

I.3. Méthodes de surveillance

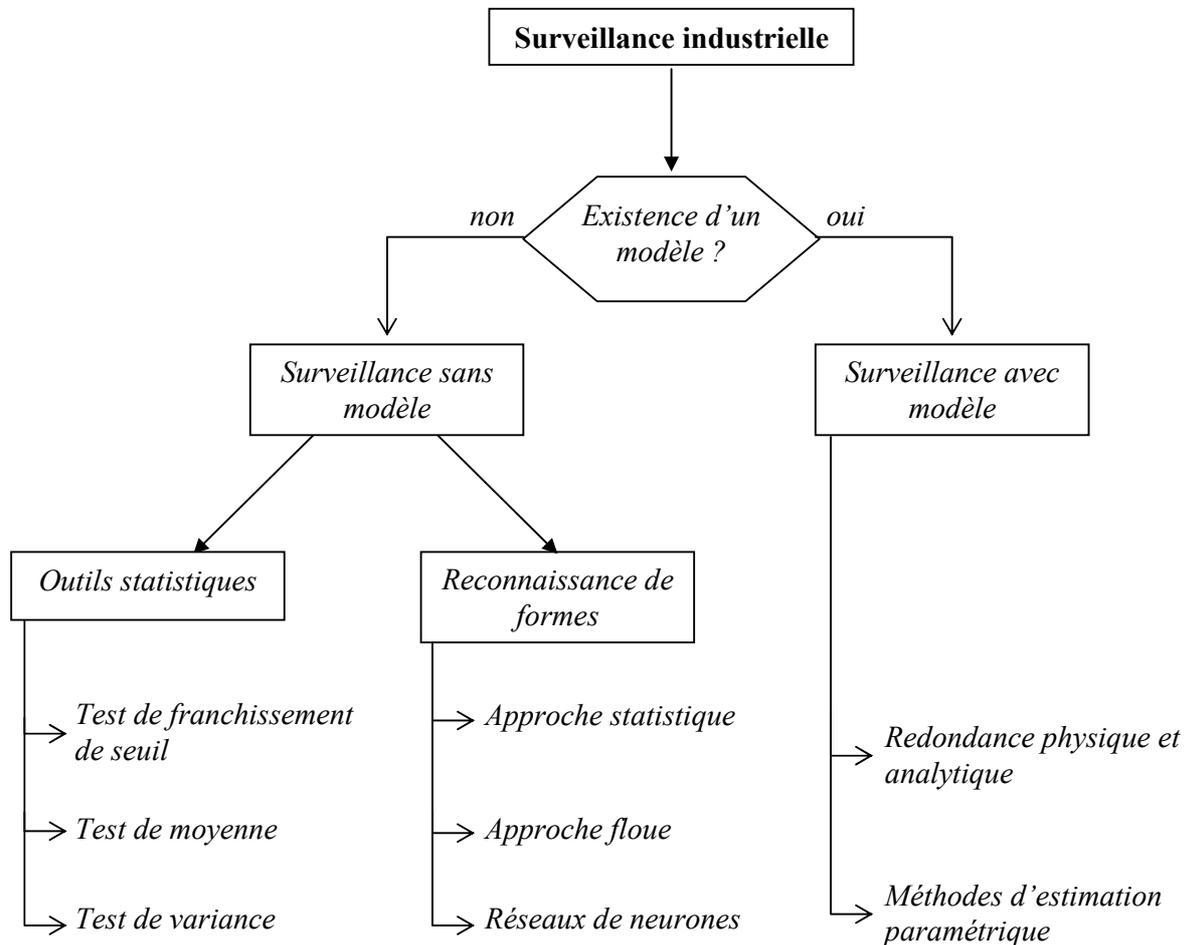


Figure 4. Classifications des méthodologies de surveillance industrielle.

Les méthodes de surveillance industrielle telle qu'elles sont présentées dans ce paragraphe sont illustrées sur la Figure 4. L'existence d'un modèle formel ou mathématique de l'équipement détermine la méthode de surveillance utilisée. La surveillance avec modèle se compose essentiellement de deux techniques : méthodes de redondance physique et analytique et méthodes d'estimation paramétrique. D'un autre côté, les méthodes qui ne se basent pas sur l'existence du modèle se divisent en deux catégories : méthodes utilisant des outils statistiques et méthodes de reconnaissance des formes. Les outils statistiques établissent des tests sur les signaux d'acquisition. Ces tests ne sont capables d'assurer que la fonction détection de défaillances. Par contre, les techniques de surveillance par reconnaissance des formes sont plus élaborées par rapport aux simples tests statistiques et sont capables de détecter et de diagnostiquer les défaillances.

I.3.1. Méthodes de surveillance avec modèles

Les méthodes de surveillance avec modèle ont pour principe de comparer les mesures effectuées sur le système aux informations fournies par le modèle (Frank, 1990). Tout écart est alors synonyme d'une défaillance. Les outils de la théorie de la décision sont ensuite utilisés pour déterminer si cet écart est dû à des aléas normaux comme, par exemple, le bruit de mesure ou s'il traduit une défaillance du système. Ces méthodes peuvent être séparées en deux techniques : techniques de redondance physique et analytique et techniques d'estimation paramétrique. Ces deux techniques seront présentées brièvement. Toutefois, pour plus de détails, nous renvoyons le lecteur aux références suivantes : (Willsky, 1976), (Isermann, 1984), (Basseville, 1988), (Gertler, 1988), (Patton et al., 1989), (Frank, 1990), (Combacau, 1991), (Basseville et al., 1993), (Cussenot, 1996), (Gertler, 1998), (Weber, 1999), (Tromp, 2000), (Combastel, 2000).

I.3.1.1. Redondances physiques et analytiques

a) Redondances physiques

Afin de fiabiliser la détection des défaillances à partir des signaux mesurés, il faut un moyen pour distinguer les défaillances capteurs des défaillances système. La méthode la plus simple consiste à utiliser la redondance physique. Il s'agit de doubler ou tripler des composantes de mesure du système. Si ces composantes identiques placées dans le même environnement émettent des signaux identiques, on considère que ces composants sont dans un état de fonctionnement nominal et, dans le cas contraire, on considère qu'une défaillance capteur s'est produite dans au moins une des composantes (Zhang, 1999). Cette méthode par redondance physique a l'avantage d'être conceptuellement simple mais est coûteuse à être mise en œuvre et conduit à des installations encombrantes. Elle est, par conséquent, utilisée uniquement pour la surveillance des sous-ensembles critiques d'un système. Un autre inconvénient est que les composantes identiques fabriquées dans la même série peuvent se dégrader de la même façon et tomber en panne en même temps. Pour pallier ce dernier inconvénient, on peut utiliser des composantes différentes qui remplissent la même fonction.

b) Redondances analytiques

Les méthodes de redondance analytique nécessitent un modèle du système à surveiller. Ce modèle comprend un certain nombre de paramètres dont les valeurs sont supposées connues lors du fonctionnement nominal. Dans la mesure où la surveillance est établie à partir des mesures échantillonnées des grandeurs observables du système, la modélisation de ce dernier sous forme discrète semble être raisonnable. De plus, dans le cas où le système présente un

caractère non linéaire, il est possible, afin de disposer d'un modèle plus simple, d'opérer une linéarisation autour d'un point de fonctionnement.

Le modèle d'espace d'état discret échantillonné relie le vecteur d'état $x(k)$ au vecteur d'entrée $u(k)$ et au vecteur de sortie $y(k)$ du système à surveiller par l'intermédiaire des matrices A , B et C (indépendante du temps) sous la forme :

$$\begin{aligned} x(k+1) &= Ax(k) + Bu(k) \\ y(k) &= Cx(k) \end{aligned} \quad [1]$$

Les défaillances et les perturbations qui peuvent survenir dans le procédé peuvent être alors modélisées à partir de ces équations. Les fautes $F_p(k)$ et le bruit $b_p(k)$ du procédé sont représentés de façon additive :

$$x(k+1) = Ax(k) + Bu(k) + PF_p(k) + Qb_p(k) \quad [2]$$

Les erreurs de mesures $F_u(k)$ et $F_y(k)$ des entrées et des sorties ainsi que les bruits $b_u(k)$ et $b_y(k)$ sont modélisés par les relations :

$$\begin{aligned} \tilde{u}(k) &= u(k) + F_u(k) + b_u(k) \\ \tilde{y}(k) &= y(k) + F_y(k) + b_y(k) \end{aligned} \quad [3]$$

où $\tilde{u}(k)$ représente en fait la réalisation du signal de commande $u(k)$ par les actionneurs et $\tilde{y}(k)$ la mesure du signal $y(k)$.

Les différences entre les matrices de paramètres du modèle et celles du système réel se traduisent par :

$$\tilde{A} = A + \Delta A(k), \tilde{B} = B + \Delta B(k), \tilde{C} = C + \Delta C(k) \quad [4]$$

Le but des méthodes de redondance analytique est d'estimer l'état du système afin de le comparer à son état réel. L'estimation de l'état du système peut être réalisée soit à l'aide de techniques d'estimation d'état, soit par obtention de relations de redondance analytique.

Le but des techniques d'estimation d'état est de reconstruire au moyen d'observateur, les états et les sorties du système, à partir des entrées et des sorties mesurées (Frank, 1990). On disposera donc d'une estimation du vecteur d'état et du vecteur de sortie du système, vecteur qui correspond généralement aux grandeurs mesurables. Ces sorties estimées sont alors comparées aux sorties réelles et tout écart est révélateur d'une défaillance. La théorie de la

décision est ensuite utilisée pour déterminer si l'écart observé est dû à des aléas normaux du fonctionnement ou à des défaillances.

Les relations de redondance analytique sont utilisées lorsque le modèle fait intervenir des grandeurs mesurables. Les relations de redondance analytique sont des relations entre les variables disponibles du système, prises dans une fenêtre temporelle. La redondance directe est la méthode la plus simple pour éliminer le vecteur d'état $x(k)$. Elle se produit parmi les capteurs qui mesurent les grandeurs qui sont reliées par les relations algébriques du modèle. C'est-à-dire que ces grandeurs sont reliées de façon à ce que la grandeur que mesure un capteur puisse être déterminée par les valeurs instantanées délivrées par les autres capteurs.

Dans les deux méthodes (estimation d'état et relations de redondance analytique) on dispose d'une estimation de l'état du système. La comparaison avec son état réel fournit alors une quantité appelée *résidu* qui va servir à déterminer si le système est dans un état défaillant ou non. Un résidu idéal doit rester à zéro en absence de panne et s'éloigner de zéro en présence de panne. A cause des erreurs de modélisation et des bruits de mesures, un résidu réel est souvent différent de zéro. Pour les pannes additives dans les systèmes d'états linéaires à paramètres constants dans le temps, la génération et l'évaluation de résidus ont été largement étudiées, tant du point de vue déterministe que stochastique (Willsky, 1976), (Patton *et al.*, 1989), (Frank, 1990), (Basseville *et al.*, 1993), (Basseville, 1997), (Gertler, 1998), (Chen *et al.*, 1999). En revanche, en ce qui concerne les pannes non additives, même pour les systèmes d'état linéaires, les résultats connus sont moins abondants (Zhang, 1999). La situation est encore moins florissante pour les systèmes non linéaires. Toutefois, pour surveiller les pannes d'amplitude faible, une démarche générale a été développée à l'IRISA² (Zhang, 1999) qui, s'appuyant sur une approche locale, permet de concevoir des algorithmes pour la génération de résidus à partir des fonctions d'estimation et pour leur évaluation. Elle s'applique à une large classe de systèmes non linéaires avec des pannes additives ou non.

I.3.1.2. Méthodes d'estimation paramétrique

Les méthodes d'estimation paramétrique supposent l'existence d'un modèle paramétrique décrivant le comportement du système et que les valeurs de ces paramètres en fonctionnement nominal soient connues. Elles consistent alors à identifier les paramètres caractérisant le fonctionnement réel, à partir de mesures des entrées et des sorties du système (Willsky, 1976). On dispose ainsi d'une estimation des paramètres du modèle, effectuée à partir des mesures prises sur le système et de leurs valeurs théoriques. Pour détecter l'apparition de défaillances dans le système, il faut effectuer la comparaison entre les paramètres estimés et les paramètres théoriques. Comme pour les méthodes de redondance analytique, la théorie de la décision sert alors à déterminer si l'écart observé est dû à des aléas normaux du fonctionnement ou à des défaillances. La différence entre les méthodes de redondance analytique et les méthodes

² Institut de Recherche en Informatique et Systèmes Aléatoires.

d'estimation paramétrique est qu'on effectue, pour les premières, la comparaison entre l'état estimé et l'état théorique du système, alors que pour les secondes, on compare les paramètres estimés aux paramètres théoriques du système.

La procédure générale d'estimation paramétrique pour la surveillance peut être décrite en 5 étapes (Isermann, 1984) :

- établissement du modèle mathématique du procédé dans les conditions normales de fonctionnement, à partir de considérations théoriques :

$$y(t) = f(u(t); \boldsymbol{\theta}) \quad [5]$$

dans lequel $u(t)$ et $y(t)$ désignent respectivement les entrées et les sorties du système et $\boldsymbol{\theta}$ représente le vecteur des paramètres du modèle.

- Détermination des relations entre les paramètres physiques du modèle $\boldsymbol{\theta}$ et les paramètres physiques du procédé \mathbf{p} :

$$\boldsymbol{\theta} = g(\mathbf{p}) \quad [6]$$

dans lequel \mathbf{p} désigne les constantes physiques du système, supposées connues, qui sont modifiées lorsqu'une défaillance survient.

- Estimation $\hat{\boldsymbol{\theta}}$ des paramètres $\boldsymbol{\theta}$ du modèle à l'aide de l'équation [5] et à partir des mesures des entrées $u(t)$ et des sorties $y(t)$ du système en fonctionnement réel

$$\hat{\boldsymbol{\theta}}(t) = h(y(1)...y(t); u(1)...u(t)) \quad [7]$$

- Estimation $\hat{\mathbf{p}}$ des paramètres physiques \mathbf{p} du système à partir de la relation [6]

$$\hat{\mathbf{p}}(t) = g^{-1}(\hat{\boldsymbol{\theta}}(t)) \quad [8]$$

- Détermination de la présence d'une défaillance ou pas. Elle se fait soit à partir de la comparaison entre les paramètres théoriques connus $\boldsymbol{\theta}$ du modèle et ceux estimés lors du fonctionnement réel $\hat{\boldsymbol{\theta}}$, soit en comparant les paramètres physiques \mathbf{p} connus du système à ceux estimés lors du fonctionnement réel $\hat{\mathbf{p}}$. Cette détermination fait également appel à la théorie de la décision.

Les méthodes d'estimation paramétrique requièrent donc l'élaboration d'un modèle dynamique précis du système à surveiller. Ceci restreint leur utilisation à des procédés bien

définis. Nous pouvons citer à titre d'exemple les travaux réalisés par *Desforges* (Desforges, 1999) qui se basent exactement sur la technique d'estimation paramétrique. Un réseau de neurones sert à estimer les paramètres physiques d'une machine outil à partir de la mesure du courant, tension et vitesse de rotation de l'axe de la machine outil. Les valeurs estimées sont utilisées comme base pour la détection et le diagnostic des défaillances.

I.3.2. Méthodes de surveillance sans modèles

Nombreuses sont les applications industrielles dont le modèle est difficile, voire impossible à obtenir suite à une complexité accrue ou à de nombreuses reconfigurations intervenants durant le processus de production. Pour ce type d'applications industrielles, les seules méthodes de surveillance opérationnelles sont celles sans modèle. Deux solutions existent dans ce cas : surveillance avec des tests statistiques et surveillance par reconnaissance des formes. La première technique est moins élaborée que la deuxième dans le sens où elle ne remplit qu'une partie de la surveillance, à savoir la détection des défaillances. Nous détaillerons donc un peu plus la partie surveillance par reconnaissance des formes. Trois approches sont alors utilisées : approche probabiliste, approche floue et approche neuronale (Dubuisson *et al.*, 2001).

I.3.2.1. Surveillance avec outils statistiques

Les outils statistiques de détection de défaillances consistent à supposer que les signaux fournis par les capteurs possèdent certaines propriétés statistiques. On effectue alors quelques tests qui permettent de vérifier si ces propriétés sont présentes dans un échantillon des signaux mesurés de taille n (appelé fenêtre d'observation glissante). On considère que le signal mesuré est une variable aléatoire notée par γ . Nous ne présentons que trois tests statistiques, mais une grande variété de tests, applicables sur un échantillon de mesures, peut être trouvée dans (Basseville, 1988).

a) Test de franchissement de seuils

Le test le plus simple est de comparer ponctuellement les signaux avec des seuils préétablis. Le franchissement de ce seuil par un des signaux capteurs génère une alarme. On peut trouver dans l'industrie deux types de seuils. Un premier type est dit seuil de pré-alarme qui permet d'entreprendre une action de maintenance préventive ; le second type est le seuil d'alarme qui impose l'arrêt de la production et l'engagement d'une action de maintenance corrective. Ce type de méthode est très simple à mettre en œuvre mais ne permet pas d'établir

un diagnostic des défaillances. Cette méthode est aussi très sensible aux fausses alarmes (Figure 5).

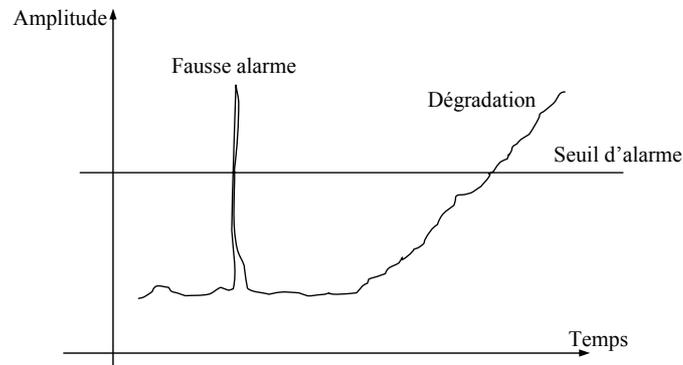


Figure 5. Sensibilité de la méthode à franchissement de seuils aux fausses alarmes.

b) Test de moyenne

Contrairement à la méthode précédente, le test de comparaison est effectué sur la moyenne \hat{y} du signal contenu dans une fenêtre de n valeurs plutôt que sur une valeur ponctuelle :

$$\hat{y} = \frac{1}{n} \sum_{i=t-n+1}^t y_i \quad [9]$$

Ceci rejoint le principe du calcul des tendances, une des techniques les plus simples de la maintenance prédictive.

c) Test de variance

On peut également calculer la variance d'un signal. Tant que cette variance se situe dans une bande située autour de sa valeur nominale, l'évolution du système est supposée normale. La variance de l'échantillon est définie par :

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=t-n+1}^t (y_i - \hat{y})^2 \quad [10]$$

I.3.2.2. Surveillance par reconnaissance des formes

L'approche de surveillance par reconnaissance des formes permet d'associer un ensemble de mesures (continues ou discrètes) effectuées sur le système à des états de fonctionnement connus. Cette fonction permet d'avoir une relation d'un espace caractéristique vers un espace de décision, de façon à minimiser le risque de mauvaise classification. Trois techniques de reconnaissance des formes sont présentées. La première technique présentée est une technique classique de discrimination basée sur les outils de la probabilité. Cette technique peut se montrer insuffisante car elle suppose une connaissance *a priori* de tous les états de fonctionnement et ne prend pas en compte l'évolution du système (Denoeux *et al.*, 1998). Les deux autres techniques de discrimination qui seront présentées reposent sur la théorie de l'intelligence artificielle. Ces techniques ont l'avantage de ne pas se baser sur les connaissances *a priori* des états de fonctionnement mais plutôt sur une phase d'apprentissage. Ces deux techniques sont la reconnaissance des formes par la logique floue et la reconnaissance des formes par réseaux de neurones.

a) Reconnaissance des formes par outils statistiques

Le formalisme général de ces techniques de reconnaissance des formes est de devoir décider parmi M classes pour tout vecteur d'entrée \mathbf{x} (vecteur forme). Les classes sont désignées par $\alpha_1, \alpha_2, \dots, \alpha_M$. On utilise alors une application d qui associe un scalaire i à chaque vecteur d'entrée \mathbf{x} :

$$d(\mathbf{x}) = i, \text{ où } \mathbf{x} \text{ est associé à la classe } \alpha_i \text{ avec } i = 1, \dots, M$$

Les probabilités *a priori* $\Pr(\alpha_i)$ des classes $\alpha_1, \alpha_2, \dots, \alpha_M$ sont connues. Deux cas sont possibles :

- Toutes les classes sont connues et dans ce cas on obtient la somme de toutes les probabilités égale à un (équation [11]). Cette situation est appelée cas d'un *monde fermé*.

$$\sum_{i=1}^M \Pr(\alpha_i) = 1 \quad [11]$$

- Dans le deuxième cas, toutes les classes ne sont pas connues. On utilise alors une classe α_0 appelée classe de rejet en distance pour combler le manque d'information sur le problème. Cette classe représente donc le mélange de toutes les autres classes non identifiées par l'utilisateur. C'est ce dernier qui lui associera une probabilité, en fonction de son degré de connaissance ou d'ignorance du système. Ce cas est qualifié de *monde ouvert*. On obtient donc la relation suivante :

$$\sum_{i=0}^M \Pr(\alpha_i) = 1 \quad [12]$$

La loi de probabilité de \mathbf{x} dans chaque classe $\alpha_1, \alpha_2, \dots, \alpha_M$ est supposée connue et caractérisée par les lois conditionnelles : $\varphi(\mathbf{x} / \alpha_i)$ $i = 1, \dots, M$. La loi du vecteur \mathbf{x} , quand on ne connaît pas sa classe d'appartenance, est donnée par la loi mélange $\varphi(\mathbf{x})$:

$$\varphi(\mathbf{x}) = \sum_{i=0}^M \Pr(\alpha_i) \varphi(\mathbf{x} / \alpha_i) \quad [13]$$

La qualité de la décision des classes d'affectation de \mathbf{x} est quantifiée par un coût de décision, $C(i, \alpha_j)$ (Duda, 1973), coût de décider α_i quand α_j est la vraie classe de \mathbf{x} ($i, j = 0, \dots, M$). La décision peut être aussi qualifiée par un autre coût qui peut jouer un rôle particulier : c'est le coût entraîné par le fait de ne pas prendre de décision. Ce coût est appelé rejet d'ambiguïté. Sa valeur est égale à (-1) quelle que soit la vraie classe α_i de \mathbf{x} : $C(-1, \alpha_i)$. La décision finale est jugée par un indicateur de performance, appelé *risque moyen de décision* R , dont on cherchera à obtenir la valeur minimal (Fukunaga, 1990).

Pour un vecteur donné \mathbf{x} , le risque R est associé à la décision $d(\mathbf{x})$:

$$R(\mathbf{x}) = \sum_{j=0}^M C(d(\mathbf{x}), \alpha_j) \Pr(\alpha_j / \mathbf{x}) \quad [14]$$

où $\Pr(\alpha_j / \mathbf{x})$ représente la probabilité *a posteriori* de la classe α_j :

$$\Pr(\alpha_j / \mathbf{x}) = \frac{\Pr(\alpha_j) \varphi(\mathbf{x} / \alpha_j)}{\varphi(\mathbf{x})} \quad [15]$$

R peut être moyenné pour tous les vecteurs \mathbf{x} : On obtient ainsi le risque moyen \hat{R}

$$\hat{R} = \int R(\mathbf{x}) \varphi(\mathbf{x}) d\mathbf{x} \quad [16]$$

La règle minimisant ce critère est appelée *règle de Bayes* ou *règle du risque minimum* (Fukunaga, 1990). Cette règle consiste à choisir la décision $d(\mathbf{x})$ qui minimise [14] et [16].

Pour fixer les coûts des décisions en surveillance, on adopte souvent la procédure suivante :

$$C(i, \alpha_j) = \begin{cases} 1 & i \neq j \\ 0 & i = j \end{cases} \quad i, j = 0, M \quad [17]$$

$$C(-1, \alpha_j) = a$$

L'équation [14] devient alors :

- si $d(\mathbf{x}) = -1$

$$R(\mathbf{x}) = R_a(\mathbf{x}) = a \quad [18]$$

- si $d(\mathbf{x}) = i$

$$R(\mathbf{x}) = R_i(\mathbf{x}) = 1 - \Pr(\alpha_i / \mathbf{x}) \quad [19]$$

La règle de décision est alors :

- soit le vecteur \mathbf{x} est associé à une des classes connues α_i

$$\Pr(\alpha_i / \mathbf{x}) = \max_{j=0, M} \Pr(\alpha_j / \mathbf{x}) \quad \text{et} \quad \Pr(\alpha_i / \mathbf{x}) \geq 1 - a \quad [20]$$

- soit le vecteur \mathbf{x} est rejeté en ambiguïté entre deux ou plusieurs classes connues

$$\Pr(\alpha_i / \mathbf{x}) = \max_{j=0, M} \Pr(\alpha_j / \mathbf{x}) \quad \text{et} \quad \Pr(\alpha_i / \mathbf{x}) < 1 - a \quad [21]$$

On préfère dans ce cas ne pas le classer plutôt que de risquer de commettre une erreur.

- soit le vecteur \mathbf{x} est rejeté en distance comme n'appartenant à aucune des classes connues

$$\Pr(\alpha_0 / \mathbf{x}) = \max_{j=0, M} \Pr(\alpha_j / \mathbf{x}) \quad \text{et} \quad \Pr(\alpha_0 / \mathbf{x}) \geq 1 - a \quad [22]$$

Le vecteur \mathbf{x} est considéré comme membre d'une nouvelle classe.

- soit le vecteur \mathbf{x} est rejeté en ambiguïté entre une ou plusieurs classes connues et la classe de rejet en distance

$$\Pr(\alpha_0 / \mathbf{x}) = \max_{j=0, M} \Pr(\alpha_j / \mathbf{x}) \quad \text{et} \quad \Pr(\alpha_0 / \mathbf{x}) < 1 - a \quad [23]$$

On préfère dans ce cas ne pas prendre de décision plutôt que d'associer le vecteur \mathbf{x} à une classe ou de le rejeter en distance comme membre d'une nouvelle classe.

Cas gaussien

La plupart du temps, on ne dispose pas de loi de probabilité des vecteurs formes dans chaque classe. On peut toutefois considérer que chaque vecteur \mathbf{x} obéit à une loi de Gauss dans chaque classe, loi dont on ignore les paramètres. Les paramètres de ces lois doivent être estimés. On doit alors disposer d'échantillons de vecteurs pour chaque classe que l'on prend en considération dans le système de décision.

La densité de probabilité d'une loi gaussienne s'écrit :

$$\varphi(\mathbf{x} / \alpha_i) = \frac{1}{\sigma^2 (2\pi)^{d/2}} \exp\left(-\frac{1}{2\sigma^2} (\mathbf{x} - \boldsymbol{\mu}_i)(\mathbf{x} - \boldsymbol{\mu}_i)^t\right) \quad [24]$$

où $\boldsymbol{\mu}_i$ est le vecteur espérance mathématique de la classe α_i :

$$\boldsymbol{\mu}_i = E(\mathbf{x}) \quad \text{avec} \quad \mathbf{x} \in \alpha_i \quad [25]$$

et σ^2_i représente la variance de la classe α_i :

$$\sigma^2_i = E\left((\mathbf{x} - \boldsymbol{\mu}_i)(\mathbf{x} - \boldsymbol{\mu}_i)^t\right) \quad \text{avec} \quad \mathbf{x} \in \alpha_i \quad [26]$$

Si l'on prend un cas monodimensionnel, on peut représenter les quatre règles de décision citées précédemment (équations [20], [21], [22], [23]) sur la Figure 6.

Comme nous l'avons dit précédemment, les paramètres des distributions gaussiennes ne sont pas a priori connus. Ces paramètres sont le vecteur espérance mathématique $\boldsymbol{\mu}_i$ et la variance σ^2_i . Il faut donc disposer d'un échantillon de vecteurs indépendant pour chaque classe. Soient donc $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N$ cet échantillon appartenant à la classe α_i . Un des moyens de déterminer ces paramètres est l'estimateur du maximum de vraisemblance. On obtient alors :

$$\hat{\boldsymbol{\mu}}_i = \frac{1}{N} \sum_{j=1}^N \mathbf{x}_j \quad [27]$$

ainsi que la variance avec l'estimateur sans biais :

$$\widehat{\sigma^2}_i = \frac{1}{N-1} \sum_{j=1}^N (\mathbf{x}_j - \hat{\boldsymbol{\mu}}_i)(\mathbf{x}_j - \hat{\boldsymbol{\mu}}_i)^t \quad [28]$$

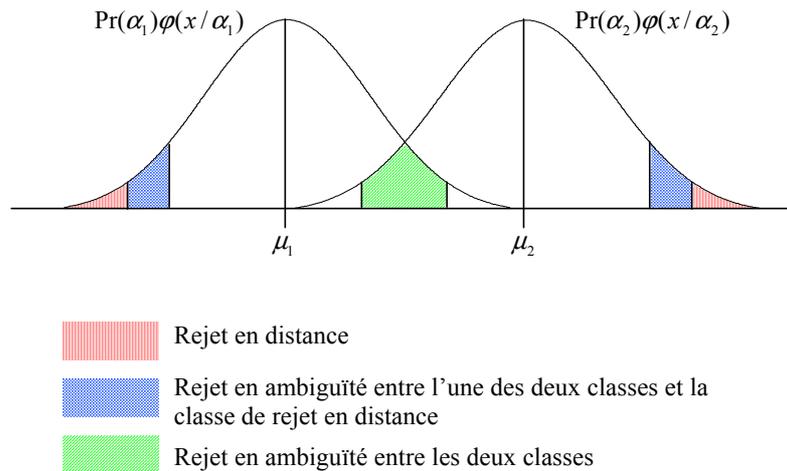


Figure 6. Représentation des différentes zones de deux distributions gaussiennes. Le rejet en distance aux deux extrémités des gaussiennes traduit l'équation [22]. La zone d'intersection des deux gaussiennes représente une situation de rejet d'ambiguïté, traduite par l'équation [21]. Un autre rejet d'ambiguïté entre l'une des deux classes et la classe de rejet en distance est traduit par l'équation [23]. Le reste de la zone représente l'appartenance de x à l'une des deux classes.

b) Reconnaissance des formes par une approche floue

En reconnaissance des formes par approche floue, les classes sont représentées par des sous-ensembles flous. Une fonction d'appartenance quantifie le degré d'appartenance $\lambda_i(\mathbf{x})$ de chaque vecteur \mathbf{x} à la classe α_i . Généralement, on donne pour chaque vecteur \mathbf{x} l'ensemble des degrés d'appartenance à toutes les classes $(\lambda_1(\mathbf{x}), \dots, \lambda_M(\mathbf{x}))$. La mise en œuvre d'une méthode de classification floue implique deux étapes : la construction des fonctions d'appartenance et la définition des règles de décision.

Définition des fonctions d'appartenance (fuzzification)

L'un des premiers algorithmes proposés pour construire automatiquement des fonctions d'appartenance dites aussi partition floue, est l'algorithme (*Fuzzy k-Means*) ou algorithme des centres mobiles flou, introduit par (Dunn, 1974) et (Bezdek, 1974). Cet algorithme non supervisé consiste à minimiser itérativement un critère en fonction d'une matrice de partition floue $U = [\lambda_k(\mathbf{x}_i)]_{(k=1, M; i=1, N)}$ et $V = (\mu_1, \dots, \mu_M)$ de la forme :

$$J_m(U, V) = \sum_{i=1}^N \sum_{k=1}^M \lambda_k(\mathbf{x}_i)^m d_k(\mathbf{x}_i)^2 \quad [29]$$

avec les conditions suivantes :

$$\lambda_k(\mathbf{x}_i) \in [0, 1] \quad \forall i, k, \quad [30]$$

$$\sum_{k=1}^M \lambda_k(\mathbf{x}_i) = 1 \quad \forall i, \quad [31]$$

$$0 < \sum_{i=1}^N \lambda_k(\mathbf{x}_i) < N \quad \forall k, \quad [32]$$

où $d_k(\mathbf{x}_i)^2 = \|\mathbf{x}_i - \boldsymbol{\mu}_k\|^2$ représente la distance euclidienne entre le vecteur d'entrée \mathbf{x}_i et le prototype $\boldsymbol{\mu}_k$ (ou noyau) de la classe α_k , m est un paramètre appelé *fuzzyfier* ($m \geq 1$). L'ensemble des vecteurs d'apprentissage est constitué de N vecteurs $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ susceptibles d'appartenir à M classes $\{\alpha_1, \alpha_2, \dots, \alpha_M\}$.

La solution qui minimise J_m ([29]) est donnée par les deux conditions suivantes :

$$\boldsymbol{\mu}_k = \frac{\sum_{i=1}^N \lambda_k(\mathbf{x}_i)^m \mathbf{x}_i}{\sum_{i=1}^N \lambda_k(\mathbf{x}_i)^m} \quad \forall k, \quad [33]$$

$$\lambda_k(\mathbf{x}_i) = \frac{1}{\sum_{j=1}^M (d_k(\mathbf{x}_i) / d_j(\mathbf{x}_i))^{2/(m-1)}} \quad [34]$$

Les prototypes ainsi que les fonctions d'appartenance sont calculés d'une manière itérative :

- Initialisation de la matrice de partition floue U^0 , $t = 0$;
- Faire
 - $t \leftarrow t + 1$
 - Calcul de la matrice des prototypes V^t avec l'équation [33]
 - Mise à jour de la matrice de partition floue U^t avec l'équation [34]
- Jusqu'à $\|U^t - U^{t-1}\| \leq \varepsilon$

Après la convergence de l'algorithme, pour chaque vecteur d'entrée \mathbf{x} , on calcule la matrice de partition floue $U = [\lambda_k(\mathbf{x})]_{(k=1,M)}$ avec l'équation [34].

Décision à partir des degrés d'appartenance (défuzzification)

Ayant calculé la matrice de partition floue $U = [\lambda_k(\mathbf{x})]_{(k=1,M)}$ qui représente donc les degrés d'appartenance du vecteur \mathbf{x} aux différentes classes, il reste à en déduire le choix d'une action $\gamma(\mathbf{x})$. Une étude comparative entre plusieurs règles de décision a été réalisée par (Masson *et al.*, 1996). Le cas le plus simple serait d'avoir chaque action $\gamma_k(\mathbf{x})$ qui représente l'affectation du vecteur \mathbf{x} à la classe α_k . Dans ce cas, on pourrait appliquer le principe du *maximum d'appartenance* (Pal, 77), qui consiste à choisir la classe ayant le plus haut degré d'appartenance :

$$\gamma(\mathbf{x}) = \gamma_k(\mathbf{x}) \quad si \quad \lambda_k(\mathbf{x}) = \max_{j=1,M} \lambda_j(\mathbf{x}) \quad [35]$$

Afin de prendre en compte les notions de rejet en distance et d'ambiguïté présentées précédemment, il est possible d'utiliser un seuil θ_k pour chaque classe. Ce seuil est soit défini a priori, soit déterminé à partir de l'ensemble d'apprentissage :

$$\theta_k = \min_{\mathbf{x}_i \in \alpha_k} \lambda_k(\mathbf{x}_i) \quad [36]$$

Si l'on considère donc $A = \{\gamma_0, \gamma_d, \gamma_1, \dots, \gamma_M\}$ l'ensemble des actions possibles incluant l'affectation à un rejet d'ambiguïté γ_0 et l'action de rejet en distance γ_d , pour chaque vecteur d'entrée \mathbf{x} , on obtient un ensemble $\mathfrak{R}(\mathbf{x})$ des résultats des actions obtenues :

$$\mathfrak{R}(\mathbf{x}) = \{k \in \{1, \dots, M\} \mid \lambda_k(\mathbf{x}) > \theta_k\} \quad [37]$$

Le résultat est exprimé de la manière suivante :

$$\gamma(\mathbf{x}) = \begin{cases} \gamma_k & si \quad \mathfrak{R}(\mathbf{x}) = \{k\} \\ \gamma_d & si \quad \mathfrak{R}(\mathbf{x}) = \emptyset \\ \gamma_0 & si \quad |\mathfrak{R}(\mathbf{x})| > 1 \end{cases} \quad [38]$$

L'inconvénient de la règle précédente est le fait que les deux options de rejet sont contrôlées par le même paramètre θ_k . La règle dite *du rapport d'appartenance*, proposée par Frélicot (Frélicot, 1992) se base sur le rapport :

$$v = \frac{\lambda_m(\mathbf{x})}{\lambda_p(\mathbf{x})} \quad [39]$$

avec

$$\begin{aligned} \lambda_p(\mathbf{x}) &= \max_{k \in \mathcal{R}(\mathbf{x})} \lambda_k(\mathbf{x}) \\ \lambda_m(\mathbf{x}) &= \max_{k \in \mathcal{R}(\mathbf{x}) \setminus \{p\}} \lambda_k(\mathbf{x}) \end{aligned} \quad [40]$$

On a évidemment $0 \leq v \leq 1$, et son interprétation est la suivante :

- Si v est proche de zéro, alors le degré d'appartenance λ_p est très grand par rapport aux autres degrés d'appartenance. L'action $\gamma_p(\mathbf{x})$ sera la plus favorable,
- Si v est proche de un, alors au moins deux actions différentes ($\gamma_p(\mathbf{x})$ et $\gamma_m(\mathbf{x})$) ont des degrés d'appartenance presque identiques ($\lambda_p(\mathbf{x}) \approx \lambda_m(\mathbf{x})$). Cette situation correspond à un rejet d'ambiguïté.

Pour prendre la décision finale, ce rapport d'appartenance v est alors comparé à un seuil S . Si $v > S$, alors \mathbf{x} est rejeté en ambiguïté, sinon, l'action $\gamma_p(\mathbf{x})$ est sélectionnée.

c) Reconnaissance des formes par réseaux de neurones

Les réseaux de neurones sont des outils de l'intelligence artificielle, capables d'effectuer des opérations de classification. Leur fonctionnement est basé sur les principes de fonctionnement des neurones biologiques. Leur principal avantage par rapport aux autres outils est leur capacité d'apprentissage et de généralisation de leurs connaissances à des entrées inconnues. Les réseaux de neurones peuvent être également implémentés en circuits électroniques, offrant ainsi la possibilité d'un traitement temps réel. Le processus d'apprentissage est donc une phase très importante pour la réussite d'une telle opération. Plusieurs types de réseaux de neurones et plusieurs algorithmes d'apprentissage existent en littérature.

Une des qualités de ce type d'outil est son adéquation pour la mise au point de systèmes de surveillance modernes, capables de s'adapter à un système complexe avec reconfigurations multiples. Nous leur dédions l'ensemble du chapitre suivant. Nous présentons ainsi les deux architectures les plus utilisées en surveillance industrielle, à savoir le Perceptron Multi Couches (*PMC*) et les Réseaux à Fonctions de base Radiales (*RFR*). La Figure 7 montre l'architecture générale d'une application de surveillance par reconnaissance des formes avec réseaux de neurones. L'expert humain joue un rôle très important dans ce type d'application. Toute la phase d'apprentissage supervisé du réseau de neurones dépend de son analyse des modes de fonctionnement du système. Chaque mode est caractérisé par un ensemble de données recueillies sur le système. A chaque mode, on associe une expertise faite par l'expert.

Cette association (ensemble de données - modes de fonctionnement) sera apprise par le réseau de neurones. Après cette phase d'apprentissage, le réseau de neurones associera les classes représentant les modes de fonctionnement aux formes d'entrée caractérisées par les données du système.

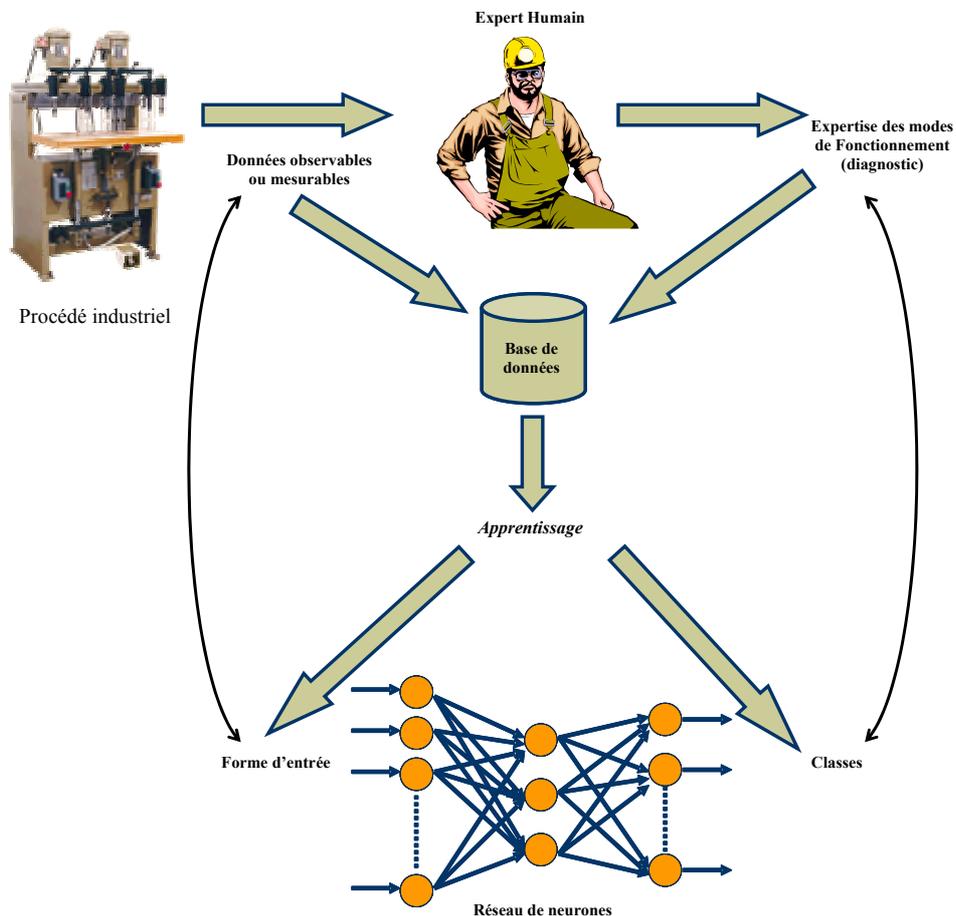


Figure 7. Reconnaissance des formes par réseau de neurones.

I.4. Conclusion

L'objectif de ce chapitre a été de donner un aperçu des techniques habituellement utilisées pour résoudre des problématiques de surveillance. La première partie de ce chapitre a été dédiée à la présentation des mots clés les plus importants en surveillance. La surveillance d'un équipement industriel se fait au travers de deux fonctions de base : la *détection* et le *diagnostic* des défaillances. La détection des défaillances a pour rôle de signaler toute situation autre qu'une situation nominale. En d'autres termes, tout ce qui n'est pas normal doit

être classé comme anormal. C'est alors que la fonction diagnostic doit *localiser* l'organe défaillant et *identifier* les causes ayant provoqué ces situations de défaillance. Cette opération est souvent menée par un expert et dans certains cas exige des connaissances poussées sur l'équipement.

Le classement des techniques de surveillance est fonction de l'existence ou non d'un modèle formel de l'équipement à surveiller. Nous avons donc présenté, d'une part, les méthodes qui ne se basent pas sur l'existence de ce modèle, c'est-à-dire les outils statistiques et les techniques de reconnaissance des formes et, d'autre part, celles qui l'utilisent, à savoir les méthodes d'estimation d'état et d'estimation paramétrique (techniques de *l'Automatique*). Ces dernières techniques ont pour principe de comparer l'état théorique du système fourni par le modèle avec son état courant donné par les observations. Souvent, pour des équipements complexes, ces modèles sont difficiles à mettre en œuvre et, quand ces modèles existent, leur réponse est souvent entachée d'incertitudes de modélisation. Ces incertitudes sont dues au fait qu'on ne peut pas cerner tous les paramètres physiques d'un équipement. Les incertitudes de modélisation ainsi que les bruits de mesures sont pris en compte d'une manière explicite par le modèle. Généralement, les paramètres inconnus, appelés perturbations, sont pris en compte dans le modèle d'une manière additive, les erreurs de modélisation d'une manière multiplicative et les bruits de mesure par la conception de résidus robustes généralement obtenus grâce à des techniques de découplage et des techniques de filtrage du signal. Les techniques de l'Intelligence Artificielle ne se basent pas sur le modèle de l'équipement et prennent en compte les perturbations ainsi que les bruits de mesure, d'une manière implicite.

La surveillance à base de modèle est souvent opérée hors ligne, empêchant ainsi des traitements temps réel. En revanche, l'Intelligence Artificielle offre des outils totalement découplés de la structure du système, permettant un suivi temps réel de l'évolution de celui-ci. Le raisonnement en ligne fait que l'approche de l'Intelligence Artificielle est plus robuste à des changements de modes opératoires comme pour les systèmes ayant plusieurs configurations. Elle est donc évolutive.

L'approche de surveillance par reconnaissance des formes, munie des notions de rejet (d'ambiguïté et de distance) et de la possibilité d'adaptation s'est donc montrée performante pour résoudre des problèmes de surveillance. En effet, la connaissance existante sur les différents modes de fonctionnement d'un système est toujours incomplète.

Le rejet d'ambiguïté permet de ne pas prendre une décision trop hâtive par rapport aux modes de fonctionnement identifiés. L'expert devra alors décider parmi deux ou plusieurs solutions proposées.

Le rejet de distance permet de tenir compte du caractère incomplet de la connaissance et l'adaptation périodiquement réalisée met en évidence de nouvelles classes. Il convient aussi d'interpréter physiquement ces classes en termes de causes des modes de fonctionnement. Cela ne peut être réalisé que par un expert.

Les systèmes de surveillance par outils de l'Intelligence Artificielle peuvent donc représenter d'excellents systèmes d'aide à la décision pour l'expert humain. Dans ce sens, le chapitre suivant sera consacré à la présentation des notions de base des réseaux de neurones, et de leur application en surveillance d'équipements de production.