ACPNL :

Les trois figures (V.8), (V.9) et (V.10) présentent, respectivement, les mesures et leurs estimations modélisées par l'analyse en composantes principales non linéaire (ACPNL) des

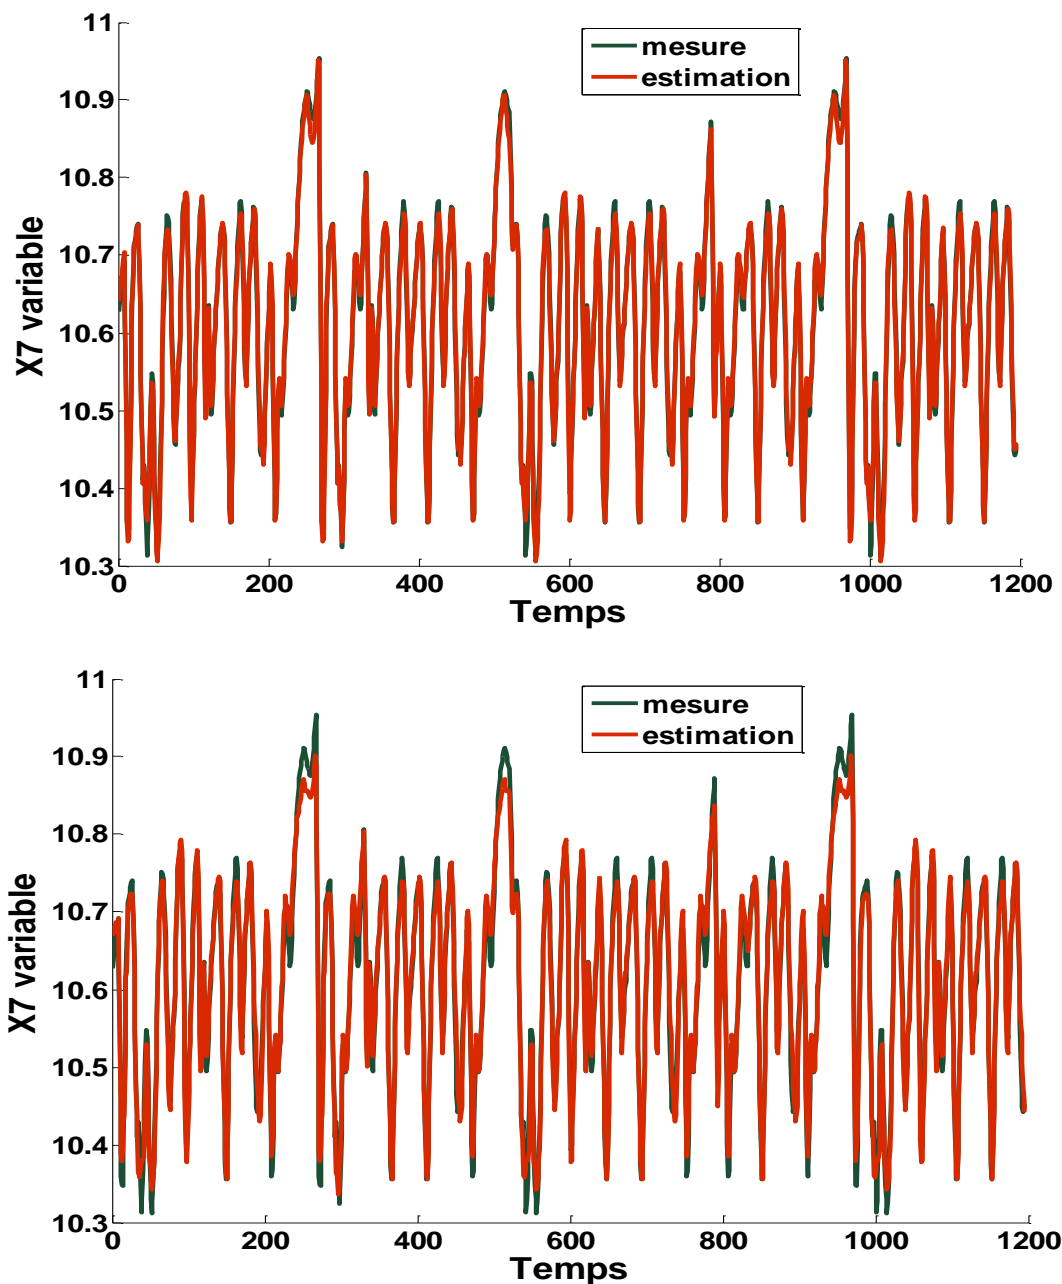
variables suivants : Température de l'air d'atomisations principales (AAT), et la pression sortie compresseur (CPD).



**Figure. V.9 :** Mesure et estimation de la température de l'air d'atomisations principales (AAT) par le modèle ACP non linéaire pour 7 CPs et 3 CPs respectivement.



**Figure .V.10 :** Mesure et estimation du débit massique air admission compresseur (AFQ) par le modèle ACP non linéaire pour 7 CPs et 3 CPs respectivement.




**Figure. V.11 :** Mesure et estimation de la pression sortie compresseur (CPD) par le modèle ACP non linéaire pour 7 CPs et 3 CPs respectivement.

Nous avons remarqué que la modélisation par l'ACP non linéaire à base de réseau neurone à cinq couche par sept composantes principales (07 CPs) est mieux significative que à trois composantes principales (03 CPs) surtout dans les variables X1 et X7.

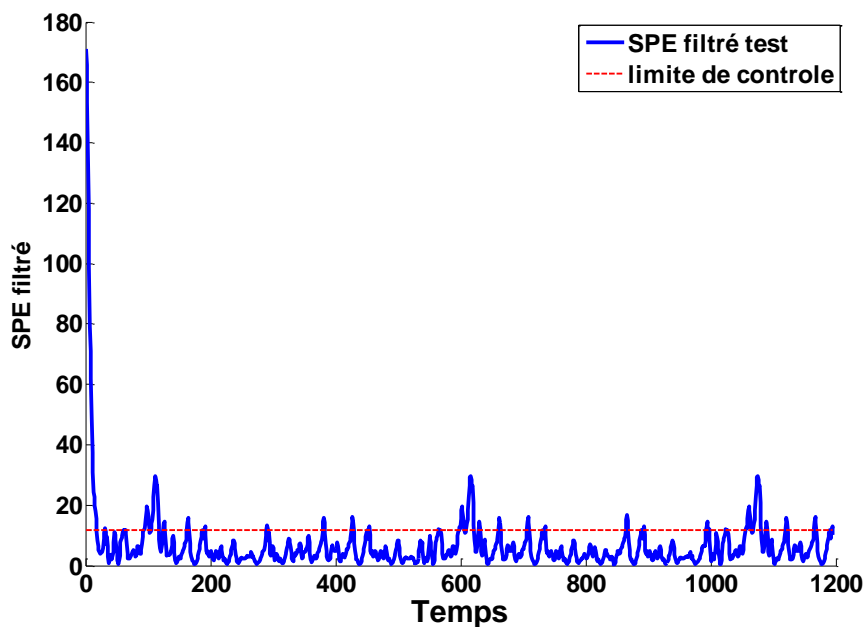
### 5.2.L'évolution de l'indice de détection cas sans défaut (ACP non linéaire) :

Les figures (V.11), (V.12) et (V.13) illustrent l'évolution de l'indice de détection (test statistique) SPE filtré à partir de données représentant le fonctionnement normal (sans défaut) de la turbine

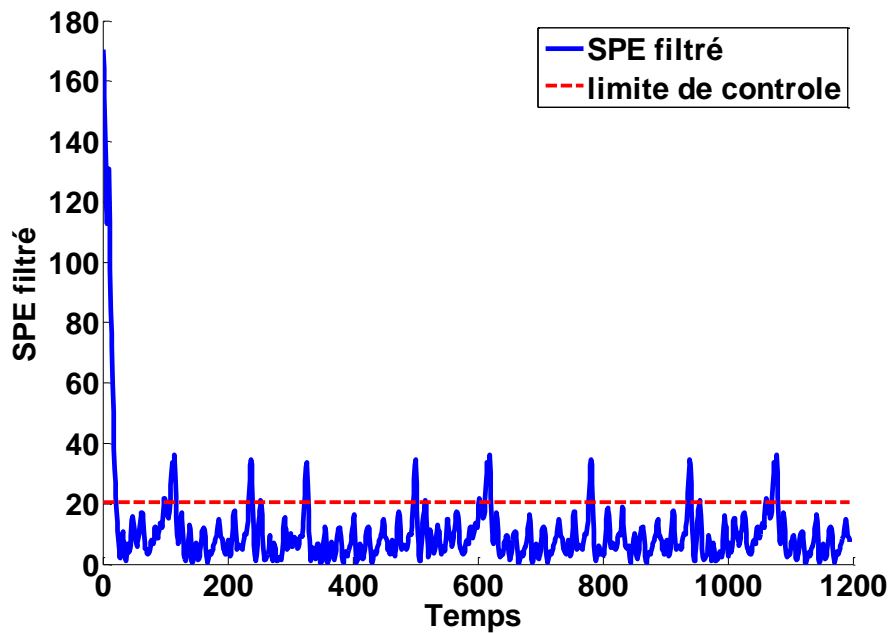
à gaz, où la ligne rouge montre le seuil de détection pour le test SPE filtré, qui modélisé par l'analyse en composantes principales linéaire (ACPL).



**Figure. V.12.** Evolution de l'indice de détection SPE filtré "cas sans défaut" pour ACPNL à 3 CPs,  $m=78$ .



**Figure. V.13.** Evolution de l'indice de détection SPE filtré "cas sans défaut" pour ACPNL à 7 CPs,  $m=78$ .



**Figure. V.14.** Evolution de l'indice de détection SPE filtré "cas sans défaut" pour ACPNL à 7 CPs, m=28.


Noter que, (m) représente le nombre du neurone dans la couche caché.

Nous avons remarqué que l'indice de détection SPE filtré "cas sans défaut" pour ACPNL à 7 CPs avec m=78 est meilleur que l'indice de détection SPE filtré "cas sans défaut" pour ACPNL à 3 CPs (m=78) et l'indice de détection SPE filtré "cas sans défaut" pour ACPNL à 7 CPs (m=28) puisque il contient moins de fluctuation et plus leur seuil (limite de contrôle) est baisse par rapport aux autres.


### 5.3.Détection de défauts par ACP non linéaire :

Pour bien tester et vérifier l'efficacité du modèle ACPNL dans le domaine de diagnostic (détection de défauts), nous avons collecté une base de données concernant quatre défauts réels qui sont affecté la turbine à gaz (modèle 6B, GE).


En se fondant sur le modèle ACPNL auparavant obtenu, où les quatre figures (V.14), (V.15) et (V.16), qui présentent respectivement, le changement de l'indice de détection SPE filtré en existence des trois scénarios de défauts (qui sont cités au-dessus dans la section 3.4) :



**Figure. V.15.a.** Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec CPs 3 ( $m=78$ ) du défaut N°1.




**Figure. V.14.b.** Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec CPs 7 ( $m=78$ ) du défaut N°1.




**Figure. V.15.c.** Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec CPs 7 ( $m=28$ ) du défaut N°1.


On remarque que les deux variantes de l'ACPNL avec 3 ou 7 composantes principales montrent une très bonne détection de défaut, qu'il détecte à partir du 400 dans l'échelle du temps, plus l'allure des deux variantes sont presque la même.



**Figure. V.16.a.** Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec 3 CPs ( $m=78$ ) du défaut N°2.

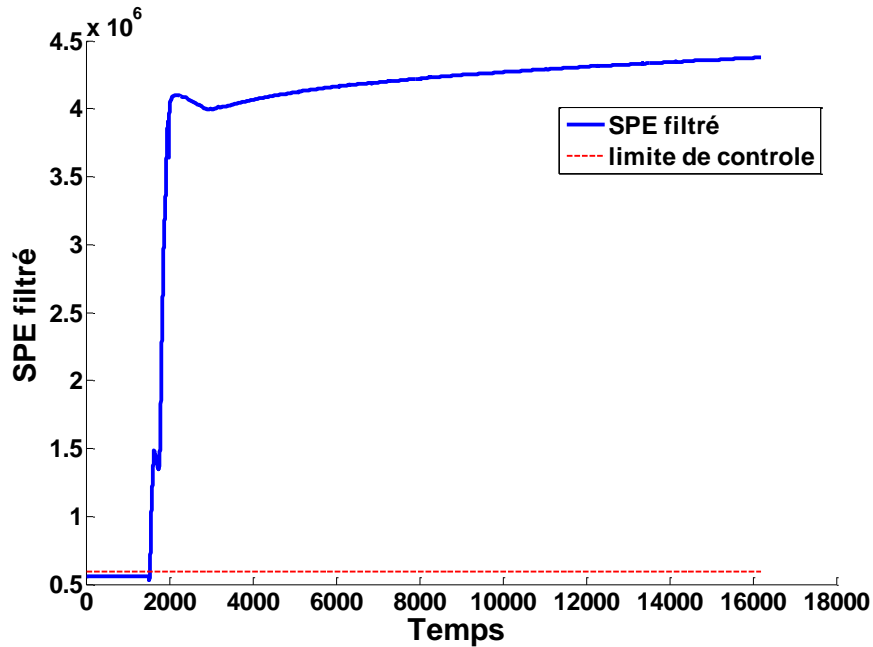


**Figure. V.16.b.** Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec 7 CPs ( $m=78$ ) du défaut N°2.




**Figure. V.16.c.** Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec CPs 7 ( $m=28$ ) du défaut N°2.


On remarque que les deux variantes de l'ACP NL avec 3 ou 7 composantes principales montrent une très bonne détection de défaut, qu'il détecte aux environ de 500 dans l'échelle du temps, plus l'allure des deux variantes sont presque la même.



**Figure. V.17.a.** Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec 3 CPs ( $m=78$ ) du défaut N°3.



**Figure. V.17.b.** Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec 7 CPs ( $m=78$ ) du défaut N°3.



**Figure. V.17.c.** Evolution de l'indice de détection SPE filtré modélisé par ACPNL avec CPs 7 ( $m=28$ ) du défaut N°3.

On remarque que les deux variantes de l'ACPNL avec 3 ou 7 composantes principales montrent une très bonne détection de défaut, qu'il détecte aux environ de 1500 dans l'échelle du temps, plus l'allure des deux variantes sont presque identique.

## 6. Interprétation et discussion des résultats :

Les résultats obtenues montre que :

- Les deux approches de l'ACP soit linéaire et non linéaire sont efficaces et fiables pour la détection de défauts, où toutes les figures dans les sections 3.4 et 4.3 montrent dépassement remarquable des seuils (limite de contrôle).
- L'ACPNL à base de réseau neurone à cinq couches donne plus d'informations et précisions que l'ACPL comme :

Le moment d'apparition du défaut.

L'ampleur et fréquence du défaut.

La période de fonctionnement normal sans défaut.

Les lignes des seuils dans l'ACPNL sont logiques et claires par rapport à l'ACPL.

- N'existe aucune différence entre toutes les variantes de l'ACPNL à base de réseau neurone à cinq couches soit à 03 CPs (nombre de composantes principales) ou à 07 CPs

et avec 28 ou 78 neurones dans la couche cachée, où toutes les figures dans la section 4.3 confirment la fiabilité et l'efficacité de détection du défaut pour toutes les variantes. Mais nous avons remarqué dans les figures concernant l'indice de détection (SPE filtré) que la qualité de l'allure (moins fluctuation et perturbation) de l'ACPNL à 07 CPs avec  $m=78$  (nombre de neurones au couche caché) est meilleur que les autres variantes soit l'ACPNL à 03 CPs avec  $m=78$ , l'ACPNL à 07 CPs avec  $m=28$ , ou l'ACPL.

### **7. Conclusion :**

En cette partie nous avons montré une application de l'analyse en composantes principales (ACP) pour la détection de défaut d'une installation industrielle de production d'énergie électrique à base d'une turbine à gaz, en utilisant la statistique SPE filtré pour la détection d'anomalies. Dans un première temps, nous avons présenté une description des 36 capteurs (variables) utilisés pour construire le modèle ACP, En 2ème étape, une base de données collectée par les mesures de ces capteurs dans le cas sans défauts (état de bon fonctionnement) est utilisée pour obtenir le modèle ACPL et ACPNL basée sur le réseau neurone à cinq couches. Ce modèle nous a permis de calculer l'indice de détection (SPE filtré) avec leur seuil de détection. Pour bien tester ce modèle dans le domaine du diagnostic, des données du 03 défauts réels, ont été collectées et utilisées, les résultats obtenu nous permet de vérifier la performance et l'efficacité de l'ACPL et l'ACPNL à détection des différents défauts. Mais montre aussi que la qualité de la détection du défaut par l'ACPNL au réseau neurone à cinq couches est supérieure que l'ACP linéaire.

**Conclusion générale :**

Les travaux de cette thèse portent sur le diagnostic des dispositifs industriels à l'aide de l'analyse en composantes principales (ACP). Dans un premier temps, nous introduisons le principe de l'analyse en composantes principales. Cette approche permet d'étudier les rapports qui trouvent parmi les variables et de déterminer la relation entre les observations multivariées pour obtenir une représentation restreinte de la dernière variable.

En cette étude, l'ACP est utilisée comme méthode pour modéliser la relation entre différentes variables d'un processus. Le modèle qui est déterminé par : l'estimation des paramètres du modèle ACP, en estimant les valeurs et les vecteurs propres de la matrice de corrélation des données, plus la résolution de la structure du modèle, en déterminant le nombre de composants (le nombre de vecteurs propres) à conserver dans ce modèle.

En effet, multiples critères de détermination du nombre de composants ont été proposés. Nous avons choisi d'utiliser le critère de la variance de reconstruction en minimisant la variance des erreurs de détermination des variables reconstruites, ce qui est très efficace pour le diagnostic car il prend en compte la redondance entre les mesures, et le plus souvent cette méthode de reconstruction est utilisée pour traiter la variable à surveiller.

Une fois le modèle déterminé, le processus de détection de défaut peut être lancé en comparant le comportement de surveillance de l'installation donné par les mesures des capteurs avec l'attitude prédit présenté par le modèle ACP pour générer des indicateurs de défaut (résiduels). Plusieurs tests sont utilisés dans les méthodes de diagnostic basées sur la ACP. Notre choix s'est porté sur les exposants de détection SPE (erreurs quadratiques) en raison de leur application simple à des données réelles d'installations industrielles.

En plus, pour optimiser l'aptitude de détection par minimisation le taux de fausse alarmes et le taux de non détection, on a utilisé un filtre passe bas de type EWMA (exponentially weighed moving average). En ce qui considère l'isolation des anomalies de l'ACP, nous montrons les méthodes le plus utilisée dans ce domaine. L'initiale est fondée sur la structure des résidus tandis que dans le cas des espaces de parité.

D'autres méthodes minent des bancs de modélisation, chacun étant sensible à un ensemble de défauts et insensible aux autres, par exemple des méthodes d'ACP partielle ou encore des

méthodes d'élimination, et des méthodes de reconstruction par principes. La dernière approche est reposée sur la théorie des contributions variables aux métriques de détection.

Dans cette étude, nous proposons un agrandissement de l'ACP dans le cas non linéaire (ACPNL). En introduisant les essentielles approches de calcul des modèles ACPNL. Les méthodes les plus connues et les plus couramment utilisées dans le domaine du diagnostic sont reposées sur les réseaux de neurones, que nous avons choisis comme étant le réseau à cinq couches le plus efficace comme méthode appliquée.

Dans la dernière partie nous avons montré l'application des approches présentées dans le cas linéaire et non linéaire à la détection de défauts d'un système de surveillance d'une turbine à gaz conçues pour entraîner un alternateur de production de l'énergie électrique.

Le travail présenté est une étude de faisabilité et confirmation la performance de l'ACP dans le domaine de diagnostic donc nous nous sommes utilisé plusieurs scénarios des défauts qui sont affectées la vie de la turbine à gaz. Avec l'indice donné on survient à détecter ces défauts, où les résultats conquis sont très encourageants à fouiller l'étude pour finaliser une procédure de diagnostic. Cependant, les résultats obtenus montrent aussi que la modélisation par l'ACPNL au réseau neurone à cinq couches est plus performante par rapport à l'ACPL.

D'un côté, nous proposons d'utiliser ce résultat de cette étude pour localiser les défauts détectés par l'approche montrée au troisième chapitre, appliquant ainsi le modèle non linéaire de l'ACP.

En ce qui contemple les applications discutées dans les sections précédent, certaines suggestions sont nécessaires pour progresser la qualité des modèles ACP. Une suggestion est d'utiliser différents modèles ACP pour différentes parties de l'opération, puisque différentes variables présentent un comportement circadien, elles peuvent être modélisées par ACP en minant des données de lot, où toute lot convient à un cycle de marche, par exemple, dans notre cas, il peut être efficace d'utiliser MWPCA (Multi-Way PCA).

## **Bibliographié:**

- [1] S. Ashish, E. Dale. Evaluation of pattern matching method for the Tennessee Eastman challenge process. *Journal of Process Control*. Vol 16.pp.601-613. 2006
- [2] S.W. Choi, J.H. Park, LEE In-Beum. Process monitoring using a Gaussian mixture model via principal component analysis and discriminant analysis. *Computer and Chemical Engineering*, Vol 28.pp.1377-1387. 2004
- [3] Y. Papadopoulos et J. McDermid. Automated safety monitoring: a review and classification of methods. *International Journal of Condition Monitoring and Diagnostic Engineering Management*, 2001.
- [4] J.A. Westerhuise, S.P. Gurden. Generalized contribution plots in multivariate statistical process monitoring of residual in MSPC. *Journal of Intelligent Laboratory systems*. Vol 51. pp. 95-114. 2000
- [5] R.Fellouah. Contribution au diagnostic de pannes pour les systèmes différentiels plats. *Automatique/Robotique*. INSA de Toulouse. 2007.
- [6] D. Ichalal, B.Marx, D.Maquin. Fault detection, isolation and estimation for Takagi-Sageno nonlinear systems. *Journal of the Franklin institute*. Vol: 352. N°7. PP 2866-2886. 2015.
- [7] E.Chow, A.Willsky. Redondance analytique et conception de systèmes de détection de pannes. *IEEE Transaction on Automatic Control*. Vol 29. Issue 7. 1984.
- [8] V. Venkatasubramanian, R. Rengaswamy, K. Yin et S.N. Kavuri. A review of process fault detection and diagnosis. 'Part I to III'. *Computers and Chemical Engineering*, 2003.
- [9] V.Uraikul, C.W.Chan, P.Tontiwa. Intelligence pour la surveillance et le contrôle de supervision des systèmes de processus. *Engineering Application of Artificial Intelligence*. Vol 20. Issue 2. 2007.
- [10] V. Venkatasubramanian, R. Rengaswamy, K. Yin et S.N. Kavuri. Un examen de la détection et du diagnostic des défauts de processus. *Informatique et génie chimique*. Vol 27. N°3. 2003.
- [11] M.Batteux. Diagnosticabilité et diagnostic de systèmes technologiques pilotés. *Intelligence artificielle*. Université Paris Sud - Paris XI, 2011.
- [12] R.N. Clark, D.C. Fosth et W.M. Walton, Detecting instrument malfunctions in control systems. *IEEE Transactions on Aerospace and Electronic Systems*. 11(4):465–473, 1975.
- [13] X. Ding et P.M. Frank, Comparison of observer-based fault detection approaches. *Proceedings of IFAC Safeprocess'94*, Helsinki, Finlande, pages 556–561, 1994.
- [14] M. Kinnaert: Fault diagnosis based on analytical models for linear and nonlinear systems - a tutorial. *Proceedings of IFAC Safeprocess'03*, Washington DC, USA, pages 37–50, 2003.
- [15] A.Alkaya, Novel data driven based fault detection for electromechanically and process control systems, Thèse Phd, Çukurova University, 2012.
- [16] A.S. Willsky : A survey of design methods for failure detection in dynamic systems. *Automatica*, 12:601–611, 1976.

- 
- [17] J.J. Gertler et D. Singer, A new structural framework for parity equation-based failure detection and isolation. *Automatica*, 26:381–388, 1990.
- [18] H. Farreny, *Les systèmes experts - Principes et exemples*. Cépadués, 1989.
- [19] S. Alvens, *Système expert d'aide au diagnostic et à la maintenance de grand entrainement électrique*, Thèse de doctorat, Institut National Polytechnique de Grenoble, 1993.
- [20] T. Kempowsky, *Surveillance de procédés à base des méthodes de classification : Conception d'un outil d'aide pour la détection et le diagnostic de défaillances*, thèse de doctorat de l'institut des sciences appliquées de Toulouse, 2004.
- [21] L. Lebart, A. Morineau, M. Piron, *Statistique Exploratoire Multidimensionnelle*, Dunod, Paris, 2004.
- [22] D. Wang, J. A. Romagnoli, Robust multi-scale principal components analysis with applications to process monitoring, *Journal of Process Control*, vol. 15, no 8, p. 869-882, 2005.
- [23] S. J. Quin, Statistical process monitoring basics and beyond, *Journal of Chemometrics*, vol. 17, no 8-9, p. 480-502, 2003.
- [24] S.J. Quin, R. Dunia, Determining the number of principal components for best reconstruction. *Journal of process control*, Vol 10, pp 254 – 2050. 2000.
- [25] N.L. Ricker, Optimal steady-state operation of the Tennessee Eastman challenge process. *Computers and Chemical engineering*, Vol 19, pp.949-959, 1994.
- [26] M. Tamura, S. Tsujita, A study on the number of principal components and of fault detection using PCA. *Computers and Chemical engineering*, 2006.
- [27] L. Weihua, S. Sirish, Structured residual vector – based approach to sensor fault detection and isolation. *Journal of Process Control*, Vol 12, pp.147-160, 2002.
- [28] B.M. Wise, *Adapting Multivariate analysis for monitoring and modeling of dynamic systems*. PhD. Dissertation, University of Washington. Seattle, 1991.
- [29] G. Zwingelstein, *Diagnostic des défaillances, théorie et pratique pour les systèmes industriels*. Edition Hermès. 1995.
- [30] R. Dunia, S. J. Qin, A subspace approach to multidimensional fault identification and reconstruction, *American Institute of Chemical Engineers Journal*, vol. 44, pp. 1813-1831, 1998.
- [31] D. Zhimin, Q. Xin, Detection and diagnosis for multiple faults in VAV systems, *Journal of Energy and Buildings*, vol. 39, n°4, pp. 923-934, 2006.
- [32] Y. Tharrault, G. Mourot, J. Ragot, D. Maquin, Fault detection and isolation with robust principal component analysis, *International Journal of Applied Mathematics and Computer Science (AMCS)*, vol. 18, n°4, pp. 429-442, 2008.
- [33] J.J. Downs, E.F. Voge, A plant-wide industrial control problem, *Computers and chemical engineering*, Vol 17, pp.245-255, 1993.

- 
- [34] S. Joe Qin, Ricardo Dunia, Determining the number of principal components for best reconstruction, *Journal of process control*, Vol. 10, pp. 245–250, 2000.
- [35] R. Dunia, S. J. Qin, Thomas F. Edgar and T. J. McAvoy, Use Of Principal Component Analysis For Sensor Fault Identification, *Computers Chem. Engng. Pergamon*, Vol. 20, pp. S713–S718, 1996.
- [36] E. R. Malinowski, *Factor Analysis in Chemistry*, Wiley-Interscience, New York, 1991.
- [37] S. Wold, Cross-validatory estimation of the number of components in factor and principal components models, *Technometrics*, vol. 20, n°4, pp. 397-405, 1978.
- [38] H. T. Eastment, W. J. Krzanowski, Cross-validatory choice of the number of components from a principal component analysis. *Technometrics*, 24(1), 73-77, 1982.
- [39] P. Besse, L. Ferre, Sur l'usage de la validation croisée en analyse en composantes principales. *Revue de statistique appliquée*, 41(1), 71-76, 1993.
- [40] R. Dunia, and S. J. Qin, Joint diagnosis of process and sensor faults using principal component analysis. *Control Engineering Practice*, 6(4), 457-469, 1998.
- [41] I.T. Jolliffe, "Principal component analysis", Springer, New York, 2002.
- [42] R. Gnanadesikan. *Methods for statistical data analysis of multivariate observations*. Wiley Editions, New York, 1977.
- [43] D. Dong and T. J. McAvoy. Nonlinear principal component analysis - based on principal curves and neural networks. *Proceeding of the American Control Conference, ACC*, 1994.
- [44] T. Hastie. *Principal curves and surfaces*. PhD thesis, Stanford University, 1984.
- [45] M. A. Kramer. Nonlinear principal component analysis using auto-associative neural networks. *AIChE Journal*, vol. 37, N° 2, pp. 233-243, 1991.
- [46] S. Tan and M. L. Mavrouniotis. Reduction data dimensionality through optimizing neural network inputs. *AIChE Journal*, vol. 41, N° 6, pp. 1471-1480, 1995.
- [47] A. R. Webb. An approach to nonlinear principal component analysis using radially symmetric kernel functions. *Statist. Comput*, vol. 6, pp. 159-168, 1996.
- [48] A. Nandakishore and T. K. Leen. Dimension reduction by local PCA. *Neural Computation*, vol. 9, pp. 1493-1510, 1997.
- [49] C. Juinghui and L. Jialin. Mixture principal component analysis models for process monitoring. *Industrial & Engineering Chemistry Research*, vol. 39, pp. 1478-1488, 1999.
- [50] T. Hastie and W. Stuetzle. Principal curves. *Journal of the American Statistical Association*, vol. 84, N° 406, pp. 502-516, 1989.

- 
- [51] R. Tibshirani. Principal curves revisited. *Statistics and computation*, vol. 2, pp. 183-190, 1992.
- [52] A. R. Webb. An approach to nonlinear principal component analysis using radially symmetric kernel functions. *Statist. Comput.*, vol. 6, pp. 159-168, 1996.
- [53] D. J. H. Wilson, G. W. Irwin. RBF principal manifolds for process monitoring. *IEEE Transaction on Neural Networks*, vol. 10, N° 6, pp. 1424-1434, 1999.
- [54] M.F. Harkat. Détection et localisation de défauts par analyse en composantes principales. *Automatique / Robotique*. Institut National Polytechnique de Lorraine - INPL, 2003.
- [55] M. Scholz, M. Fraunholz, and J. Selbig, *Nonlinear Principal Component Analysis: Neural Network Models and Applications*, F.L.Jahn, Str. 15, 17487 Greifswald, Germany, Am Muhlenberg 1, 14424 Potsdam, Germany.
- [56] M. F. Harkat, Y. Tharrault, G. Mourot, J. Ragot, Modélisation et diagnostic des systèmes non linéaires par Multi-ACP, 4 ème Colloque Interdisciplinaire en Instrumentation.
- [57] N. Pessel, J F. Balmat, F. Lafont and J. Bonnal, *Neuronal Principal Component Analysis for the Diagnosis of a Non Linear System*, LSIS, UMR CNRS 6168, University of South Toulon Var, IUT of Toulon, University of Sciences and Techniques, T23,031, 2007.
- [58] U. Thissen, W. J. Melssen, and L. M. Buydens. Nonlinear process monitoring using bottleneck neural networks. *Analytica Chimica Acta*, 446(1), 369-381, 2001.
- [59] E. C. Malthouse, R. S. H. Mah, and A. C. Tanhane. Some theoretical results on nonlinear principal component analysis. *Proceeding of the ACC*, Seattle, Washington, pp.744-748. 1995.
- [60] R. Der, U. Steinmetz, G. Balzuweit. Nonlinear principal component analysis. Technical Report at the Institut fur Informatik, Universitat Leipzig. 1998.
- [61] B. Voss. A simulation study on nonlinear principal component analysis. Technical Report 42/99 SFB 475, Department of Statistics, University of Dortmund. 1999.
- [62] A. H. Monaha. Nonlinear principal component analysis of climate data. PhD thesis, British Columbia University. 2000.
- [63] G. Kerschen and J. C. Golinval. Nonlinear generalisation of principal component analysis: from a global to a local approach. *Journal of Sound and Vibration*. 2002.
- [64] K. Funahashi. On the approximate realization of continuous mappings by neural. *Neural Networks*, vol. 2, pp. 183-192. 1989.
- [65] G. Cybenko. Approximation by superposition of sigmoidal function. *Mathematics of Control Signal and Systems*, vol. 2, pp. 303-314. 1989.

- 
- [66] M. Kerling. Optimizing the multilayer perceptron - Problems, tools and strategies. Proc. of Eufit'99, Aachen, Germany, 1999.
- [67] G. Kerschen and J.C. Golinval, Feature extraction using auto-associative neural networks, *Smart Mater. Struct.* 13, 2003.
- [68] L. Weigang, A. Rodrigues de Moraes, S. Lihua et R. Yukihiro Matsushita, Nonlinear Principal Component Analysis for Withdrawal of Employment Time Guaranty Fund, C.P. 4466, The University of Brasilia, The University of Brasilia, Brasilia DF, CEP : 70919-970, Brazil, Stanford University, USA.
- [69] E. C. Malthouse, R. S. H. Mah, and A. C. Tanhane. Some theoretical results on nonlinear principal component analysis. *Proceeding of the ACC*, Seattle, Washington, pp.744-748. 1995.
- [70] D. Dong and T.J. McAvoy. Nonlinear principal component analysis–based on principal curves and neural networks. *Computers & Chemical Engineering*, 65–78. 1996.
- [71] F. Jia, E.B. Martin and A.J. Morris. Non-linear principal component analysis for process fault detection. *Computers & Chemical Engineering*, **22** (Supplement), S851–S854, 1998.
- [72] K. Levenberg. A method for the solution of certain nonlinear problem in least squares. *Quart. Appl. Math.*, vol. 2, pp. 164-168. 1944.
- [73] D. W. Marquardt. An algorithm for least-squares estimation of nonlinear parameters. *J. Soc. Appl. MATH.*, vol. 11, pp. 431-441. 1963.
- [74] M. D. Buhmann, *Radial Basis Functions*, Cambridge University Press, Cambridge, 2003.
- [75] F. Fogelman Soulié, B. Lamy, E. Viennet, Multi-Modular Neural Networks Architectures for Pattern Recognition : Applications in Optical Characters Recognition and Human Face Recognition , *Int. J. Pattern Recognition and Artificial Intelligence*, vol. 7, n° 4, p. 721-755, 1993, Extended version as Tech. Report 827, LRI 1993.
- [76] B. Schölkopf, A. Smola, et K.-R. Müller. Nonlinear component analysis as a kernel eigenvalue problem. *Neural Comput.* 10(5), 1299–1319. 1998.
- [77] B. E. Boser, I. M. Guyon, & V. Vapnik. A training algorithm for optimal margin classifiers. In *Fifth Annual Workshop on COLT*, Pittsburgh, ACM, 1992.
- [78] M. A. Aizerman, E. M. Braverman, & L. I. Rozonoér. Theoretical foundations of the potential function method in pattern recognition learning. *Automation and Remote Control*, 25:821:837, 1964.
- [79] B. E. Boser, I. M. Guyon, & V. Vapnik. A training algorithm for optimal margin classifiers. In *Fifth Annual Workshop on COLT*, Pittsburgh, 1992. ACM.

- [80] B. Schölkopf, C. Burges, & V. Vapnik. Extracting support data for a given task. In U. M. Fayyad & R. Uthurusamy, eds., Proceedings, First International Conference on Knowledge Discovery & Data Mining, Menlo Park, CA, AAAI Press. 1995.
- [81] B. Schölkopf, A. J. Smola, & K.-R. Müller. Nonlinear component analysis as a kernel eigenvalue problem. Technical Report 44, Max-Planck-Institut für biologische Kybernetik, Submitted to Neural Computation. 1996.
- [82] M. Parizeau, Le perceptron multicouche et son algorithme de retro propagation des erreurs, Université Laval, 10 septembre 2004.
- [83] T.Kourti, and J. F.MacGregor. Recent Developments in Multivariate SPC Methods for Monitoring and Diagnosing Process and Product Performance. Journal Of Quality Technology, vol. 28, N° 4, pp. 409-428. 1996.
- [84] J. V.Kresta, J. F.MacGregor and T. E. Marlin. Multivariate statistical monitoring of process operating performance. Can. J. Chem. Eng., vol. 69, N° 1, pp. 35-47. 1991.
- [85] J. F.MacGregor, T.Kourti and P.Nomikos. Anlysis, monitoring and fault diagnosis of industrial processes using multivariate statistical projection methods. IFAC, 13th Triennial Word Congress, pp. 145-150, San Francisco, USA. 1996.
- [86] S. J.Qin, Y.Hongyu and R. Dunia. Self-validating inferntial sensors with application to air emission monitoring. Industrial & Engineering Chemistry Research, vol. 36, pp. 1675-1685. 1997.
- [87] H.Tong and C. M.Crowe. Detection of Gross errors in data reconciliation by Principal Component Analysis. Process Systems Engineering, vol. 41, N° 7. 1995.
- [88] B. M. Wise and N. B. Gallagher. The process chemometrics approach to process monitoring and fault detection. Journal of Process Control, vol. 6, N° 6, pp. 329-348. 1996.
- [89] J.Gertler and T.McAvoy . Principal component analysis and parity relations – A strong duality. IFAC Conference SAFEPROCESS, Hull, UK, pp. 837-842. 1997.
- [90] J.Gertler, L.Weihua, H.Yunbing and T.McAvoy. Isolation enhanced principal component analysis. 3rd IFAC Workshop on On-line Fault Détection and Supervision in the Chemical Process Industries, Lyon, June 4-5, France. 1998.
- [91] P.Miller, R. E.Swanson, and C. E. Heckler. Contribution plots: A missing link in multivariate quality control. Applied Mathematics and Computer Science, vol. 8, N° 4, pp. 775-792. 1998.
- [92] J. Gertler, L.Weihua, H.Yunbing and T.McAvoy, 'Isolation enhanced principal component analysis', AIChE Journal, vol. 45, pp. 323-334, 1999.
- [93] G.Cherry, S. J.Qin, 'Multiblock principal component analysis based on a combined index for semiconductor fault detection and diagnosis', IEEE Transactions on Semi- conductor Manufacturing, vol. 19, n°2, pp. 159-172, 2006.

- 
- [94] S.Yoon, J. F.MacGregor, 'Fault diagnosis with multivariate statistical models, part I : Using steady state fault signatures', *Journal of Process Control*, vol. 11, pp. 387-400, 2001.
- [95] S. J.Qin, Valle S., Piovoso M., 'On unifying multiblock analysis with applications to decentralized process monitoring', *Journal of Chemometrics*, vol. 15, pp. 715-742, 2001.
- [96] Y.Huang, J.Gertler, T.McAvoy, 'Sensor and actuator fault isolation by structured partial PCA with nonlinear extensions', *Journal of Process Control*, vol. 10, pp. 444-459, 2000.
- [97] E. A.Domlan, 'Diagnostic des systèmes `a changement de régime de fonctionnement', Thèse de Doctorat de l'Institut National Polytechnique de Lorraine, France, Octobre 2006.
- [98] C. L.Stork, D. J.Veltkamp, B. R.Kowalski, 'Identification of multiple sensor disturbances during process monitoring', *Journal of Analytical Chemistry*, vol. 69, pp. 5031-5036, 1997.
- [99] J. E.Jackson, G. S. Mudholkar. Control procedures for residuals associated with principal component analysis. *Technometrics*, vol. 21, N° 3. 1979.
- [100] S. J. Qin, and L.Weihua. Detection, identification and reconstruction of faulty sensors with maximized sensitivity. *AIChE Journal*, vol. 45, N° 9, pp. 1963-1976. 1999.
- [101] J.Gertler, J.Cao, 'Design of optimal structured residuals from partial principal component models for fault diagnosis in linear systems', *Journal of Process Control*, vol. 15, pp. 585-603, 2005.
- [102] J.M.Barrera, A.Reina, A.Mate, et al. Fault detection and diagnosis for industrial processes based on clustering and auto-encoders: a case of gas turbines. *Int. J. Mach. Learn. & Cyber.* 13, 3113–3129 (2022). <https://doi.org/10.1007/s13042-022-01583-x>.
- [103] D.Liu, S.Zhong, L.Lin, et al. CSiamese: a novel semi-supervised anomaly detection framework for gas turbines via reconstruction similarity. *Neural Comput & Applic* (2023). <https://doi.org/10.1007/s00521-023-08507-y>.
- [104] M. S. Waleligne, A. A. K. Zainal, A. L. Tamiru, Investigation of fault detection and isolation accuracy of different Machine learning techniques with different data processing methods for gas turbine, *Alexandria Engineering Journal*, Volume 61, Issue 12, 2022, Pages 12635-12651, <https://doi.org/10.1016/j.aej.2022.06.026>.