



HAL
open science

Surveillance de systèmes continus à l'aide de méthodes n'utilisant pas de modèles formels : Application aux systèmes médicaux

Sylvie Charbonnier

► **To cite this version:**

Sylvie Charbonnier. Surveillance de systèmes continus à l'aide de méthodes n'utilisant pas de modèles formels : Application aux systèmes médicaux. Automatique / Robotique. Institut National Polytechnique de Grenoble - INPG, 2006. tel-00170078

HAL Id: tel-00170078

<https://theses.hal.science/tel-00170078>

Submitted on 6 Sep 2007

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Institut National Polytechnique de Grenoble

Diplôme d'habilitation à diriger des recherches

présenté par

Sylvie Charbonnier

Maître de conférences à Polytech'Grenoble, U.J.F.

**Surveillance de systèmes continus à l'aide de méthodes
n'utilisant pas de modèles formels : Application aux
systèmes médicaux**

Dans le cadre de l'Ecole doctorale
Electronique, Electrotechnique, Automatique, Traitement du signal

Soutenance le 13 Novembre 2006 devant un jury composé de :

M ^{me} Sylviane Gentil	Président, professeur à l'Institut National Polytechnique de Grenoble
M. Jean Philippe Cassar	Rapporteur, professeur à l'Université de Lille
M. Guy Dumont	Rapporteur, professeur à l'Université de Colombie Britannique, Vancouver, Canada
M. Jim Hunter	Rapporteur, professeur à l'Université d'Aberdeen, Ecosse
M. Pierre Baconnier	Examineur, professeur à l'Université Joseph Fourier, Grenoble
M. Christian Jutten	Examineur, professeur à l'Université Joseph Fourier, Grenoble

Remerciements

Je tiens tout d'abord à remercier tous les membres du jury pour avoir accepté d'examiner ce travail, et pour l'aide qu'ils m'ont apportée pour aboutir à ce document qui résume plusieurs années de recherche :

Mme Sylviane Gentil, pour les précieux conseils qu'elle m'a donnés lors de la préparation de cette HDR, et pour le soutien qu'elle m'a apporté lors de l'encadrement de la thèse de Lyes Badji

M Pierre Baconnier, pour m'avoir écouté quand au début de ma carrière je souhaitais m'orienter vers les applications médicales et pour m'avoir mis en relation avec les médecins avec qui il travaillait. Merci aussi pour son soutien apporté lors de l'encadrement de la thèse de Guillaume Becq, tout particulièrement dans cette phase difficile que fut la rédaction. Enfin, je le remercie de m'avoir permis de participer à cette merveilleuse aventure qu'était la création du département TIS de Polytech'Grenoble.

M. Christian Jutten, pour l'honneur et le plaisir qu'il m'a faits d'être présent ce jour-là.

Je remercie tout particulièrement les rapporteurs de ce travail, M Jean-Philippe Cassar, M. Jim Hunter et M. Guy Dumont pour les remarques pertinentes et constructives qu'ils ont faites sur ce document. Je les remercie aussi pour leur présence le jour de la soutenance, bien que le voyage depuis leur lieu de résidence jusqu'à Grenoble était pour certains bien long.

Merci à tous les collègues du groupe OSSCAR_apprentissage avec lesquels les échanges scientifiques ont toujours été très enrichissants, et plus particulièrement à Marie-Christine Chambrin, à Jean-Pierre Perdrix et à Pierre-Yves Carry pour leur dynamisme et leur disponibilité.

Je remercie tous mes collègues de l'équipe technique du LAG, pour leur soutien dans nos activités de recherche quotidienne, et plus particulièrement Pascal Bellemain pour son travail sur le développement de l'interface présentant les travaux sur l'analyse de tendances, Olivier Chabert pour son soutien en informatique, mais aussi Marie-Rose, Marie-Thé, Marielle, Virginie, Patricia, Daniel, ... pour leur travail qui nous facilite grandement le quotidien. Merci aussi aux membres de l'axe Sûreté et Diagnostic pour les échanges intellectuels fructueux et, plus largement, à tous les membres du LAG.

Je tiens à remercier tous mes collègues de Polytech'Grenoble et plus particulièrement ceux du département TIS qui forment une équipe pédagogique dynamique, ouverte, disponible pour chaque étudiant, avec qui il est très agréable de travailler.

Merci enfin à ma famille, mon mari Alain, mes enfants Avril et Yann, pour leur soutien moral et leur joie de vivre, à mes parents et à mes amis.

Résumé :

Ce document présente nos travaux sur la surveillance de systèmes dynamiques à l'aide de méthodes n'utilisant pas de modèles formels, dont un des domaines d'application est la surveillance de patients. L'information disponible sur ces systèmes est un ensemble de mesures provenant de différents capteurs et une connaissance experte non modélisable à l'aide d'équations différentielles. Les méthodes consistent à extraire des caractéristiques pertinentes des signaux puis à les fusionner à l'aide d'un modèle de décision copiant l'expertise humaine. Deux voies de recherche ont été plus particulièrement abordées : l'analyse de tendance qui a comme avantage de mettre en évidence les transitoires dans un signal afin de les utiliser dans le modèle de décision et la reconnaissance de formes qui permet d'exploiter les liens statiques entre variables grâce à une base de données conséquente. Les applications concernent la surveillance de patients hospitalisés en unités de soins intensifs ainsi que la reconnaissance d'états physiologiques (phases de sommeil, chocs hémorragiques).

Abstract :

In this document, our studies on monitoring of dynamic systems without using formal models are presented. The applications concern medical systems. Information available is a set of measurements recorded on the system by sensors and some expert knowledge, which cannot be modelled by differential equations. Relevant features are extracted from the signals and merge using decision models that copy the expert reasoning. Two paths were explored :

- trend analysis which enables the relevant transients of a signal to be enhanced, so as to use them in a decision making process
- pattern recognition where the static links between variables are exploited. Knowledge about diagnosis processes can be extracted using data mining techniques when a large data base is available.

Applications are about patient monitoring in Intensive Care Units and physiological states diagnosis (sleep/wake stages, hemorrhagic choc).

Table des matières

1. INTRODUCTION	6
1.1. MEDECINE ET AUTOMATIQUE	6
1.2. SURVEILLANCE DE SYSTEMES	9
1.2.1. EXTRACTION D'INFORMATIONS	10
1.2.2. FUSION DES INFORMATIONS	12
1.3. SURVEILLANCE ET DIAGNOSTIC DES SYSTEMES MEDICAUX	13
2. SURVEILLANCE DE SYSTEMES PAR ANALYSE DE TENDANCE : APPLICATION A LA SURVEILLANCE DE PATIENTS HOSPITALISES EN SERVICE DE REANIMATION	16
2.1. INTRODUCTION	16
2.2. BIBLIOGRAPHIE	17
2.2.1. DEFINITION DE LA TENDANCE	17
2.2.2. METHODES D'EXTRACTION DE LA TENDANCE	17
2.2.3. UTILISATION DE LA TENDANCE POUR LE DIAGNOSTIC ET LA SUPERVISION	22
2.3. METHODE PROPOSEE POUR L'EXTRACTION DE TENDANCE EN LIGNE	23
2.3.1. VERSION INITIALE	23
2.3.2. MODIFICATIONS APORTEES	34
2.3.3. CONCLUSION SUR LA METHODE D'EXTRACTION DE TENDANCE	41
2.4. AIDE A LA SURVEILLANCE DE PATIENTS HOSPITALISES EN REANIMATION PAR ANALYSE DE TENDANCES	42
2.4.1. DETECTION AUTOMATIQUE D'EVENEMENTS A PARTIR D'UNE ANALYSE MULTIVARIABLE DES PARAMETRES PHYSIOLOGIQUES	42
2.4.2. CALCUL D'INDICE DE CHANGEMENT TEMPOREL PERMETTANT DE METTRE EN EVIDENCE LES PERIODES STABLES ET INSTABLES DU PATIENT	47
2.4.3. FILTRAGE D'ALARME DE SpO_2 PAR ANALYSE CONJOINTE DES AUTRES VARIABLES PHYSIOLOGIQUES.	50
2.4.4. FONCTIONNEMENT EN LIGNE DU SYSTEME D'AIDE A LA SURVEILLANCE DE PATIENTS	56
2.5. CONCLUSION ET PERSPECTIVES	57
2.5.1. RECONNAISSANCE D'EVENEMENTS PAR « PATTERN MATCHING » A PARTIR DE MODELES FLOUS	58
2.5.2. CREATION D'UN ALPHABET DE LA DYNAMIQUE DU SIGNAL	58
2.5.3. PROPOSITION D'UNE MESURE DE DISTANCE SYMBOLIQUE PERMETTANT DE RELIER UNE FORME TEMPORELLE MULTIVARIABLE DEFINIE PAR DES LETTRES AVEC UN MODELE DE REFERENCE	59
2.5.4. MISE EN ŒUVRE DE TECHNIQUES DE FOUILLE DE DONNEES AFIN DE CONSTRUIRE AUTOMATIQUEMENT LES SIGNATURES DE REFERENCE D'ANOMALIES	59
3. DIAGNOSTIC PAR RECONNAISSANCE DE FORMES. APPLICATION AU DIAGNOSTIC DE CHOC HEMORRAGIQUE ET A L'ANALYSE DU SOMMEIL HUMAIN	60
3.1. PRINCIPE DU DIAGNOSTIC PAR RECONNAISSANCE DE FORMES	60
3.1.1. CONSTRUCTION DE LA BASE D'APPRENTISSAGE	61
3.1.2. EXTRACTION DES CARACTERISTIQUES	61
3.1.3. SELECTION DE CARACTERISTIQUES PERTINENTES	62
3.1.4. APPRENTISSAGE DE LA FONCTION DE DECISION	62
3.1.5. VALIDATION DU SYSTEME DE DIAGNOSTIC	64
3.2. DIAGNOSTIC DE CHOC HEMORRAGIQUE SUR BLESSE TRAUMATISE	65
3.2.1. OBJECTIFS	65
3.2.2. MATERIEL	65
3.2.3. METHODES	67
3.2.4. RESULTATS	69

3.2.5.	VISUALISATION DE L'EVOLUTION DU CHOC HEMORRAGIQUE	71
3.2.6.	CONCLUSION ET PERSPECTIVES	73
3.3.	ANALYSE DU SOMMEIL HUMAIN PAR RECONNAISSANCE DE FORMES	74
3.3.1.	MATERIEL	74
3.3.2.	METHODES	77
3.3.3.	RESULTATS	78
3.3.4.	CONCLUSIONS ET PERSPECTIVES	82
4.	CONCLUSIONS ET PERSPECTIVES	85
<hr/>		
	REFERENCES BIBLIOGRAPHIQUES	93
<hr/>		

1.Introduction

1.1. Médecine et Automatique

La science du vivant est une discipline qui m'a toujours intéressée. Ainsi, après un diplôme d'ingénieur en génie électrique, j'ai cherché un moyen de concilier mon goût pour cette discipline avec les compétences acquises au cours de mes études. Cela a conduit mes pas au LAG, plus particulièrement dans l'équipe bioprocédés, dirigée par Arlette Cheruy dont la thématique de recherche était la commande de procédés biologiques. Après cinq années passées à la modélisation de la croissance de bactéries, à leur observation et leur commande (une année de DEA, 3 années de thèse, une année d'ATER), il m'a semblé difficile d'apporter des idées nouvelles à une thématique déjà activement explorée par plusieurs chercheurs du LAG. Après mon recrutement sur un poste de maître de conférence, j'ai souhaité développer un nouvel axe de recherche, alors inexistant au LAG, qui consiste à appliquer les techniques de l'automatique à un système vivant de plus grande taille mais non moins complexe, l'humain. Je me suis ainsi attachée à créer un axe de recherche « automatique et médecine ». C'est un parcours qui a été long et difficile car démarrer une nouvelle thématique signifie créer des liens alors inexistantes avec de nouvelles personnes, notamment les médecins. Il est en effet impensable d'envisager travailler dans le domaine de la médecine, sans une étroite collaboration avec les principaux utilisateurs des outils que l'on va être amené à développer. Cette collaboration s'est avérée indispensable pour mûrir ma réflexion sur ce que l'automatique peut apporter à la médecine.

L'association des termes automatique et médecine évoque naturellement des systèmes élaborés grâce à l'automatique qui vont aider le médecin dans sa prise en charge du patient. Or, la médecine étant une discipline très vaste, comportant de nombreuses spécialités, ces systèmes sont, eux aussi, extrêmement divers. Ce peut être un équipement complexe comme un scanner, un robot d'aide à la chirurgie, un respirateur artificiel ou encore des logiciels d'aide au diagnostic de pathologie, ou d'aide à la prescription de médicaments...

Cependant, du point de vue de l'automaticien, qui s'intéresse à des systèmes bouclés et dont l'objectif est de proposer une action en réponse à un ensemble d'informations recueillies sur un système, deux grandes classes d'applications médicales émergent naturellement. Ces deux classes dépendent de la place du patient dans la boucle mesures/actions. Les problématiques de recherche propres à chacune des classes sont très différentes.

La première classe est constituée des systèmes où le patient se situe à l'extérieur de la boucle mesures/actions. Les informations qui servent à l'élaboration d'une action ne proviennent pas directement du patient lui-même, mais de l'instrument. Dans cette classe, nous pouvons citer, à titre d'exemples, certains appareils de diagnostic comme le scanner, l'IRM ou de traitement comme un appareil de radio thérapie. L'exigence de qualité des soins que l'on délivre au patient rend indispensable l'utilisation de boucles de commande au sein de l'appareil. On trouvera des boucles de commande classiques comme des asservissements de position, de vitesse, ... Bien que les problèmes de commande posés puissent être complexes, le fait que le système soit utilisé à des fins médicales ne change pas ou peu de choses au problème scientifique posé.

La deuxième classe, à l'opposé, est constituée des systèmes où le patient se trouve au sein de la boucle mesures/actions. Les informations recueillies sur le patient servent à proposer ou à modifier un traitement médical à appliquer sur le patient. Depuis la nuit des temps, la tâche de

commande est dans ce cas dévolue au médecin. La question se pose de l'aide que peut apporter l'automaticien au médecin pour ce type de système.

Une réponse immédiate serait de proposer de remplacer le médecin par un système de commande automatique chargé de modifier et d'appliquer seul une thérapie (délivrer une dose de médicament par exemple) au patient. Ceci peut sembler intéressant pour certaines maladies chroniques, où le corps humain a perdu sa capacité à réguler la concentration d'une substance biologique, comme le diabète par exemple. Un autre cas potentiellement intéressant est celui où un médicament doit être fréquemment délivré, par exemple pour maintenir un patient dans un état particulier au cours d'une anesthésie. Actuellement, le médecin anesthésiste doit réinjecter régulièrement des doses de médicaments pour maintenir un niveau suffisant d'anesthésie, ou pour abaisser la tension artérielle au cours d'une opération de chirurgie cardiaque. Il serait envisageable de le décharger de cette tâche par le biais d'un régulateur automatique, afin qu'il puisse se concentrer sur d'autres tâches, comme la détection de complications.

Or, bien qu'un grand nombre d'articles aient été publiés sur ces différents sujets dans des revues scientifiques - IEEE Transactions on Biomedical Engineering en particulier - ([PAJ 90], [BEH 91], [MAR 92], [DEL 94], [ISA 93], [FUR 95], [MAI 97], [CHI 97], [FRE 00], [JIA 99], [KIA 93], [TRA 98], [CHE 05], ...) , très peu de systèmes automatiques bouclés, c'est-à-dire capables d'agir directement sur le patient en fonction de mesures effectuées sur celui-ci, ont vu le jour. Ceci est dû à des limitations technologiques : manque de fiabilité des mesures, manque de capteurs portables, capables de mesurer une variable physiologique in situ (mesure de glycémie dans le cas du diabète). Mais, plus encore, ceci est dû à la réticence des médecins à laisser une machine « fermer la boucle », pour des raisons de sécurité que l'on peut aisément comprendre. Le système « patient » est très difficilement modélisable. Les liens entre variables sont complexes et non nécessairement reproductibles. Un modèle élaboré à l'aide de données provenant d'un patient ne sera pas nécessairement applicable à un autre patient, voire sur le même patient, dans une situation différente. Des informations très variées sont nécessaires au médecin pour prendre une décision, qui ne sont pas toujours accessibles à une machine et donc intégrables dans un modèle. Enfin, la thérapie proposée à un patient dépend fortement de ses antécédents médicaux et du contexte de soins. Ainsi, pour de mêmes symptômes observés sur deux patients, un médecin pourra proposer des thérapies différentes.

Toutes ces raisons font que les rares systèmes commercialisés où la machine prend seule la décision d'agir sur le patient correspondent à des applications où l'action effectuée par la machine est très simple et n'entraîne pas de danger pour le patient. Citons, par exemple, certains systèmes d'assistance respiratoire (respirateur se déclenchant après détection d'un effort inspiratoire Sté TAEMA, système de traitement d'apnée du sommeil délivrant une pression positive après détection d'une apnée chez le patient, Sté BREAS) ou de suppléance cardiaque (pacemaker asservi à l'activité, Sté ELA médical).

L'apport de l'automatique concernant les applications médicales où le patient est à l'intérieur de la boucle mesures/actions ne porte donc pas sur l'élaboration d'un contrôleur susceptible de se substituer au médecin, mais consiste plutôt à développer des méthodes permettant d'aider le médecin dans sa prise de décision, que celle-ci consiste à poser un diagnostic ou à proposer une thérapie. **Le rôle de l'automatique est d'aider le médecin à fermer la boucle.** Des actions peuvent être proposées en réponse à une analyse des informations recueillies sur un patient, mais le choix est toujours laissé au médecin de les appliquer ou non.

L'exemple de l'anesthésie illustre bien cette proposition. Récemment, de nets progrès ont été réalisés dans ce domaine avec le développement de modèles pharmacocinétiques et pharmacodynamiques de produits anesthésiants et d'indicateurs du niveau d'anesthésie. Des logiciels utilisant ces modèles pharmacologiques permettent au médecin d'adapter au mieux la dose de produit anesthésiant à administrer au patient, en fonction de son âge, son poids et permettent d'atteindre un degré d'anesthésie adéquat en évitant l'administration de doses excessives. Un indicateur du niveau d'anesthésie (l'indice BIS), calculé en ligne à partir de l'EEG du patient, permet au médecin de mieux suivre le niveau d'anesthésie en cours d'opération. Cet indicateur est une information supplémentaire, venant s'ajouter aux signes habituellement utilisés par le médecin anesthésiste. Il peut aider le médecin dans sa décision de réinjecter du médicament et permet ainsi d'éviter les périodes d'éveil en cours d'opération. Des recherches sont en cours pour proposer d'autres indicateurs de niveau d'anesthésie ([ZIK 06]). Cependant, malgré ces avancées technologiques, le médecin reste au coeur de la boucle de décision.

Ma réflexion sur l'apport de l'automatique à la médecine s'est construite au fil des projets sur lesquels j'ai travaillé. Ainsi, le tout premier projet auquel j'ai participé était un projet de recherche financé par le CNRS dans le cadre du programme Microsystèmes. Ce projet, intitulé "Micromed", débuté en 1994 et reconduit en 98, regroupait, entre autres, les laboratoires TimC, le LAAS et le CHU de Grenoble. Ce projet avait comme objectif la réalisation d'un système de régulation de la tension artérielle implanté à l'intérieur du corps humain, pouvant fonctionner pendant trois ans. Le but de ce système était de traiter des patients atteints d'hypertension instable grave, en leur délivrant régulièrement une dose de médicament correspondant à leurs besoins. En tant que jeune chercheuse débutant dans le domaine, ce projet me semblait parfaitement convenir à ma nouvelle thématique de recherche.

Ce projet n'a pas abouti. D'une part, aucun démonstrateur sur animal n'a pu être réalisé, pour des raisons technologiques : difficulté à obtenir une mesure de la pression artérielle invasive et portable sans risque pour le patient, difficulté à implanter une micro pompe de médicament dans le patient. D'autre part, les simulations que nous avons réalisées à l'aide d'un modèle pharmacodynamique de l'effet du médicament hypotenseur choisi, conçues à partir de mesures provenant de plusieurs patients sous traitement, ont montré que la délivrance à intervalle régulier d'une dose de médicament déterminée en fonction de la valeur de la tension n'apportait pas de gain thérapeutique pour le patient par rapport à la prise journalière d'une dose à libération prolongée.

Cependant, au fil de mes discussions avec le médecin cardiologue participant à ce projet, dans l'objectif de déterminer quelles étaient les variables à mesurer chez un patient pour pouvoir correctement apprécier son niveau tensionnel, il est apparu qu'un outil logiciel lui facilitant le diagnostic d'hypertension lui serait très utile. L'hypertension est une maladie diagnostiquée à l'aide d'un holter tension artérielle, appareil qui enregistre chaque 15 minutes la tension artérielle en ambulatoire d'un patient sur une durée de 24 heures. La tension artérielle en ambulatoire est une grandeur hautement variable, qui fluctue de manière importante en fonction de l'activité du patient ou de son état d'émotivité au cours de la journée. Cette variabilité complexifie fortement le travail d'analyse des données enregistrées, notamment pour apprécier l'effet d'un médicament. Dans le but de faciliter le diagnostic d'hypertension, nous avons donc développé un modèle mathématique explicitant les fluctuations de la pression artérielle en fonction de mesures de l'activité du patient, estimées à l'aide d'accéléromètres, et de la fréquence cardiaque et proposé la création d'un nouveau holter tension, équipé d'un accéléromètre tri-axial ([CHA 99], [CHA 00]).

Par la suite, convaincue par l'aide que pouvait apporter l'automatique dans l'analyse des informations recueillies sur patients, j'ai axé mes recherches sur les thématiques de surveillance

et diagnostic qui constituent des thèmes de recherche en essor dans le domaine de l'automatique. Je me suis intéressée à l'aide à la prise en charge de patients dans des situations critiques. J'ai ainsi travaillé sur des problèmes d'aide à la surveillance de patients hospitalisés en Unités de Réanimation, à l'aide d'analyse de tendances des signaux. J'ai été amené à mettre en œuvre des techniques de diagnostic par reconnaissance de formes afin de développer un système de diagnostic automatique d'états de choc hémorragique à partir de mesures physiologiques non invasives, puis afin de développer un système d'analyse automatique de phases de sommeil humain. Ce sont ces recherches que je développerai dans la suite de ce mémoire.

1.2. Surveillance de systèmes

Suite à l'évolution technologique des procédés dans un grand nombre de domaines industriels et à l'augmentation du nombre des équipements, et plus particulièrement des capteurs, les opérateurs chargés de la surveillance des procédés doivent interpréter rapidement un flot de données important et sont ainsi soumis à une surcharge cognitive de plus en plus forte. Cette augmentation du flot de données a incité la communauté scientifique automatique à migrer vers le développement de nouveaux systèmes de surveillance ayant pour objectifs de :

- faciliter l'interprétation du flot de données provenant des différents capteurs d'un système
- détecter les anomalies survenant sur le système et alerter les opérateurs (fonction de détection)
- fournir une aide à la décision en proposant un diagnostic pour le problème rencontré (fonction de localisation du défaut et d'identification)

La fonction de détection consiste à reconnaître et indiquer en temps réel (le plus tôt possible) les anomalies de comportement du système. (Dans la terminologie de la surveillance, on parle en général de défaut ou de défaillance. J'utilise plutôt le terme anomalie qui, à l'inverse des deux précédents, peut s'appliquer aux systèmes médicaux). Le système de surveillance détecte que le système ne fonctionne plus correctement et génère une alarme pour alerter l'opérateur, sans préciser son origine. La fonction de diagnostic va plus loin dans l'analyse de la situation en précisant à l'opérateur l'origine de l'anomalie. Les connaissances nécessaires à l'élaboration d'une fonction de détection ou de diagnostic ne sont donc pas les mêmes. La réalisation d'une fonction de détection ne nécessite que la connaissance du bon fonctionnement du système. Toute différence de comportement observée sur le système par rapport au comportement en bon fonctionnement génère une alarme. La réalisation d'une fonction de diagnostic nécessite elle la connaissance du comportement du système en mauvais fonctionnement, et notamment la connaissance de la signature de chaque anomalie à diagnostiquer.

Les performances d'un système de surveillance se mesurent par :

- sa capacité à reconnaître la présence d'une anomalie, estimée par le taux de non détection :
- sa capacité à reconnaître l'absence d'une anomalie, estimée par le taux de fausses alarmes
- sa rapidité de détection, estimée par le retard à la détection

Les méthodologies de surveillance peuvent être divisées en deux groupes. Les méthodes dites avec modèle utilisent un modèle formel du système (on appelle ici modèle formel un modèle mathématique décrivant la dynamique du système à l'aide d'équations différentielles) afin de générer des symptômes : écarts entre la prédiction par le modèle et les mesures effectuées sur le procédé (nommés résidus), valeurs des paramètres du modèle identifiés en ligne ... Les autres méthodes, dites sans modèle, n'utilisent que les observations du système.

D'une manière générale, les méthodes de surveillance sans modèle formel peuvent se schématiser de la manière suivante :

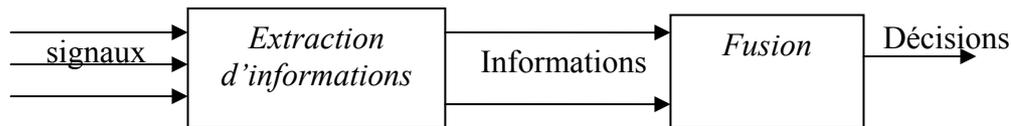


Figure 1 : Techniques de surveillance de systèmes sans modèles formels

Les signaux enregistrés sur le système à l'aide de capteurs sont dans un premier temps traités pour extraire en ligne les informations pertinentes pour la détection d'une anomalie et/ou pour son diagnostic. Celles-ci sont ensuite fusionnées à l'aide de modèles pour fournir une décision (détection, diagnostic).

Les différences entre les méthodes de surveillance sans modèles formels proviennent de la nature des informations extraites (et donc des techniques d'extraction) et de la manière dont elles sont fusionnées.

1.2.1. Extraction d'informations

Les informations extraites des signaux peuvent être :

- des valeurs binaires caractérisant la présence ou l'absence d'un évènement particulier dans le signal
- des valeurs numériques (éventuellement converties en valeurs symboliques) caractérisant le signal (appelées caractéristiques)
- des informations permettant la description du signal sous un autre formalisme, plus propice à la reconnaissance d'anomalies

1.2.1.1. Détection d'évènements

Un évènement est l'apparition d'un changement sur le signal, transitoire ou non. Ce peut être la modification d'une caractéristique du signal (moyenne, variance, modification d'énergie dans une bande fréquentielle, ...) ou encore l'apparition d'une forme temporelle particulière, une dérive ...

Certaines techniques de diagnostic sans modèle consistent dans un premier temps à détecter la présence (ou l'absence) d'un évènement dans le signal, caractéristique d'une anomalie. L'information extraite du signal est donc une information binaire, ou graduée entre 0 et 1 si l'on utilise des techniques de détection intégrant un indice de confiance dans la détection. Parmi ces méthodes, se trouvent les méthodes de détection de ruptures dans un signal temporel, fondées sur la théorie de la détection ([BAS 93], [KAY 98]). Avent et al ([AVE 90]) présentent une revue des différentes techniques permettant de détecter une rupture de type échelon ou une dérive dans un signal physiologique. Imhof et al [IMH 98]) proposent une méthode de détection des artéfacts, dérives et changements de niveau sur des signaux physiologiques à partir de modèles AR.

La détection d'un changement transitoire sur le signal peut aussi se faire dans le plan temps-fréquence. Ainsi, Martin ([MAR 04]), propose un détecteur permettant de détecter des non stationnarités dans un signal fondé sur un test de Neyman Person après transformation dans le plan temps fréquence. ([BLO 06], [KAH 06], [RAJ 05], [LES 03]) présentent des applications sur la détection de singularités dans un signal à partir de la transformée en ondelettes.

La détection de formes caractéristiques dans un signal peut aussi être réalisée à l'aide de gabarits dont on vérifie en ligne l'adéquation avec le signal. Contrairement aux méthodes citées précédemment qui opèrent sur un signal unique, les gabarits peuvent être définis sur plusieurs variables. Haimovitz et al ([HAI 95], [HAI 96]) utilisent des gabarits de forme quadratique pour détecter des tendances sur les courbes de taille et de poids chez l'enfant et diagnostiquer ainsi des problèmes de croissance. Miksh et al ([MIK 96], [MIK 97]) utilisent des gabarits formés d'enveloppes exponentielles pour détecter des évolutions anormales sur des signaux physiologiques enregistrés en service de néo natalité. Steimann ([STE 96]) puis Lowe et al (LOW 99), [LOW 01]) utilisent des gabarits flous permettant de détecter des variations temporelles caractéristiques de l'apparition de certaines complications chez le patient sous anesthésie. Lesecq et al. ([LES 05]) proposent de détecter certains défauts affectant un laminoir à l'aide d'un gabarit défini dans le plan fréquentiel. L'adéquation du signal avec le gabarit est mesuré par un indicateur flou, après transformation du signal dans le plan fréquentiel par transformée de Fourier.

La détection de motifs temporels caractéristiques peut être réalisée par pattern matching à l'aide d'une mesure de distance temporelle de type Dynamic Time Warping ([KEO 97], [KAS 97], [VUL 98], [SIN 01]).

1.2.1.2. Extraction de caractéristiques

Une caractéristique est une information numérique extraite à l'aide de techniques de traitement du signal. Une caractéristique peut décrire le signal dans le domaine temporel ou fréquentiel. Elle est en général extraite en ligne à l'aide d'une fenêtre glissante, avec ou sans recouvrement. La taille de la fenêtre doit être choisie avec soin : suffisamment longue pour que la fenêtre contienne un nombre d'échantillons permettant une bonne estimation de la caractéristique, suffisamment courte pour que l'hypothèse de stationnarité du signal soit vérifiée (la caractéristique reste constante sur toute la durée de la fenêtre) et que la détection soit rapide. Il n'est bien sûr pas possible de fournir ici une liste exhaustive de caractéristiques. Leur choix dépend du signal mesuré et des anomalies que l'on cherche à diagnostiquer sur le système.

1.2.1.3. Changement de représentation

Le signal temporel enregistré peut être décrit sous un autre formalisme, permettant une meilleure description des anomalies à reconnaître, ou réalisant une compression des données facilitant l'utilisation des modèles de décision de la deuxième étape. Le signal transformé est utilisé comme entrées de la fonction de décision ou pour extraire certaines caractéristiques qui serviront d'entrées à la fonction de décision. La transformation du signal peut être numérique/numérique ou numérique/symbolique.

Parmi les transformations numériques/numériques, citons la modélisation des signaux à l'aide de modèles auto régressifs. Le signal est représenté par les paramètres du modèle, estimés en ligne par des méthodes adaptatives. Les paramètres peuvent servir d'entrées au module de décision, ou être utilisés pour calculer des caractéristiques fréquentielles ([SEU 05], [ALS 02]). Thavatia et al ([THA 91]) modélisent le signal de vibration enregistré sur le genou d'un patient en cours

d'effort par un modèle AR dont les coefficients sont utilisés pour effectuer un diagnostic d'altération du cartilage. Un modèle AR a été utilisé par Paiss et Inbar ([PAI 87]) sur un signal EMG pour détecter en ligne des états de fatigue. Le modèle est utilisé pour calculer la densité spectrale de puissance avec une meilleure résolution que par transformée de Fourier.

Certains auteurs appliquent une transformation en ondelettes et utilisent ensuite les coefficients de décomposition ou des caractéristiques extraites du scalogramme comme entrées de la fonction de décision ([SHI 06], [NIL 06], [JEO 06]). Fontenla-Romero et al. ([Fon 03]) réalisent un diagnostic d'apnée du sommeil par réseau de neurones après avoir décomposé le signal d'effort thoracique en coefficient d'ondelettes, formant les entrées du réseau de neurones.

Les transformations numériques/symboliques réalisent une abstraction temporelle du signal. Parmi celles-ci, citons la représentation par tendances qui sera présentée dans le détail dans la suite de ce mémoire. La tendance est une succession d'épisodes consécutifs décrivant complètement et de manière semi qualitative l'évolution temporelle d'un signal. D'autres abstractions peuvent être proposées comme la décomposition du signal en une suite d'évènements datés. Le choix des évènements est spécifique à une application, ([YAI 04]). Carrault et al ([CAR 03]) ont ainsi décrit le signal d'électrocardiogramme (ECG) par une succession de complexes QRS et d'ondes P, détectés en ligne sur le signal, afin de diagnostiquer certaines formes d'arythmies cardiaques à l'aide de chroniques.

1.2.2. Fusion des informations

Les informations extraites des signaux sont ensuite fusionnées pour obtenir une décision. La fonction de décision est une fonction d'un espace de dimension n (n est le nombre d'information à fusionner) vers un espace de dimension d . d est le nombre de décisions. Dans le cas d'un problème de détection, d vaut 2 (2 décisions sont possibles : anomalie, pas d'anomalie). Dans le cas d'un problème de diagnostic, d est le nombre d'anomalies à diagnostiquer.

La fonction de décision s'appuie sur un modèle de décision, dont l'élaboration dépend de la connaissance à priori que l'on a du système. Le modèle peut être élaboré à partir de la connaissance d'un expert ou à partir des données (on parle alors d'apprentissage à partir des données), ou encore par apprentissage mixte (méthode de classification Lamda [AGU 01], [LAM 05]).

Un modèle de connaissance est constitué d'un ensemble de règles dont les prémisses sont les informations extraites des signaux et les conclusions sont les anomalies à détecter. Il décrit explicitement la signature d'une anomalie. Les entrées de ces modèles peuvent être de nature différente, binaires, numériques et/ou symboliques, après transformation numérique/symbolique des caractéristiques des signaux ou après un changement de représentation. La complexité des modèles est très diverse. Le modèle de connaissance peut être une règle (quand l'entrée du modèle est la présence d'un évènement détecté sur le signal et que la présence de l'évènement correspond à la signature de l'anomalie), une base de règles floues ([CAV 04], [EVS 98], [OKU 04]) un arbre de décisions ([BEC 97], [SUK 93], [KOS 94]) ou encore un ensemble de chroniques (après transformation numérique/symbolique du signal en une suite d'évènements), permettant de prendre le temps en compte de manière explicite ([COR 01]).

Le modèle peut être appris à partir des données quand celles-ci sont en nombre suffisant et que les anomalies à diagnostiquer sont bien représentées dans la base de données d'apprentissage ([COR 02]). L'apprentissage est dit supervisé si pour chaque exemple de la base d'apprentissage,

défini par l'ensemble des informations extraites sur les signaux à un moment donné, on connaît l'anomalie correspondante. Le processus d'apprentissage consiste dans un premier temps à choisir à priori une structure de modèle. Les données de la base d'apprentissage sont ensuite utilisées pour en estimer les paramètres.

Parmi les techniques d'apprentissage à partir des données, on trouve les techniques de reconnaissance de formes ([DUB 90], [DUB 01a], [DUB 01b]). La fonction de décision est un classifieur qui permet de classer un vecteur forme composé de n caractéristiques parmi une des classes correspondant à une anomalie. Bien que plusieurs techniques de classification puissent être choisies, un grand nombre de publications porte sur l'utilisation d'un réseau de neurones ([BAR 94], [OSB 06], [GUL 05], [SRI 05], [TUR 02], ...). Le choix de la méthode de classification détermine la forme des frontières partageant l'espace de représentation (l'espace des entrées) en régions de décisions.

A l'inverse, l'apprentissage est dit non supervisé quand l'anomalie correspondante n'est pas connue pour chaque exemple. Dans ce cas, les techniques d'apprentissage consistent à trouver des groupements dans les données (cluster), au sens d'une distance donnée. L'expert intervient ensuite pour associer chaque cluster à une anomalie.

Enfin, parmi les techniques d'apprentissage à partir des données, citons le raisonnement à base de cas. La base de données expertisée forme la base de connaissance du système. Tout nouveau cas, caractérisé par les n paramètres d'entrées de la fonction de décision, est comparé au sens d'une mesure de similarité, à tous les cas de la base de connaissance. La décision sur le nouveau cas sera identique au cas qui lui est le plus semblable ([ZIY 03], [HAI 04], [OLS 04], [FEN 02], [MEL 01]).

D'une manière générale, les performances d'un système de diagnostic sans modèle formel dépendent de la qualité des informations extraites des signaux et de la pertinence du modèle de décision (choix des entrées, structure du modèle, précision des paramètres estimés, ...), que celui-ci soit appris à partir des données ou élaboré grâce à la connaissance d'un expert.

1.3. Surveillance et diagnostic des systèmes médicaux

L'augmentation du flot d'informations due à l'évolution technologique est un phénomène qui s'observe aussi en médecine. Le médecin doit poser un diagnostic à partir d'un nombre de plus en plus important de mesures physiologiques, tout en maintenant un diagnostic de qualité. Les informations augmentent en diversité mais aussi en quantité, car la fréquence des mesures s'accroît. Cette tendance ira en augmentant dans les prochaines années, avec le développement de systèmes de mesures embarqués et de la télé médecine. Le médecin passera moins de temps avec son patient mais devra analyser un flot de données plus important.

Le problème de surcharge cognitive due à l'augmentation du flot d'information est encore plus accentué dans les services d'urgence ou d'anesthésie réanimation où la rapidité de réaction joue un rôle important sur la qualité des soins apportés au patient : une complication médicale doit être détectée au plus tôt et un diagnostic posé rapidement.

Ainsi, les objectifs d'un système de surveillance médicale sont les mêmes que ceux d'un système de surveillance classique: aide à l'interprétation des données, détection, proposition de diagnostic. Dans la suite de ce chapitre, on ne parlera plus d'anomalie mais d'état. L'objectif de la surveillance est de détecter un changement d'état ou de reconnaître un état particulier chez un patient, cet état pouvant être pathologique ou non.

La mise en oeuvre de systèmes de surveillance ou de diagnostic suppose que l'on dispose d'un flot d'informations régulier. Cela implique que le patient soit équipé d'appareils de mesure qui permettent le recueil fréquent de données. Actuellement, les applications concernent :

- la surveillance de patients hospitalisés, plus particulièrement dans les services d'anesthésie ou de réanimation où l'état des patients est étroitement surveillé à l'aide de systèmes de monitoring. Il s'agit de détecter en temps réel une dégradation de l'état de santé du patient.

- l'interprétation d'informations recueillies sur un patient sur une période de temps donnée à des fins de diagnostic. Le recueil peut être fait en milieu hospitalier (analyse du sommeil), à domicile (analyse de signaux respiratoires au cours du sommeil), ou en ambulatoire (mesures de signaux cardio-vasculaires par Holter). L'analyse des données n'est pas nécessairement effectuée en temps réel.

Un patient est un « système » complexe difficilement modélisable par un système d'équations différentielles. Les relations entre variables sont fortement non linéaires, peuvent changer en fonction du temps, et d'un patient à l'autre. Les techniques de surveillance à base de modèle ne sont pas applicables à ce type de système car les performances de ces méthodes dépendent fortement de la fiabilité du modèle. On se tournera donc vers les méthodes de diagnostic sans modèle qui sont mieux adaptées.

L'état du patient est décrit par un ensemble d'informations dont l'observation permet le diagnostic. Le choix des informations à extraire et du modèle de fusion dépend des états que l'on cherche à reconnaître. Parmi les différentes techniques de diagnostic possibles, deux types d'approches se dégagent :

- L'état du patient est caractérisé par un ensemble d'informations mesurées à un instant donné.

Le diagnostic est réalisé par reconnaissance de formes. Un ensemble de caractéristiques numériques est extrait des signaux mesurés sur le patient et utilisé comme entrées d'un classificateur dont les sorties sont les états à reconnaître. Les caractéristiques sont extraites à l'aide d'une fenêtre temporelle au cours de laquelle les signaux sont supposés stationnaires.

L'hypothèse sous-jacente est que l'état du patient est « stable par morceaux ». Le patient se trouve dans un état donné pendant une certaine période de temps puis évolue très rapidement vers un nouvel état où il reste un certain temps.

Ce mode de diagnostic est assez classique en médecine, notamment en médecine d'urgence. Il existe des tables de scoring permettant d'effectuer un diagnostic rapide de l'état de santé d'un patient, décrit par un ensemble de règles définies à partir de la valeur de différentes variables physiologiques [BLE 95]. Citons par exemple le score de Glasgow qui donne un indice de gravité de l'atteinte neuro-physiologique.

- L'état du patient est décrit par l'évolution temporelle des signaux.

Un état est reconnu à partir de l'analyse des changements transitoires des signaux. La signature d'un état est définie à partir de formes temporelles multi-variables. La reconnaissance de ces formes temporelles sur les signaux permet le diagnostic de l'état. Les techniques de diagnostic utilisées sont des méthodes d'analyse de tendances, de reconnaissance de formes temporelles à l'aide de gabarit ou par mesures de distance.

Ce mode de diagnostic est lui aussi utilisé en médecine. Citons, dans cette catégorie, la détection de problèmes de croissance chez l'enfant (retard de croissance, puberté précoce, ...) à partir d'une courbe de croissance moyenne, qui constitue un gabarit de « bonne croissance ».

Dans la suite de ce rapport, je décrirai mes travaux de recherche concernant le diagnostic de système médicaux, traitant des deux approches précédentes. La première partie sera consacrée au diagnostic par analyse de tendances et son application pour l'aide à la surveillance de patients en unités de réanimation. La deuxième partie sera consacrée à deux exemples de diagnostic par reconnaissance de formes : la détermination de l'état d'urgence d'un blessé polytraumatisé et la reconnaissance de phases de sommeil humain.

2. Surveillance de systèmes par analyse de tendance : Application à la surveillance de patients hospitalisés en service de réanimation

Dans ce chapitre, je présenterai mes travaux de recherche sur la surveillance de systèmes par analyse de tendance et son application à la surveillance de patients hospitalisés en service de réanimation. Ce travail a débuté en 2000. Il a donné lieu à quatre stages de master recherche (Guillaume Becq, juin 2000, Master recherche spécialité « Modèles et Instruments en Médecine et Biologie », Marion Henry, Septembre 2002, Master recherche spécialité « Signal, Images, Paroles », Romain Blayac, Septembre 2003 et David Pean, Juin 2005, Master recherche spécialité « Automatique »), à quatre stages de fin d'études d'ingénieur et au travail de thèse de Lyes Badji, spécialité Automatique, co-encadré avec Sylviane Gentil, débuté en Octobre 2003.

2.1. Introduction

L'état de santé des patients séjournant dans les services de réanimation est grave, voire critique. Il nécessite une surveillance étroite de la part du personnel soignant de ces services : celui-ci doit reconnaître au plus tôt une dégradation de l'état d'un patient et lui apporter les soins nécessaires.

Afin de faciliter la tâche du personnel, les patients sont équipés d'appareils de monitoring qui fournissent une mesure de différents paramètres physiologiques (fréquence cardiaque, fréquence respiratoire ...) à des fréquences élevées (0.2 Hz ou 1 Hz). Grâce au progrès technologique, le nombre de ces paramètres est en constante augmentation, ce qui rend leur interprétation de plus en plus difficile. Ainsi, le personnel soignant souffre de surcharge cognitive liée à la nécessité d'analyser au plus vite un flot important d'informations. Cette surcharge cognitive, fréquemment rencontrée chez les opérateurs chargés de la surveillance d'un procédé, est aggravée par le fait que le personnel a la charge de plusieurs patients, souffrant de pathologies diverses.

A ce problème s'ajoute celui de la pollution sonore, générée par un nombre important de fausses alarmes. Les systèmes de surveillance actuels utilisent des techniques de franchissement de seuil, très sensibles aux artéfacts : une alarme se déclenche dès que la variable mesurée sort de bornes fixées au préalable par le personnel soignant. La multiplication des alarmes dans les unités de soins intensifs, accroît encore les difficultés d'interprétation et relâche l'attention du personnel ([TIS 97], [BEN 89], [LAW 94], [OCA 86]).

Pourtant, malgré une évidente nécessité, aucun outil d'aide à l'interprétation du flot de données recueillis sur le patient n'a été développé afin d'aider le personnel dans sa tâche d'analyse et de diagnostic, pas plus qu'un système d'alarmes utilisant un autre principe que le franchissement de seuils.

Dans cet objectif, nous avons développé une méthodologie d'extraction de tendances qui fournit une aide visuelle à l'interprétation de l'évolution d'un paramètre physiologique, et nous l'avons utilisé comme support d'algorithmes de reconnaissance d'évènements ou de diagnostic d'alarmes. En effet, l'état d'un patient est caractérisé par la valeur numérique des variables et leur tendance. La connaissance médicale s'exprimant sous la forme de propositions du type, *SI*

variable1 augmente ET variable2 augmente ET variable3 augmente OU variable3 stable ALORS conclusion, nous avons cherché à réaliser une transformation numérique/symbolique rendant compte de ces différentes catégories "augmente, diminue, stable".

La suite de ce chapitre sera organisée comme suit. Le deuxième paragraphe présentera une bibliographie sur les techniques d'extraction de tendances et leur utilisation à des fins de diagnostic. La méthode d'extraction de tendances que nous avons développée sera décrite au paragraphe 3 et son utilisation à des fins d'aide à la surveillance de patients hospitalisés en réanimation sera présentée au paragraphe 4.

2.2. Bibliographie

2.2.1. Définition de la tendance

Une tendance est une représentation condensée de la dynamique d'un signal, sur une échelle de temps asynchrone, reposant sur une bibliothèque de formes utilisées pour la description qualitative ou semi-qualitative du signal.

La tendance est composée d'une suite continue d'épisodes de longueur variable, consécutifs et ne se chevauchant pas. Un épisode est un intervalle de temps, défini par un instant de début et un instant de fin, auquel est associé une forme, appelée primitive, choisie parmi une bibliothèque de formes décrivant la dynamique du signal.

2.2.2. Méthodes d'extraction de la tendance

On peut trouver dans la littérature plusieurs types de méthodes d'extraction de la tendance. Elles dépendent de la complexité des primitives qui lui sont associées. Il existe deux classes de tendances : celles qui décrivent le signal à partir de formes du premier et second ordre, de type droite ou parabole, et celles qui décrivent le signal uniquement par des formes du premier ordre. Les premières nécessitent la connaissance des dérivées première et seconde du signal pour pouvoir extraire la primitive alors que les deuxièmes ne nécessitent que la connaissance de la dérivée première.

2.2.2.1. Tendances construites à partir de primitives du premier et deuxième ordre.

Cheung et Stephanopoulos ([CHE 90 a], [CHE 90 b]) proposent de décrire la tendance d'un signal à l'aide de 7 primitives, linéaires ou quadratiques, définies à partir de la valeur qualitative (0, +, -) des dérivées première et seconde du signal. Un épisode est défini comme un intervalle de temps au cours duquel la valeur qualitative des dérivées première et seconde est constante. Lorsque celles-ci commutent, un nouvel épisode débute. Ainsi, le début d'un épisode correspond à un point d'inflexion sur le signal (commutation de la dérivée seconde) ou à un extremum (commutation de la dérivée première). Chaque épisode peut être représenté par une forme triangulaire. L'épisode triangulaire, défini sur un intervalle de temps $[t_i, t_j[$, à partir des points d'amplitude y_{t_i} , y_{t_j} , est délimité par les droites suivantes : la droite passant par le point (t_i, y_{t_i}) et tangente au signal en ce point, la droite passant par le point (t_j, y_{t_j}) et tangente au signal en ce point, et la droite reliant les points y_{t_i} et y_{t_j} .

Janusz et Venkatasubramanian ([JAN 91]) décrivent eux aussi la tendance d'un signal à l'aide de primitives du premier et second ordre. Ils utilisent les 7 primitives décrites par Cheung et

Stephanopoulos auxquelles ils ajoutent deux autres, le maximum et le minimum, définis par l'état qualitatif {dérivée première nulle et dérivée seconde positive ou négative}. Un signal est décrit dans leur formalisme par un profil, ils ajoutent une information numérique sur la valeur du signal en début et fin d'épisodes.

Colomer et al. ([MEL 01], [COL 02 a]) complètent cette représentation par 4 nouvelles primitives représentant explicitement les discontinuités ou ruptures dans le signal. Elles sont caractérisées par le fait que la dérivée seconde prend une valeur importante lors de leur apparition. La tendance est alors décrite par 13 primitives au total.

2.2.2.1.1. Identification des primitives par dérivée numérique

L'extraction de la tendance à partir du signal consiste à identifier les primitives en ligne. Une solution possible est le calcul des dérivées premières et secondes du signal. Le signal est dérivé numériquement à chaque période d'échantillonnage et les deux dérivées sont classées suivant trois classes en fonction de la valeur calculée : positive ou négative, selon le signe, si supérieure à un seuil en module, nulle sinon (le seuil fixant la valeur à partir de laquelle la dérivée est considérée nulle peut être différent pour la dérivée première et seconde). Dans le cas de Colomer et al., il faut définir de plus un seuil maximal sur la dérivée seconde qui permet de détecter les primitives représentant les discontinuités. Il est ensuite aisé d'attribuer une primitive au signal, à partir des valeurs qualitatives estimées des dérivées. Un épisode maximal est construit comme la concaténation d'épisodes élémentaires dont la primitive est calculée à chaque période d'échantillonnage, ou encore par la détection dans le signal d'instant caractéristiques (commutation des valeurs qualitatives des dérivées) qui indiquent le début d'un nouvel épisode (et donc la fin de l'épisode précédent).

Le calcul de dérivée pose néanmoins le problème d'amplification du bruit et un filtrage passe-bas est nécessaire avant son application. Différents types de filtres peuvent être utilisés. Citons par exemple Konstantinov et Yoshida ([KON 92]) qui approchent préalablement le signal par une fonction polynomiale, Bakshi et Stephanopoulos (1994) ([BAS 94 a]) qui utilisent une décomposition du signal par ondelettes ce qui leur permet de décrire la tendance à différentes échelles de temps, Vedam et Venkatasubramanian ([VED 97 a]) qui réalisent une interpolation du signal par B-spline, ou encore Colomer et Melendez ([COL 01]) qui utilisent un filtre passe bande à réponse impulsionnelle finie pour dériver le signal.

Quelle que soit la méthode, il est cependant nécessaire d'avoir des informations a priori sur la dynamique du signal afin de régler le filtre au mieux, et ainsi retrouver sur la tendance les informations nécessaires à une bonne description de la dynamique du signal. Le filtrage ne doit pas masquer certaines informations importantes pour l'analyse du signal, comme les ruptures, qui peuvent correspondre à la signature d'un défaut particulier.

2.2.2.1.2. Identification des primitives par reconnaissance de formes

Afin de s'affranchir des problèmes de filtrage associés au calcul numérique des deux premières dérivées, Rengaswamy et Venkatasubramanian ([REN 95 a], [REN 95 b]) proposent de transformer le problème d'identification des primitives en un problème de reconnaissance de forme. Les primitives sont identifiées en ligne à l'aide d'un réseau de neurones de type perceptron multi couches (PMC). Le PMC est composé d'une couche de k entrées, d'une couche cachée composée de n neurones et d'une couche de sortie composée de 7 neurones. A chaque entrée correspond la valeur du signal à un instant donné ($y_i, y_{i-1}, \dots, y_{i-k}$, i correspondant à l'instant courant pour lequel on cherche à identifier la primitive). A chaque neurone de sortie

correspond une des 7 primitives à reconnaître, telles que définies par Cheung et Stephanopoulos. Les deux autres primitives, maximum et minimum, sont déduites de la tendance extraite par des règles d'inférence, fondées sur la continuité des dérivées. Le choix de la structure du réseau (nombre n de neurones dans la couche cachée) et l'apprentissage du réseau de neurones sont réalisés à partir d'une base d'exemples comprenant les sept primitives à identifier.

Idéalement, en l'absence de bruit sur le signal, l'identification des 7 primitives peut se faire à l'aide de 3 mesures successives sur le signal ($k = 3$). Cependant, pour que l'identification soit robuste au bruit de mesure, elle doit être effectuée sur une période temporelle d'observation plus importante. Le choix de la durée de la période d'observation est un compromis entre la sensibilité au bruit et la capacité d'observation des dynamiques les plus rapides du signal. Rengaswamy et Venkatasubramanian ([REN 95 b], [REN 01]) proposent de faire varier la période d'observation entre 5 et 10 périodes d'échantillonnage, l'expérience ayant montré que cela semble convenir pour les procédés pour lesquels la méthode a été utilisée (procédés chimiques, essentiellement). ([REN 95b]).

Pour conclure, il convient de noter que si les méthodes d'extraction de tendance utilisant des primitives du 1^{er} et 2nd ordre permettent une description fine de l'évolution temporelle du signal, elles restent cependant sensibles au bruit perturbant le signal et sont à éviter quand le rapport bruit sur signal est important.

2.2.2.2. Tendances construites à partir de primitives du premier ordre

Quand les signaux à analyser sont fortement perturbés par du bruit, il est difficile de représenter la tendance par des primitives du 2nd ordre. C'est le cas par exemple des signaux biologiques ou physiologiques, enregistrés sur des êtres vivants. La tendance consiste alors à décrire l'évolution temporelle du signal sous forme simplifiée, à partir de trois primitives (quatre au maximum) : constant, croissant, décroissant (instable). L'identification des primitives ne nécessite plus alors que l'estimation de la dérivée première. Celle-ci peut être calculée soit par régression linéaire sur une fenêtre temporelle glissante, soit après découpage du signal en segments de droite (segmentation).

2.2.2.2.1. Tendance obtenue par régression linéaire sur fenêtre glissante

Makivirta et al. ([MAK 89], [MAK 91]) choisissent de représenter la tendance de paramètres physiologiques enregistrés sur des patients hospitalisés en unité de soin intensifs cardiologiques à l'aide de trois primitives : croissant, décroissant, stable. La tendance est extraite en ligne en faisant glisser à chaque période d'échantillonnage une fenêtre de taille prédéfinie sur le signal et en calculant la droite de régression qui approche au mieux les données au sens des moindres carrés. La valeur qualitative (positive, négative ou nulle) de la pente de la droite de régression détermine la primitive, calculée à chaque période d'échantillonnage. Un épisode est défini sur une succession d'instant où la primitive est identique (la dérivée garde la même valeur qualitative). La taille de la fenêtre est choisie a priori. La droite de régression opère comme un filtre passe-bas, dont la fréquence de coupure dépend de la taille de la fenêtre. Plus la fenêtre est courte et plus la tendance suivra les oscillations rapides du signal. Plus elle est longue et plus la tendance extraite décrira les variations à long terme.

Le calcul de la droite de régression par la méthode des moindres carrés rend cette méthode sensible aux artéfacts de mesure (changements importants et de courte durée pouvant affecter le signal, observables sur les signaux physiologiques), l'hypothèse nécessaire à une estimation

optimale sans biais de la pente étant que le bruit affectant le signal soit blanc gaussien. Afin de réduire la sensibilité de la tendance aux artéfacts, Makivirta et al. filtrent préalablement le signal à l'aide d'un filtre médian, qui a la propriété d'éliminer tout artéfact de durée inférieure à la moitié de la taille de la fenêtre du filtre, sans déformer les variations brusques, de type échelon, du signal. Enfin, notons que toute variation de type échelon sur le signal sera décrite par un épisode croissant (ou décroissant) de durée égale à la taille de la fenêtre glissante.

Calvelo et al. ([CAL 99], [CAL 00]) décrivent la tendance temporelle des paramètres physiologiques de patients adultes hospitalisés en réanimation par quatre primitives : stable, croissant, décroissant, instable. Les primitives sont identifiées en ligne à partir d'une fenêtre glissante de taille fixe (n). Le choix de la primitive dépend du coefficient de corrélation entre le signal y et le temps t , calculé sur les n points de la fenêtre et de l'écart type du signal estimé sur la fenêtre. Si l'écart type du signal est supérieur à un seuil fixé, la primitive identifiée est instable. Les primitives croissant et décroissant sont identifiées si le coefficient de corrélation est supérieur à 0.8 en valeur absolue, sinon la primitive est stable. Les épisodes instables de la tendance correspondent à des zones temporelles où l'on observe des transitoires rapides (un échelon, par exemple) sur le signal, ou des artéfacts, mais la méthode ne permet pas de distinguer les deux. Enfin, Calvelo et al. proposent une méthode pour choisir automatiquement la taille de la fenêtre glissante, pendant une période d'apprentissage. Elle est fondée sur un critère statistique d'appréciation de l'approximation des données par une droite.

2.2.2.2.2. Régression linéaire après segmentation du signal

La segmentation d'un signal consiste à détecter, en ligne ou non, les intervalles de temps où les caractéristiques d'un signal sont invariantes. Dans le cas de l'extraction de tendance à l'aide de primitives du premier ordre, la segmentation consiste à détecter les intervalles de temps où le signal peut être correctement approché par une droite.

Hunter et McIntosh ([HUN 99]) proposent d'extraire la tendance de paramètres physiologiques, définie par les primitives (croissant, décroissant, stable), à l'aide d'un algorithme de segmentation développé par Keogh ([KEO 97]). Cet algorithme de segmentation, dit ascendant, découpe automatiquement une série temporelle en plusieurs intervalles où les données peuvent être approchées correctement par un segment de droite. L'algorithme convertit une suite de points en une séquence d'intervalles élémentaires, puis fusionne itérativement les intervalles adjacents en intervalles plus grands jusqu'à ce qu'une condition d'arrêt, définie à partir de la somme de la différence au carré des points par rapport aux segments de droite, soit satisfaite. La pente de la droite calculée sur chaque intervalle obtenu peut alors être calculée, et le signe de la pente permet d'attribuer une des trois primitives à l'intervalle. Bien que cette méthode permette d'extraire la tendance du signal sans filtrage préalable et en mettant en évidence les discontinuités de type échelon, son inconvénient est qu'elle ne fonctionne que hors ligne. Keogh et al [KEO 01] a ensuite développé un algorithme de segmentation semi en ligne, à partir d'un buffer de données. Le temps de retard nécessaire à l'extraction d'un signal segmenté (égal à la taille du buffer) ne permet pas d'utiliser l'algorithme pour extraire une tendance en ligne sur des signaux physiologiques.

Yang et al ([YAN 05]) segmentent le signal en ligne à l'aide d'un filtre de Kalman adaptatif couplé à un prédicteur EWMA (Exponential Weighting Moving Average). Le signal est modélisé par un modèle de croissance linéaire décrivant la dynamique du système à l'aide de deux variables d'état: la pente et la valeur du signal. Un filtre de Kalman est utilisé pour débruiter le signal et estimer en ligne la valeur de la pente. Le modèle de croissance linéaire couplé à un

prédicteur EWMA est utilisé pour prédire les valeurs futurs du signal à N pas. La somme cumulée de la différence entre la prédiction et le signal (CUSUM) est calculée et permet de détecter les instants de changement dans la dynamique quand la CUSUM franchit un seuil. Ce seuil n'est pas fixe mais calculé en fonction de l'écart type de la somme des prédictions. La valeur de la pente moyenne calculée entre deux points de changement permet d'attribuer une primitive parmi stable, croissant, décroissant à l'intervalle de temps délimité par ces deux points.

2.2.2.3. Conclusion sur les méthodes d'extraction de la tendance

Le choix du type de représentation par la tendance dépend essentiellement des signaux que l'on cherche à décrire, et en particulier du bruit qui les affecte. Si le rapport signal sur bruit est faible, il est inutile de chercher à décrire la tendance par des primitives du second ordre, car l'extraction des primitives du second degré est alors difficile à réaliser et la tendance obtenue assez souvent erronée. L'extraction de primitives du second ordre sur des signaux fortement bruités nécessite de filtrer les données de manière importante, avec le risque de déformer le signal, et notamment les ruptures de type échelon, le plus souvent caractéristiques d'un défaut. Le réseau de neurones proposé par Rengaswamy et Venkatasubramanian n'obtient pas non plus de bons résultats en présence d'un bruit important. Il est préférable alors d'opter pour une représentation simplifiée de la tendance à l'aide de trois primitives seulement.

Cependant, si le niveau de bruit affectant le signal est faible, la tendance composée de primitives du 2nd degré offre une représentation plus riche de l'évolution temporelle du signal, et peut permettre de diagnostiquer certains défauts affectant le procédé, dont la signature est une évolution temporelle du signal de type quadratique. On constate dans la littérature que le diagnostic de systèmes de type systèmes chimiques ou biochimiques passe par la description de l'évolution temporelle des signaux par des primitives du 2nd ordre. Dans le cas de systèmes médicaux, on se contente de primitives du premier ordre, croissant, décroissant, stable, qui correspondent au vocabulaire utilisé par les médecins. Le bruit important qui perturbe ces signaux ne permet de toute façon pas l'utilisation de méthodes nécessitant le calcul de la dérivée seconde.

Les méthodes utilisant la valeur de la dérivée première pour identifier les primitives se heurtent à la difficulté de détecter les dérives lentes dans le signal, et ceci que la dérivée soit calculée numériquement après filtrage, ou par estimation à l'aide de la pente de la droite de régression. Une dérive lente se caractérise par une variation de pente faible qui peut être inférieure au seuil minimum qui permet de distinguer entre stable et variation linéaire. Cette difficulté à reconnaître une dérive lente est aussi rapportée par Vedam et Venkatasubramanian ([VED 97b]), lors de l'utilisation du PMC.

Parmi les méthodes n'utilisant que la dérivée première pour extraire la tendance, celle de Calvelo et al. a l'avantage de la simplicité de mise en œuvre, car elle est très simple à programmer. La recherche automatique de la meilleure longueur de fenêtre évite d'avoir à répondre à des questions complexes sur le choix du meilleur filtre à appliquer sur le système, comme c'est le cas en utilisant la dérivée numérique. Il n'est pas nécessaire de régler des seuils au préalable. Cependant, la méthode n'a pas la capacité de reconnaître des transitoires rapides, qui sont souvent caractéristiques de certains défauts.

2.2.3. Utilisation de la tendance pour le diagnostic et la supervision

La tendance permet de représenter de manière symbolique l'évolution temporelle d'un signal, et de mettre ainsi en évidence sur le signal certaines formes qui sont caractéristiques de l'apparition d'un défaut. La reconnaissance automatique de ces formes va permettre de fournir un diagnostic.

Le développement d'un système de diagnostic est constitué de deux tâches :

- une première tâche d'apprentissage dont l'objectif est de mettre en correspondance une forme temporelle avec un défaut. Cette tâche peut être réalisée avec l'aide d'un expert, qui va décrire la forme particulière prise par le signal au cours de l'apparition d'un défaut. Elle peut aussi être réalisée de manière automatique, à l'aide de techniques de fouilles de données.

- Une tâche de détection de formes en ligne, ou « pattern matching », dont l'objectif est de retrouver dans la tendance du signal la forme temporelle caractéristique du défaut, à l'aide d'un critère de similarité net ou flou ([DAS 03]).

Une forme temporelle correspond à un épisode ou à une succession d'épisodes, caractérisant un signal. Par exemple, un échelon correspond à la suite d'épisodes : stable, croissant (ou décroissant) pendant une durée brève, stable. Un changement d'état est caractérisé par la suite d'épisodes stable, croissant (ou décroissant), stable. Une oscillation correspond à une succession d'épisodes croissants puis décroissants. L'apport d'information quantitative comme la valeur du signal en début et fin d'épisodes permet de définir plus finement la forme temporelle. On peut ainsi différencier un échelon de faible amplitude d'un échelon de grande amplitude.

L'abstraction réalisée par l'association de plusieurs épisodes sur un signal (forme temporelle) permet de décrire des signatures de défauts affectant plusieurs signaux en même temps. En effet, une forme temporelle multi signaux peut être définie comme une combinaison de formes temporelles mono signal. Une forme temporelle multi signaux peut être décrite par exemple par « un changement d'état observé sur le signal A concomitant avec des oscillations sur le signal B ».

Le développement d'un système de diagnostic fondé sur l'analyse de tendance dépend de la connaissance experte que l'on possède sur le procédé.

- La connaissance experte peut être explicite c'est-à-dire qu'elle peut être représentée par une base de règles ou par un arbre de décision qui synthétise la connaissance de l'expert. Le diagnostic consiste alors à retrouver dans la tendance les formes temporelles qui forment les prémisses des règles et à inférer pour obtenir le diagnostic. Cette technique est celle utilisée par Janusz et Venkatasubramanian ([JAN 91]) pour diagnostiquer les défauts d'un réacteur chimique fonctionnant en mode continu, par Rengaswamy et Venkatasubramanian ([Ren 95 a]), pour diagnostiquer les défauts d'une unité de crackage catalytique fluidisée (FCCU), par Gamero et al ([GAM 06]) pour prédire les instabilités dans un haut fourneau, par Hunter et Mackintosh ([HUN 99]) pour repérer les changements de sonde d'O₂ collées sur la peau des bébés hospitalisés en service de néo-natalité ou par Charbonnier et al. ([CHA 05 a]) et Chambrin et al. ([CHAM 04]) pour reconnaître des événements associés à des alarmes en unités de soins intensifs.

- La connaissance experte peut être implicite quand l'expert est capable de reconnaître les défauts sur les signaux, mais pas d'expliquer sa démarche diagnostique. La connaissance est alors fournie par une base de données documentée, où les défauts sont repérés et diagnostiqués par l'expert. La réduction d'information obtenue par l'extraction de tendance permet d'adopter une

méthode de type fouille de données. Ainsi, Bakshi et Stephanopoulos utilisent l'approche d'induction par arbre de décision pour apprendre les signatures de défauts, définis par une succession d'épisodes triangulaires ([BAS 94 b]). Ils ont appliqué leur méthode avec succès sur plusieurs procédés chimiques industriels ([STE 97]). Colomer et al utilisent une approche par raisonnement à base de cas pour diagnostiquer les défaillances d'un système de deux bacs en cascade régulés en niveau. La base de cas est composée d'enregistrements de signaux représentés par leur tendance et correspondant à un défaut particulier. La recherche de similarité entre cas est réalisée à partir d'une mesure de distance utilisant les épisodes, inspirée de la mesure de distance Dynamic Time Wrapping ([COL 02 a], [COL 02 b]).

2.3. Méthode proposée pour l'extraction de tendance en ligne

Dans ce paragraphe, la méthode d'extraction de tendance en ligne que nous avons développée est présentée de manière détaillée. La première partie présente la version initiale de la méthode, la deuxième partie détaille les améliorations apportées ultérieurement.

La tendance extraite est une succession d'épisodes temporels, définis par l'instant de début et de fin ainsi que par la valeur du signal en début et fin d'épisode, auxquels sont associées trois primitives, stable, croissant, décroissant. Un épisode est décrit par l'équation **Eq. 1**.

$$[primitive, k_d, k_f, y_d, y_f] \quad \text{Eq. 1}$$

Dans le cadre d'une interface Homme-Machine, chaque épisode peut être associé à une phrase lui correspondant. Ainsi, l'épisode [*croissant*, k_d , k_f , y_d , y_f] signifie que « le signal est croissant depuis l'instant k_d jusqu'à l'instant k_f , de la valeur y_d à la valeur y_f . ».

Le signal est décomposé en deux informations complémentaires : la tendance et le résidu. La tendance exprime l'évolution temporelle du signal alors que le résidu décrit les variations du signal autour de sa tendance.

2.3.1. Version initiale

L'extraction de la tendance est effectuée en ligne en quatre étapes successives ([CHA 05b]):

- découpage du signal en segments de droite (segmentation) et extraction du résidu
- classification des deux derniers segments en une forme temporelle parmi sept: stable, croissant, décroissant, échelon positif ou négatif, transitoire croissant-décroissant ou décroissant-croissant
- transformation de la forme temporelle en un ou deux épisodes élémentaires semi-qualitatifs
- agrégation de l'épisode courant avec les précédents.

2.3.1.1. Extraction de la tendance en ligne

2.3.1.1.1. Segmentation en ligne du signal et extraction du résidu

Le signal est approché en ligne par une succession de segments de droite. La droite associée à un segment est définie par l'équation **Eq. 2**

$$y_k = p.(k - k_o) + y_o \quad \text{Eq. 2}$$

où p est la pente de la droite, k_o est l'instant d'origine et y_o l'ordonnée à l'origine.

L'algorithme de segmentation ([CHA 04]) détermine en ligne l'instant où la droite courante n'approche plus correctement le signal et calcule alors une nouvelle approximation linéaire par le critère des moindres carrés. La détection de l'instant où une nouvelle droite doit être identifiée se fait à l'aide de la somme cumulée des erreurs entre le signal et l'extrapolation par la droite (*Cusum*). Son fonctionnement est décrit ci-dessous et illustré Figure 2.

2.3.1.1.1.1. Décomposition en segments de droite

Supposons qu'à l'instant k_l , une nouvelle droite approchant au mieux le signal vienne d'être calculée par l'algorithme. Elle est définie par les paramètres p_l , k_o^l , y_o^l . Aux instants suivants, l'extrapolation du signal par la droite vaut :

$$y_{k_1+i} = p_l.(k_1+i - k_o^l) + y_o^l \quad \text{Eq. 3}$$

La différence entre le signal, y_m , et l'extrapolation est :

$$e_{k_1+i} = y_{k_1+i} - y_{m_{k_1+i}} \quad \text{Eq. 4}$$

La somme cumulée des différences calculée depuis l'instant k_l s'écrit :

$$Cusum_{k_1+i} = Cusum_{k_1+i-1} + e_{k_1+i} = \sum_{j=0}^i e_{k_1+j} \quad \text{Eq. 5}$$

A chaque période d'échantillonnage, la valeur absolue de la *Cusum* est comparée à deux valeurs seuils, nommées $seuil_1$ et $seuil_2$, avec $seuil_1 < seuil_2$, définies a priori.

- Si $abs(Cusum_{k_1+i}) \leq seuil_1$, l'approximation linéaire est correcte.
- Si $seuil_1 < abs(Cusum_{k_1+i}) \leq seuil_2$, la valeur du signal $y_{m_{k_1+i}}$ et l'instant correspondant k_{l+i} sont stockées dans une matrice nommée matrice des valeurs anormales. $Matrice_{valeursanormales} = \{y_{m_{k_1+i}} / seuil_1 < abs(Cusum_{k_1+i}) \leq seuil_2\}$. Cette matrice est vidée si la valeur absolue de la *Cusum* repasse sous $seuil_1$.

- Si $abs(Cusum_{k_1+i}) > seuil_2$, l'approximation linéaire courante n'est plus acceptable. Les paramètres de la nouvelle droite approchant au mieux les données au sens des moindres carrés sont calculés à partir des données stockées dans la matrice des valeurs anormales qui contient l'ensemble des points successifs $y_{m_{k_1+i}}$ pour lesquels la valeur absolue de la *Cusum* est comprise entre $seuil_1$ et $seuil_2$. Cette matrice doit contenir au moins trois points pour qu'une nouvelle approximation linéaire puisse être calculée. La *Cusum* est remise à zéro.

L'algorithme de segmentation inclut la possibilité de détecter les artéfacts sur le signal et de les éliminer avant le calcul des paramètres de la droite par la méthode des moindres carrés. Un artéfact est modélisé dans l'algorithme par un changement brutal de grande amplitude sur le signal, limité dans le temps. Il correspond à une erreur de mesure. Les artéfacts sont détectés à l'aide de trois paramètres. Les deux premiers fixent la taille de l'amplitude à partir de laquelle le changement est vu comme un artéfact, le troisième fixe sa durée. La détection d'artéfacts est une option de l'algorithme.

2.3.1.1.1.2. Détermination de l'instant d'origine du nouveau segment de droite

Afin d'éviter des discontinuités entre deux segments successifs qui ne correspondent pas à une réalité sur le signal, une recherche de continuité entre le segment précédent et le segment qui vient d'être calculé est effectuée. Pour cela, l'algorithme recherche l'intersection entre le nouveau segment et le segment précédent. Si l'intersection a lieu avant le début du segment précédent ou après l'instant courant, il y a discontinuité entre les deux segments. Le début du nouveau segment correspond à l'instant où la valeur absolue de la *Cusum* a dépassé pour la première fois $seuil_1$. Si l'intersection a lieu après le début du segment précédent et avant le temps courant, le début du nouveau segment est l'instant d'intersection entre les deux segments.

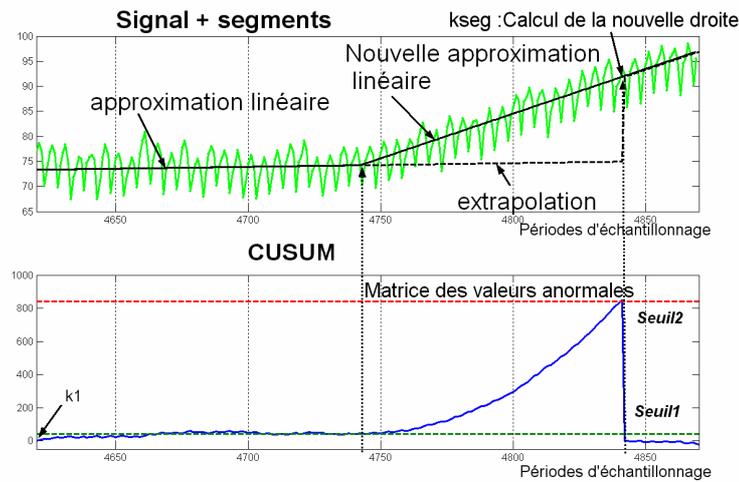


Figure 2 : Segmentation en ligne du signal

2.3.1.1.1.3. Extraction du résidu

Notons k_{seg} , l'instant où l'algorithme de segmentation vient de calculer une nouvelle approximation linéaire. A cet instant, l'approximation linéaire calculée par l'algorithme de segmentation approche au mieux le signal. Il est possible de calculer la différence entre le signal et l'approximation linéaire, depuis l'instant où a eu lieu la précédente segmentation jusqu'à l'instant k_{seg} . Cette différence, que l'on nomme résidu, correspond à la partie du signal qui n'est pas expliquée par l'approximation linéaire.

$$res_k = y_k - y_{mk} \quad \text{Eq. 6}$$

2.3.1.1.2. **Classification des deux derniers segments en une forme temporelle**

Soit k_{seg} , l'instant où l'algorithme de segmentation vient de calculer une nouvelle approximation linéaire, qui forme un $i^{ème}$ segment. L'information délivrée par l'algorithme de segmentation est :

k_0^i : instant d'origine de la droite, p^i : pente de la droite, y_0^i : ordonnée à l'origine.

A l'instant k_{seg} , la droite qui vient d'être calculée définit un segment de droite courant, noté segment i . Ce segment i est défini par :

- Un instant de début $k_{deb}^i = k_0^i$
- Un instant de fin : $k_{fin}^i = k_{seg}$

- Une valeur de début : $y_{deb}^i = y_0^i$
- Une valeur de fin $y_{fin}^i = p^i \cdot (k_{seg} - k_0^i) + y_0^i$

Le segment précédent, noté segment i-1, se termine une période d'échantillonnage avant le début du nouveau segment i. Il est défini par :

- Un instant de début $k_{deb}^{i-1} = k_0^{i-1}$
- Un instant de fin : $k_{fin}^{i-1} = k_0^i - Ts$, avec Ts la période d'échantillonnage
- Une valeur de début : $y_{deb}^{i-1} = y_0^{i-1}$
- Une valeur de fin $y_{fin}^{i-1} = p^{i-1} \cdot (k_{fin}^{i-1} - k_0^{i-1}) + y_0^{i-1}$.

Le segment courant i et le segment précédent i-1 créent une forme temporelle qui peut être classée en 7 formes distinctes : stable, croissant, décroissant, échelon positif ou négatif, transitoire croissant-décroissant ou décroissant-croissant. La forme associée au segment i débute à la fin du segment précédent, k_{fin}^{i-1} . La forme i peut être décrite à l'aide de 3 caractéristiques (Figure 3):

- La variation totale, nommée I, qui correspond à la différence entre la valeur à la fin du segment i et la valeur à la fin du segment i-1 :

$$I^i = y_{fin}^i - y_{fin}^{i-1} = \{p^i \cdot (k_{seg} - k_0^i) + y_0^i\} - \{p^{i-1} \cdot (k_{fin}^{i-1} - k_0^{i-1}) + y_0^{i-1}\} \quad \text{Eq. 7}$$

- La variation due à la discontinuité, nommée I_d , qui est calculée comme la différence entre la valeur en début de segment i et la valeur en fin de segment i-1

$$I_d^i = y_{deb}^i - y_{fin}^{i-1} = y_0^i - \{p^{i-1} \cdot (k_{fin}^{i-1} - k_0^{i-1}) + y_0^{i-1}\} \quad \text{Eq. 8}$$

- La variation due à la pente, nommée I_s , calculée comme la différence entre la valeur en fin de segment i et la valeur en début de segment i.

$$I_s^i = y_{fin}^i - y_{deb}^i = p^i \cdot (k_{seg} - k_0^i) + y_0^i \quad \text{Eq. 9}$$

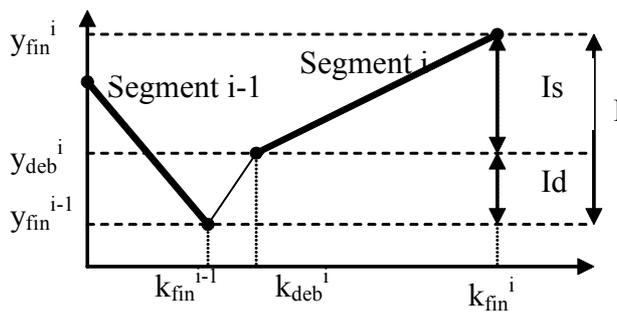


Figure 3 : Caractéristiques permettant de classer deux segments consécutifs en sept formes temporelles

La forme est classée en l'une des sept formes à l'aide d'un arbre de décision utilisant les 3 caractéristiques définies ci-dessus, $\{I, I_d, I_s\}$. L'arbre de décision, présenté Figure 4, est réglé à l'aide d'un paramètre de réglage, noté $seuil_c$. $seuil_c$ correspond à la valeur à partir de laquelle toute variation est considérée comme significative. Si la valeur de discontinuité est supérieure à ce seuil, la discontinuité est prise en compte dans la classification, sinon, elle est jugée

négligeable. De même, si la variation totale est supérieure à ce seuil, la forme est du type croissante ou décroissante. Ce paramètre peut être très facilement réglé par un expert du domaine.

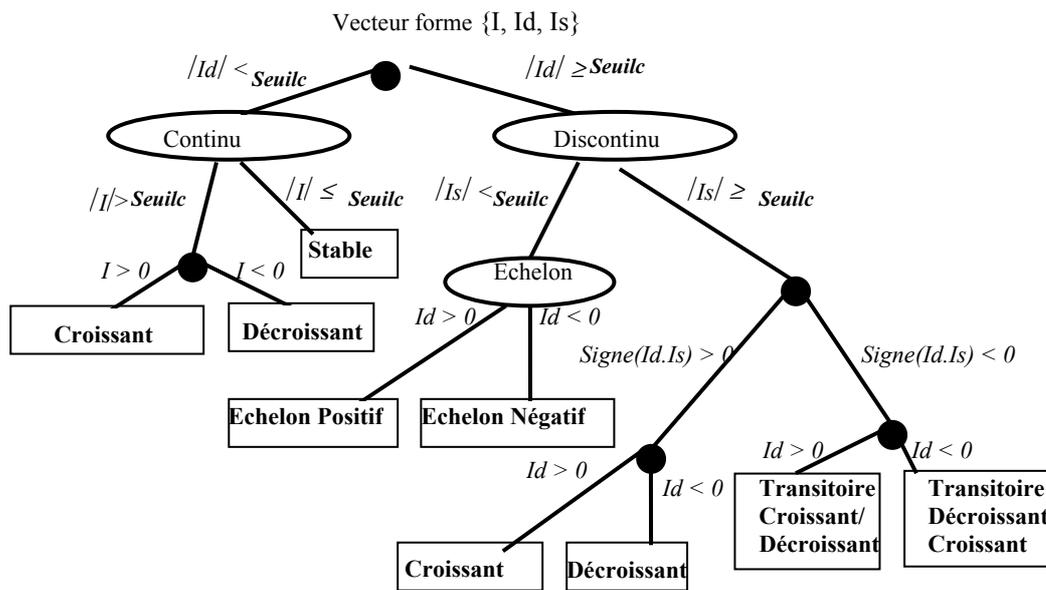


Figure 4 : Arbre de décision permettant le classement en sept formes temporelles

2.3.1.1.3. Transformation de la forme temporelle en épisodes semi-quantitatifs

La classification de deux segments consécutifs i et $i-1$ fournit une information qualitative, à laquelle on peut ajouter de l'information quantitative :

- l'instant de début de la forme : k_{fin}^{i-1}
- la valeur de l'approximation linéaire au début de la forme : y_{fin}^{i-1}
- la valeur de l'approximation linéaire une période d'échantillonnage plus tard : y_0^i
- l'instant de fin de la forme : k_{fin}^i
- la valeur de l'approximation linéaire à la fin de la forme : y_{fin}^i

La combinaison de l'information qualitative et quantitative permet de construire des épisodes, définis par un instant de début, un instant de fin, une valeur de début, une valeur de fin, et une primitive parmi $\{stable, croissant\text{ ou }décroissant\}$.

Si la forme temporelle est $\{stable, croissant\text{ ou }décroissant\}$, la forme est naturellement transformée en un épisode débutant et finissant aux mêmes instants, de mêmes valeurs aux

extrémités et de même primitive associée. Par exemple, la forme i classée en stable est transformée en épisode :

$$[Stable, k_{fin}^{i-1}, y_{fin}^{i-1}, k_{fin}^i, y_{fin}^i]$$

Dans ce cas, la discontinuité entre segments est négligeable ($y_0^i \approx y_{fin}^{i-1}$) et peut être supprimée de la définition de l'épisode.

Si la forme est discontinue, de type échelon ou transitoire, elle est découpée en deux épisodes temporels distincts, le premier ne durant qu'une période d'échantillonnage.

Ainsi, un échelon positif (respectivement négatif) devient :

$$[Croissant \text{ (respectivement Décroissant)}, k_{fin}^{i-1}, y_{fin}^{i-1}, k_{deb}^i, y_0^i] + [Stable, k_{deb}^i, y_0^i, k_{fin}^i, y_{fin}^i]$$

Un transitoire croissant-décroissant (respectivement décroissant-croissant) devient :

$$[Croissant \text{ (respectivement Décroissant)}, k_{fin}^{i-1}, y_{fin}^{i-1}, k_{deb}^i, y_0^i] + [Décroissant \text{ (respectivement croissant)}, k_{deb}^i, y_0^i, k_{fin}^i, y_{fin}^i]$$

Extraire les épisodes en deux phases, la classification en forme temporelle d'abord puis le découpage en épisodes, permet une bonne détection des discontinuités sur la tendance. La classification en forme temporelle permet une première fusion d'information en incluant une discontinuité de faible amplitude dans la forme temporelle et en mettant en évidence les discontinuités de plus grande amplitude. Sans cette étape, un épisode croissant (ou décroissant) pourrait être vu comme deux épisodes, un premier stable d'une durée d'une période d'échantillonnage puis un deuxième croissant (ou décroissant), ce qui poserait problème lors de la phase suivante d'agrégation d'épisodes deux à deux.

2.3.1.1.4. Agrégation des épisodes deux à deux

2.3.1.1.4.1. Règles d'agrégation

La phase d'agrégation d'épisodes consiste à agréger l'épisode courant avec le dernier épisode de la tendance déjà calculée, afin d'obtenir un épisode maximal. C'est une phase d'abstraction temporelle, qui est réalisée à partir de règles d'agrégation.

Afin de rendre la suite plus explicite, un épisode est maintenant défini de la manière suivante : $[primitive ; k_{deb}^i, y_{deb}^i, k_{fin}^i, y_{fin}^i]$. Un exemple d'agrégation d'épisodes est donné ci-dessous :

Si l'épisode précédent est $[croissant ; k_{deb}^{i-1}, y_{deb}^{i-1}, k_{fin}^{i-1}, y_{fin}^{i-1}]$

Si l'épisode suivant est $[croissant ; k_{deb}^i, y_{deb}^i, k_{fin}^i, y_{fin}^i]$

Alors l'épisode est agrégé avec le précédent et devient $[croissant ; k_{deb}^{i-1}, y_{deb}^{i-1}, k_{fin}^i, y_{fin}^i]$

Sinon, (si l'épisode suivant est stable ou décroissant : $[stable \text{ ou } décroissant ; k_{deb}^i, y_{deb}^i, k_{fin}^i, y_{fin}^i]$)

Alors il n'est pas agrégé avec le précédent et forme un nouvel épisode. La tendance est :

$$[croissant ; k_{deb}^{i-1}, y_{deb}^{i-1}, k_{fin}^{i-1}, y_{fin}^{i-1}] ;$$

$$[stable \text{ ou } décroissant ; k_{deb}^i, y_{deb}^i, k_{fin}^i, y_{fin}^i]$$

Les règles d'agrégation sont :

Croissant + croissant =croissant

Décroissant + décroissant =décroissant

Stable + stable= stable ou croissant (décroissant)

2.3.1.1.4.2. Détection de dérives lentes

Les règles d'agrégation permettent de transformer deux épisodes stables en un épisode croissant ou décroissant, ce qui permet de détecter les dérives lentes sur le signal. En effet, une dérive lente peut être constituée d'une succession de petits épisodes de faibles variations mais qui peuvent devenir significatives si elles sont mises bout à bout. Si seule la règle d'agrégation « stable + stable =stable » est possible, ces dérives lentes ne sont pas détectées.

La solution qui consiste à transformer un épisode stable en un épisode croissant ou décroissant si la différence entre les deux extrémités de l'épisode agrégé est supérieure au seuil de classification $seuil_c$ n'est pas satisfaisante, car un épisode stable et plat de longue durée suivi de deux épisodes classés en stable mais légèrement penchés peuvent être agrégés en un long épisode croissant ou décroissant, non représentatif de l'évolution temporelle du signal. La solution retenue consiste à classer avant agrégation chaque épisode stable en un épisode stable plat ou penché. Un épisode stable est penché si sa variation est supérieure en valeur absolue au quart du seuil de classification ($0.25 * seuil_c$), sinon il est plat. Au cours de la phase d'agrégation, une pile d'épisodes stables penchés est créée en ligne. Chaque fois qu'un épisode stable penché doit être agrégé, il est ajouté à la pile. La différence entre la valeur du signal à la fin du dernier épisode de la pile et celle de la valeur du début du premier épisode est ensuite calculée. Si celle-ci est supérieure au seuil $seuil_c$ de classification, alors un épisode croissant (ou décroissant) est créé, dont l'instant de début correspond à l'instant de début du premier épisode stable penché de la pile. La pile est vidée chaque fois qu'un épisode stable plat, croissant ou décroissant est détecté et présenté pour être agrégé.

2.3.1.2. **Visualisation des épisodes**

Il est important de noter que, du fait de la procédure d'agrégation :

- deux épisodes successifs ne peuvent pas avoir la même primitive. Les épisodes obtenus sont donc maximaux.

- la valeur à la fin d'un épisode est égale à la valeur en début de l'épisode suivant.

- l'instant de fin d'un épisode est égal à l'instant de début de l'épisode suivant. Les épisodes sont consécutifs.

Afin de faciliter l'interprétation visuelle de la tendance, les épisodes stables sont rendus plats de manière à être reconnus en un simple coup d'œil par un observateur. Ainsi, quand un épisode stable a été détecté, la valeur médiane du signal est calculée sur la durée de l'épisode et les valeurs aux extrémités de l'épisode sont remplacées par cette valeur médiane. La valeur de fin de l'épisode précédent est aussi modifiée afin de préserver la continuité.

La Figure 5 illustre le processus d'extraction de tendance sur un signal simulé. La partie supérieure de la figure présente la décomposition en segments de droite et la partie inférieure la tendance extraite. Le signal a été découpé en sept segments par l'algorithme de segmentation qui ont été classés en six formes temporelles successives : {stable, stable, échelon, stable, stable, stable}. Le début de chaque forme temporelle est repéré par un point. Bien que l'on observe des discontinuités entre les segments, comme entre le segment 3 et 4 par exemple, la valeur de celle-

ci est inférieure au seuil de classification $seuil_c$ et la forme temporelle associée est stable. Après l'agrégation de deux épisodes stables successifs, les extrémités de l'épisode agrégé sont remplacées par la valeur médiane du signal. L'épisode est ainsi rendu plat, ce qui permet une bonne reconnaissance visuelle des périodes où la tendance du signal est stable. Les discontinuités significatives sont correctement mises en évidence.

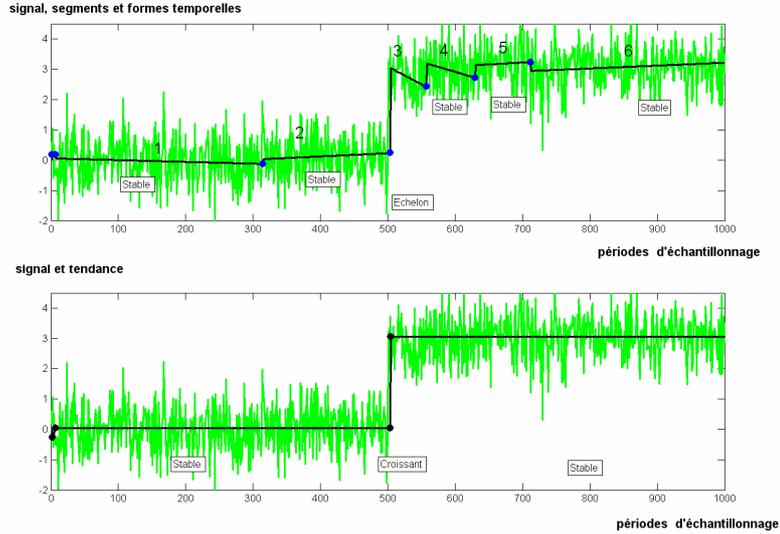


Figure 5 : Extraction de tendance sur signal simulé

2.3.1.3. Implantation de la méthode en ligne

Un épisode temporel est détecté et agrégé avec les précédents chaque fois que l'algorithme de segmentation vient de calculer une nouvelle approximation linéaire, c'est-à-dire à chaque fois que la valeur de la *Cusum* franchit $seuil_2$. Notons k_{seg} cet instant et numérotons ce dernier segment (ou segment courant) ic . A cet instant, le segment courant n'est pas complètement défini, car son instant de fin n'est pas encore connu. Celui-ci ne sera connu qu'à la prochaine segmentation. Par contre, le segment précédent, $ic-1$ est, lui, définitivement connu. Il est défini par :

$$\text{Segment } ic-1: \{ k_0^{ic-1}, y_0^{ic-1}, k_{fin}^{ic-1}, y_{fin}^{ic-1} \}$$

$$\text{Avec : } k_{fin}^{ic-1} = k_0^{ic} - Ts$$

$$\text{et : } y_{fin}^{ic-1} = p^{ic-1} \cdot (k_{fin}^{ic-1} - k_0^{ic-1}) + y_0^{ic-1}$$

Les étapes de classification, transformation en épisodes semi-qualitatifs puis agrégation peuvent être effectuées dans un premier temps sur le segment $ic-1$. La tendance définitive est extraite jusqu'à la fin du segment précédent, soit k_{fin}^{ic-1} .

Afin d'extraire la tendance jusqu'à l'instant k_{seg} , le segment courant est temporairement défini par :

$$\text{Segment } ic: \{ k_0^{ic}, y_0^{ic}, k_{seg}, y_{fin}^{ic} \}$$

$$\text{avec : } y_{fin}^{ic} = p^{ic} \cdot (k_{seg} - k_0^{ic}) + y_0^{ic}$$

Les étapes de classification, transformation en épisodes semi-qualitatifs puis agrégation sont ensuite effectuées sur le segment courant afin d'extraire la tendance temporaire jusqu'à k_{seg} . Celle-ci est dite temporaire, car la fin du segment courant n'est pas encore connue. Plus tard, quand une nouvelle approximation linéaire sera calculée, le segment courant ic deviendra le segment précédent et sera complètement défini. Il sera agrégé pour former la tendance définitive

jusqu'à l'instant k_{fin}^{ic} et une tendance temporaire sera calculée à partir du nouveau segment. La Figure 6 illustre le fonctionnement en ligne.

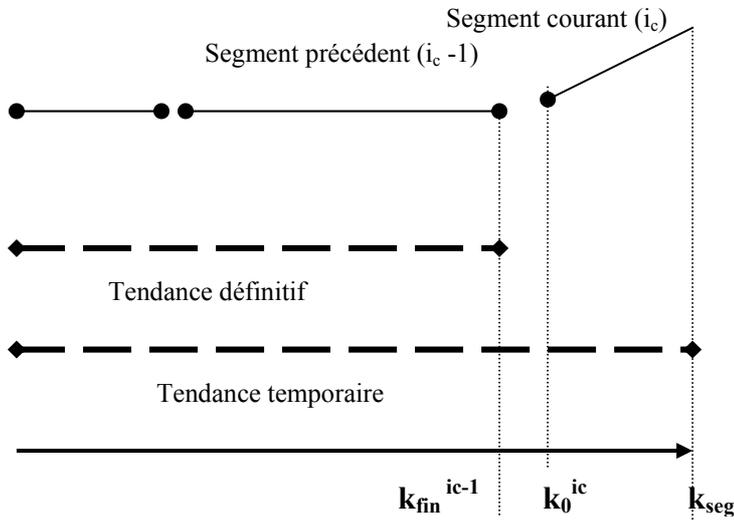


Figure 6 : Extraction en ligne de la tendance : tendance définitive et tendance temporaire

La méthode a été mise en œuvre avec Matlab, version 6.5. Elle fonctionne en ligne et permet d'extraire la tendance sur plusieurs signaux simultanément. Les figures 7 et 8 présentent l'interface qui a été réalisée pour suivre l'évolution de la tendance extraite sur trois variables physiologiques enregistrées sur patients en réanimation, la pression artérielle systolique, le taux de saturation pulsée en oxygène (SpO_2), et la fréquence cardiaque, enregistrés chaque seconde. La partie de gauche représente la tendance extraite (lignes continues) superposée au signal. La flèche visualise l'instant où le dernier segment a été calculé (k_{seg}). Les lignes pointillées représentent les segments et leurs extrapolations, calculés par l'algorithme de segmentation. La partie de droite présente l'interprétation de la tendance, à l'aide de termes linguistiques. Les deux figures correspondent à deux instantanés, le premier pris à un temps $t_0=345s$ (Figure 7) et l'autre pris 30 secondes plus tard (Figure 8).

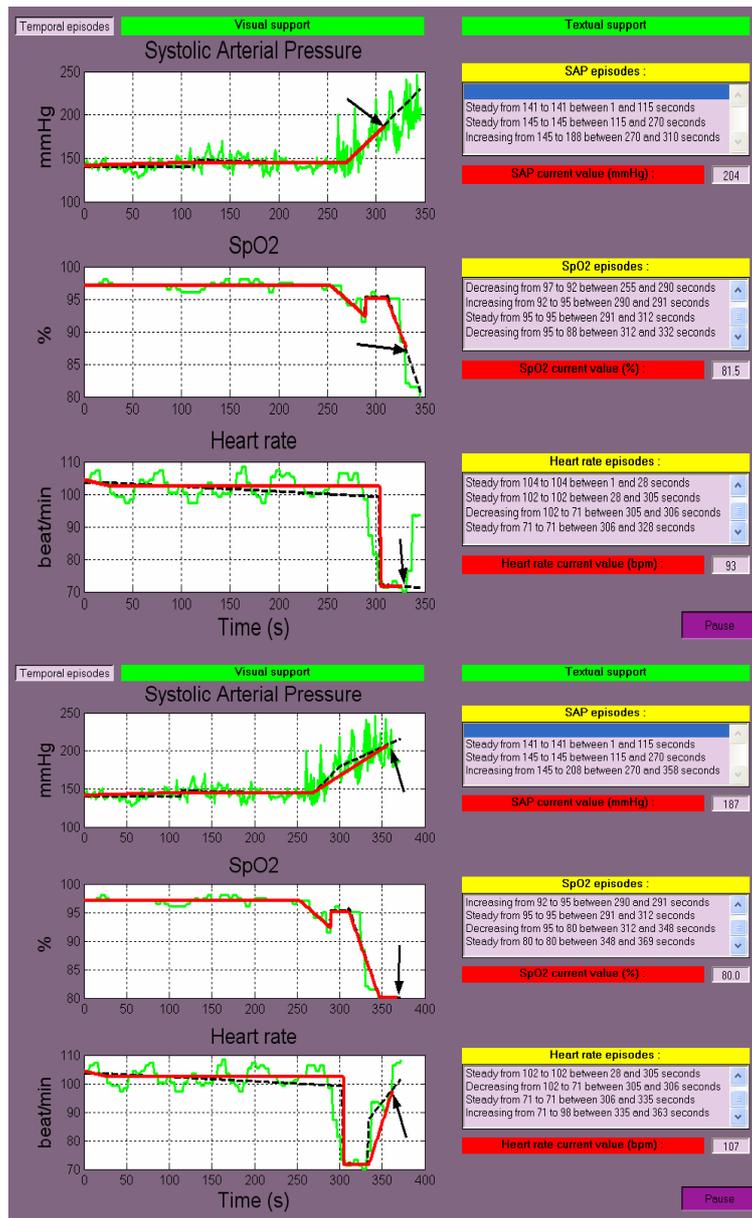


Figure 7 et Figure 8 : Interface de visualisation de tendance extraits sur trois variables simultanément. Instantanés à $t=345s$ puis à $t=375s$

2.3.1.4. Exemple sur signaux réels

La Figure 9 présente la tendance extraite de trois paramètres physiologiques - saturation pulsée en oxygène (SpO_2), fréquence cardiaque, volume expiré - enregistrés toutes les 5 secondes pendant environ 3 heures 30 sur un patient adulte hospitalisé en réanimation. Le patient est en phase de sevrage d'assistance respiratoire. De l'instant $k_0=1500$ périodes d'échantillonnage jusqu'à l'instant $k_1=1700$ périodes d'échantillonnage, le patient est sous assistance respiratoire, connecté à un respirateur artificiel. A l'instant $k_1=1700$ périodes d'échantillonnage, il est déconnecté du respirateur artificiel. Le signal de volume expiré n'est alors plus accessible. A l'instant $k_2=3040$ périodes d'échantillonnage, le patient est reconnecté au respirateur artificiel car le sevrage a échoué. Ceci est mis en évidence par la saturation pulsée en oxygène (paramètre indicateur de la bonne oxygénation des tissus) que le patient n'arrive pas à maintenir seul au-dessus de 95%.

La tendance extraite met en évidence un état stable du patient jusqu'à l'instant k_1 . Juste après la déconnection du respirateur, un transitoire (décroissant-croissant) est détecté sur la saturation

pulsée en oxygène associé à une augmentation de la fréquence cardiaque. Une chute très lente de la saturation pulsée en oxygène est ensuite mise en évidence, simultanée à une augmentation très lente de la fréquence cardiaque du patient. La saturation pulsée en oxygène décroît de 98% à 95% en 650 périodes d'échantillonnage environ (soit en près d'une heure), ce qui correspond à une pente de 0.05% par minute. La fréquence cardiaque croît de 88 à 102 battements par minute (bpm) en 1500 périodes d'échantillonnage (c'est à dire environ 2 heures), soit avec une augmentation de 0.11 bpm par minute. Ces deux dérives lentes sont correctement détectées par la méthode d'extraction de tendance.

Ensuite, à l'instant $k_3=3000$ périodes d'échantillonnage, la saturation pulsée en oxygène décroît brutalement de 95% à 82% en 5 minutes et passe en situation d'alarme. Ceci est détecté sur la tendance par trois épisodes successifs {décroissant de 94% à 90% - stable à 90% - décroissant de 90% à 82%}. Le patient est alors immédiatement reconnecté au respirateur ce qui engendre une augmentation rapide de la saturation pulsée en oxygène jusqu'à 97%, détectée par un unique épisode croissant. Des changements de réglage du respirateur ainsi qu'une aspiration trachéale génèrent des transitoires sur la saturation pulsée en oxygène, détectés par des épisodes décroissant/croissant. Pendant l'enregistrement, les données sont parfois manquantes. Celles-ci sont repérées par des triangles sur la figure. La méthode fonctionne correctement malgré l'absence de données.

La Figure 9 illustre la capacité de la méthode d'extraction de tendance à mettre en évidence des changements sur les signaux, qu'ils soient rapides ou lents. La dérive lente de la saturation pulsée en oxygène associée à l'augmentation de la fréquence cardiaque qui précède l'épisode de désaturation (chute de la saturation pulsée en oxygène sous 90%) est maintenant évidente alors qu'elle n'a pas été détectée par les médecins lors de la phase de sevrage du patient.

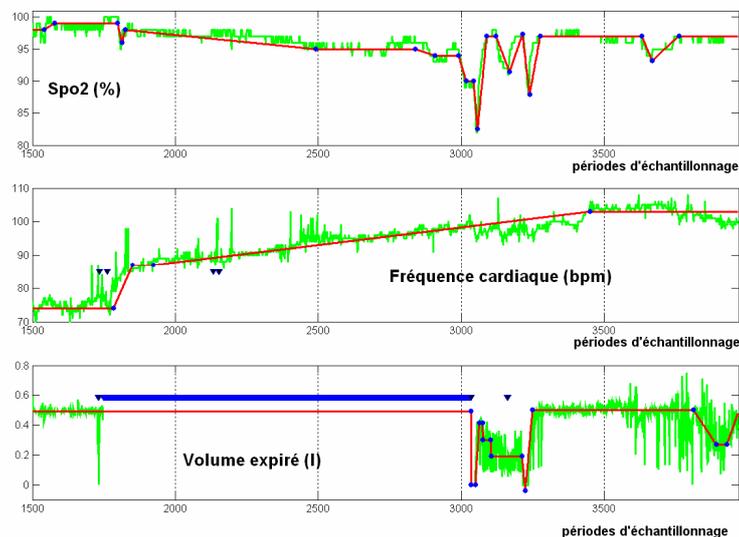


Figure 9 : Extraction de tendance sur signaux réels enregistrés sur un patient hospitalisé en unité de réanimation

2.3.2. Modifications apportées

Dans ce paragraphe, nous allons détailler les améliorations apportées à la version initiale de la méthode : l'agrégation des épisodes 3 à 3 et l'adaptation en ligne des paramètres de réglage, $seuil_1$, $seuil_2$ et $seuil_c$.

2.3.2.1. Agrégation 3 à 3

L'algorithme d'agrégation présenté dans le paragraphe précédent réalise l'agrégation de deux épisodes successifs. A la suite de cette agrégation, deux épisodes consécutifs ne peuvent pas être décrits par la même primitive. Cependant, un épisode de primitive différente peut venir s'intercaler entre deux épisodes de mêmes primitives. Afin de déterminer si l'épisode intercalé a une pertinence et l'éliminer sinon, il est nécessaire de réaliser une agrégation d'épisodes 3 à 3. Ainsi, nous avons ajouté, à la suite des 4 étapes successives qui forment la base de la méthode, un algorithme d'agrégation qui agrège en un seul épisode certaines suites de 3 épisodes. Deux cas sont à étudier : les successions d'épisodes *croissant-stable-croissant* et *croissant-décroissant-croissant*. Les autres cas, *décroissant-stable-décroissant* et *décroissant-croissant-décroissant* s'obtiennent par symétrie.

2.3.2.1.1. Suite d'épisodes : *croissant-stable-croissant*

Une règle d'agrégation a été arbitrairement choisie : tout épisode stable intercalé entre deux épisodes de même primitive est éliminé si sa durée est inférieure à une durée D. Cette règle est fondée sur le fait qu'un épisode stable n'a de sens pour la dynamique du signal que sa longueur est suffisante. Dans le cas de la surveillance de patients hospitalisés en réanimation, nous avons fixé la valeur de D à 120 secondes, soit 2 minutes.

La succession d'épisodes [*croissant*; k_{deb}^{i-2} , y_{deb}^{i-2} , k_{fin}^{i-2} , y_{fin}^{i-2}], [*stable*; k_{deb}^{i-1} , y_{deb}^{i-1} , k_{fin}^{i-1} , y_{fin}^{i-1}], [*croissant*; k_{deb}^i , y_{deb}^i , k_{fin}^i , y_{fin}^i] est agrégée en [*croissant*; k_{deb}^{i-2} , y_{deb}^{i-2} , k_{fin}^i , y_{fin}^i].

2.3.2.1.2. Suite d'épisodes : *croissant-décroissant-croissant*

Pour ce type de suite, il est difficile de proposer une règle d'agrégation expliquant les différents cas où les épisodes doivent être agrégés. Par contre, il est aisé pour un observateur de déterminer visuellement, en fonction de la forme décrite par les 3 épisodes, si une suite d'épisodes correspond à une unique séquence croissante et doit être agrégée. Ainsi, nous avons élaboré un modèle d'agrégation à l'aide de techniques de reconnaissance de formes. Une base d'exemples a été créée de la manière suivante. Une forme correspondant à une suite d'épisodes *croissant-décroissant-croissant* était présentée sur un écran à un observateur qui donnait son avis : « à agréger car traduit une seule séquence croissante » ou « à ne pas agréger ». La base finale est constituée de 400 exemples, dont 283 exemples négatifs (à ne pas agréger) et 117 exemples positifs (à agréger).

Les caractéristiques utilisées pour décrire une suite d'épisode sont :

$$A1, \text{l'amplitude du 1}^{\text{er}} \text{ épisode : } A1 = (\text{abs}(y_{fin}^{i-2} - y_{deb}^{i-2}))$$

$$A2, \text{l'amplitude du 2}^{\text{ème}} \text{ épisode : } A2 = (\text{abs}(y_{fin}^{i-1} - y_{deb}^{i-1}))$$

$$A3, \text{l'amplitude du 3}^{\text{ème}} \text{ épisode : } A3 = (\text{abs}(y_{fin}^i - y_{deb}^i))$$

$$T1, \text{la durée du 1}^{\text{er}} \text{ épisode : } T1 = k_{fin}^{i-2} - k_{deb}^{i-2}$$

$$T2, \text{la durée du 2}^{\text{ème}} \text{ épisode : } T2 = k_{fin}^{i-1} - k_{deb}^{i-1}$$

$$T3, \text{la durée du 3}^{\text{ème}} \text{ épisode : } T3 = k_{fin}^i - k_{deb}^i$$

Le vecteur forme est composé des six caractéristiques normalisées :

$$\left[\frac{A1}{\max(A1, A2, A3)}, \frac{A2}{\max(A1, A2, A3)}, \frac{A3}{\max(A1, A2, A3)}, \frac{T1}{\max(T1, T2, T3)}, \frac{T2}{\max(T1, T2, T3)}, \frac{T3}{\max(T1, T2, T3)} \right]$$

Les amplitudes sont exprimées en pourcentage du plus ample épisode et les durées sont exprimées en pourcentage du plus long épisode. Ainsi, le modèle d'agrégation appris est totalement indépendant de l'ordre de grandeur ou de la dynamique du signal dont on extrait la tendance.

Un classificateur de type réseau de neurones (Perceptron Multi Couches) a été entraîné sur une base d'apprentissage composée de 200 exemples, 57 positifs et 143 négatifs. Le réseau de neurones est composé d'une couche d'entrée formée de 6 neurones, d'une couche cachée formée de 3 neurones, dont les fonctions d'activation sont des tangentes hyperboliques et d'une couche de sortie formée de 1 neurone, dont la fonction d'activation est une fonction de Heavyside.

Les résultats obtenus sur la base de test, composée de 200 nouveaux exemples, 60 positifs et 140 négatifs, montrent que le réseau de neurones est capable de classer correctement 98% des exemples. 1 exemple parmi les 60 exemples positifs a été classé en « à ne pas agréger » et 3 exemples parmi les 140 exemples négatifs ont été classés en « à agréger ».

Ainsi, suite à l'agrégation 2 à 2, toute suite d'épisode [*croissant*; $k_{deb}^{i-2}, y_{deb}^{i-2}, k_{fin}^{i-2}, y_{fin}^{i-2}$], [*décroissant*; $k_{deb}^{i-1}, y_{deb}^{i-1}, k_{fin}^{i-1}, y_{fin}^{i-1}$], [*croissant*; $k_{deb}^i, y_{deb}^i, k_{fin}^i, y_{fin}^i$] est agrégée en [*croissant*; $k_{deb}^{i-2}, y_{deb}^{i-2}, k_{fin}^i, y_{fin}^i$] si la décision prise par le réseau de neurones est positive.

2.3.2.2. Adaptation en ligne des paramètres de réglage, *seuil₁*, *seuil₂* et *seuil_c*.

Dans la version initiale de l'extraction de tendance, la valeur des trois paramètres de réglage *seuil₁*, *seuil₂* et *seuil_c* est constante et ne dépend que du signal traité. Ainsi, les paramètres permettant d'extraire la tendance sur les signaux physiologiques enregistrés sur des patients de réanimation sont fixés en fonction des paramètres physiologiques enregistrés. Ils gardent les mêmes valeurs quel que soit l'enregistrement et quel que soit le patient ; ils ne sont pas réglés en début d'enregistrement, l'hypothèse sous-jacente étant que le bruit s'ajoutant sur un paramètre physiologique ne dépend pas du patient mais du paramètre enregistré.

Or, dans la pratique, cette hypothèse n'est pas toujours vérifiée. La variance de certains signaux peut varier fortement. C'est le cas des paramètres physiologiques dont la variance peut changer en fonction du contexte de soins délivrés au patient (mode de ventilation par exemple), ou encore de la délivrance de médicaments (qui peut avoir une incidence sur la variabilité cardiaque, par exemple). La variance peut donc changer d'un patient à l'autre, mais aussi en fonction du temps, pour le même patient. L'information à extraire sur la dynamique du signal à l'aide de la tendance est liée la variance du signal. En effet, une augmentation de faible amplitude peut être significative si la variance du signal est très faible et devenir non significative si la variance est plus forte.

Afin de prendre en compte ce changement de variance sur les paramètres, nous avons développé une version adaptative de la méthode d'extraction de tendance. Les seuils *seuil₁*, *seuil₂* et *seuil_c* ne sont plus fixes, mais s'adaptent en ligne en fonction de la variance du signal.

2.3.2.2.1. Influence des paramètres de réglage de la méthode

La méthode d'extraction de tendance est réglée par trois paramètres, $seuil_1$, $seuil_2$ et $seuil_c$. Les deux paramètres $seuil_1$ et $seuil_2$ influent sur la décomposition en segments de droite. Le paramètre $seuil_c$ influe sur la classification des formes, et donc sur les primitives associées aux épisodes.

D'après l'algorithme de segmentation, le paramètre $seuil_1$ est un indicateur de la qualité d'approximation du signal par la droite. Il doit être réglé en fonction du niveau de bruit qui affecte le signal. Une analyse de sensibilité a pu montrer que la méthode était peu sensible à ce paramètre dans la mesure où sa valeur restait de l'ordre de l'écart type du bruit. L'algorithme de segmentation opère un filtrage passe-bas sur le signal dont la fréquence de coupure dépend de $seuil_2$. Si $seuil_2$ est petit, les segments calculés sont plus courts et le signal segmenté peu filtré. A l'inverse, si $seuil_2$ est grand, le temps nécessaire à la détection d'un changement est plus important, et certains transitoires importants peuvent être filtrés. Le paramètre $seuil_c$ dépend de l'ordre de grandeur du signal dont on veut extraire la tendance. Il fixe la valeur minimale à partir de laquelle une variation est considérée comme significative sur le signal et doit être interprétée comme croissante ou décroissante. Une valeur trop faible de $seuil_c$ génère une succession d'épisodes croissants et décroissants, qui correspondent à une interprétation des variations dues au bruit. A l'inverse, une valeur de $seuil_c$ trop importante entraîne la non détection de variations significatives sur le signal.

Il est possible de caractériser les types de transitoires qui sont filtrés par la méthode en fonction de $seuil_2$ et $seuil_c$.

Un transitoire de type créneau, d'amplitude A et de durée D, est filtré par la méthode d'extraction de tendance si :

$$A < seuil_c \text{ (l'amplitude de la variation est considérée comme non significative)}$$

ou si

$$A.D < seuil_2 \text{ (l'intégrale du transitoire est inférieure au seuil déclenchant la segmentation).}$$

Un transitoire de type rampe, de pente α et de durée T est filtré si :

$$\alpha.T < seuil_c \text{ (l'amplitude de la variation est considérée comme non significative)}$$

ou si

$$\frac{1}{2}\alpha T^2 < seuil_2 \text{ (l'intégrale du transitoire est inférieure au seuil déclenchant la segmentation).}$$

2.3.2.2.2. Adaptation des paramètres de réglage de la méthode

Les 3 paramètres de réglage de la méthode sont modifiés en ligne en fonction de l'écart type estimé du signal (la racine carrée de la variance).

2.3.2.2.2.1. Estimation de l'écart type du signal

L'écart type du signal est estimé à l'aide du résidu, défini par **Eq.6**. Le résidu est un signal non stationnaire, de moyenne a priori nulle, mais dont la variance varie au cours du temps. Il contient la partie du signal non explicitée par l'approximation linéaire. L'écart type du résidu est estimé à chaque période d'échantillonnage, sur une fenêtre temporelle glissante de taille fixe N, par l'équation **Eq. 11**.

$$m_k = \frac{1}{N} \sum_{i=k-N}^k Re s_i \tag{Eq. 10}$$

$$\sigma_{res_k} = \sqrt{\frac{1}{N-1} \sum_{i=k-N}^k (Res_i - m_k)^2} \quad \text{Eq. 11}$$

N est fixée à 60 périodes d'échantillonnage (ie 60 s). C'est une durée suffisamment courte pour que l'hypothèse de stationnarité du signal reste plausible et suffisamment longue pour obtenir une estimation peu biaisée de l'écart type.

L'estimation de l'écart type moyen est effectué par calcul de la valeur médiane des écarts types calculés à chaque période d'échantillonnage, sur une fenêtre d'apprentissage de x périodes d'échantillonnage (Eq. 12). Ceci permet de filtrer les augmentations d'écart type dues à des artéfacts perturbant le signal. D'après Eq. 11, tout artéfact sur le signal provoque une augmentation importante de l'écart type sur une durée égale à la taille de la fenêtre, N. Le filtre médian calculé sur une fenêtre de durée x périodes d'échantillonnage a la propriété de filtrer toute variation transitoire de durée inférieure à la moitié de la taille de la fenêtre. Ainsi, la taille minimale pour x permettant de filtrer l'effet d'un artéfact sur le signal est 2N+1.

$$Mx_k = \text{mediane}_{i=k-x:k}(\sigma_{res_i}) \quad \text{Eq. 12}$$

La taille de la fenêtre, x, a été choisie égale à 300 périodes d'échantillonnage. C'est un compromis entre la durée de l'information passée à prendre en compte et la sensibilité de la mesure Mx à des artéfacts sur le signal, qui sont d'autant mieux filtrer que la période d'apprentissage est longue. Dans ce cas, l'estimation de l'écart type reste insensible à la présence de deux artéfacts affectant le signal pendant la période de temps x.

2.3.2.2.2. Adaptations des paramètres

L'adaptation des paramètres est réalisée à chaque nouvelle segmentation du signal. Soit k_{seg} , l'instant où l'algorithme de segmentation calcule une nouvelle approximation linéaire. Le calcul du résidu est effectué jusqu'à k_{seg} et l'écart type médian du signal est estimé par $Mx_{k_{seg}}$. Deux fonctions d'adaptation ont été proposées, une définie par un cycle d'hystérésis, l'autre par une fonction linéaire de l'écart type.

Adaptation par cycle d'hystérésis

La fonction d'adaptation est un cycle d'hystérésis (Figure 10). 2 jeux de seuils $\{seuil_1, seuil_2, seuil_c\}_{important}$ et $\{seuil_1, seuil_2, seuil_c\}_{faible}$ sont applicables à l'algorithme. Ils correspondent aux jeux de réglage à appliquer quand l'écart type du résidu est faible et quand il est plus important. $\{seuil_1, seuil_2, seuil_c\}_{important}$ correspondent aux valeurs de seuils proposés dans [CHA 05c]. $\{seuil_1, seuil_2, seuil_c\}_{faible}$ correspondent aux valeurs de $\{seuil_1, seuil_2, seuil_c\}_{important}$ divisées par 2.

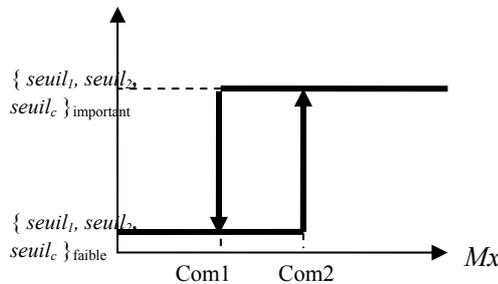


Figure 10 : fonction d'adaptation des seuils $seuil_1$, $seuil_2$, et $seuil_c$

Diviser $seuil_2$ par 2 permet de moins filtrer le signal en segmentant des transitoires dont l'aire est 2 fois plus petite (transitoire de type créneau de durée deux fois plus faible ou d'amplitude deux fois plus faible). Diviser $seuil_c$ par 2 permet de détecter des changements d'amplitude 2 fois plus faible.

L'utilisation d'un cycle d'hystérésis permet de limiter des alternances répétées entre les 2 jeux de réglages, quand la mesure de Mx est proche du seuil de commutation.

Choix des seuils de commutation

L'écart type d'un signal dépend de son ordre de grandeur. Dans le cadre de la surveillance de patients en réanimation, 10 paramètres physiologiques sont enregistrés. Afin de ne pas augmenter trop fortement le nombre de seuils à régler sur l'algorithme, les seuils de commutation ($Com1$ et $Com2$) du cycle d'hystérésis ont été normalisés pour chaque paramètre physiologique, à partir de la fonction de répartition de l'écart type des différents paramètres.

Celle-ci a été estimée à partir d'un ensemble d'enregistrements obtenus sur une vingtaine de patients différents. L'écart type du signal a été estimé à chaque période d'échantillonnage à l'aide de l'équation **Eq. 11** sur une fenêtre glissante de 60 périodes d'échantillonnage, sur tous les enregistrements. L'ensemble des mesures d'écart type calculées sur chaque enregistrement pour un paramètre donné a été mis en commun et un tirage aléatoire a été effectué. Un sous-ensemble constitué du quart des valeurs de la base de données a été réalisé et a servi à estimer la fonction de répartition de l'écart type. La valeur correspondante au 95^{ème} percentile a été relevée pour chaque paramètre. Les seuils de commutation du cycle d'hystérésis ont été choisis à 15% et 25% de la valeur du 95^{ème} percentile pour chaque paramètre physiologique.

Le jeu $\{seuil_1, seuil_2, seuil_c\}_{faible}$ est appliqué à l'initialisation de l'algorithme et est maintenu tant que la valeur de Mx ne dépasse pas 25% du 95^{ème} percentile. Quand la commutation vers le jeu $\{seuil_1, seuil_2, seuil_c\}_{important}$ a eu lieu, le jeu sera maintenu jusqu'à ce que la valeur de Mx devienne inférieure à 15% du 95^{ème} percentile.

Exemple sur signal réel

Un exemple de fonctionnement de l'algorithme est présenté Figure 11. Pendant la première phase de l'enregistrement, le patient est endormi, puis il s'éveille. Un changement significatif de l'écart type de la pression artérielle systolique et donc du résidu peut être observé. La valeur des paramètres de réglage commute automatiquement du jeu associé à l'écart type faible au jeu associé à l'écart type élevé. Un changement de faible amplitude est détecté dans la première partie de l'enregistrement alors qu'un changement de même amplitude est filtré dans la seconde partie.

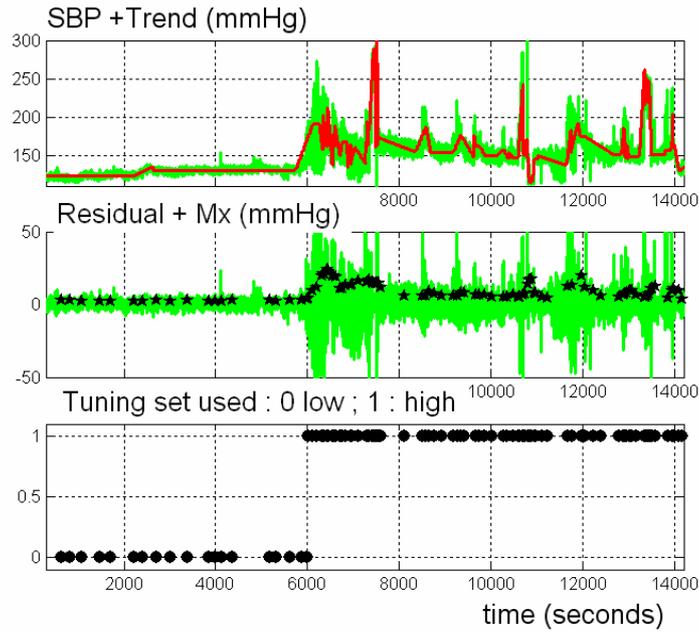


Figure 11 : Tendence extraite par la méthode adaptative utilisant un cycle d’hystérésis. La figure du haut présente la pression artérielle systolique enregistrée sur un patient pendant 4 heures et la tendance extraite. La figure du milieu montre le résidu et la valeur de Mx calculée à chaque nouvelle segmentation. La figure du bas montre le jeu de paramètres sélectionné par l’algorithme (faible ou important) à chaque nouvelle segmentation.

Adaptation par une fonction paramétrique

Les valeurs des paramètres de réglage de la méthode sont recalculées à chaque segmentation, à l’aide des fonctions suivantes :

$$seuil_c = \begin{cases} seuil_{c\ max} & \text{si } l.Mx_{k_{seg}} \geq seuil_{c\ max} \\ l.Mx_{k_{seg}} & \text{si } seuil_{c\ min} < l.Mx_{k_{seg}} < seuil_{c\ max} \\ seuil_{c\ min} & \text{si } l.Mx_{k_{seg}} \leq seuil_{c\ min} \end{cases} \quad \text{Eq. 13}$$

$seuil_c$ est une fonction linéaire de l’écart type. Nous avons fixé la valeur du paramètre l à 3, ce qui signifie que toute variation supérieure à 3 fois l’écart type du signal est considérée comme significative. Si l’on suppose que le signal est stationnaire par morceaux et que le bruit perturbant le signal est blanc gaussien d’écart type Mx , la variation détectée correspond à un changement significatif du signal avec une confiance de 95%. Deux bornes, une supérieure et une inférieure sont proposées. La borne inférieure fixe la valeur minimale à partir de laquelle une variation peut être considérée comme significative. Elle permet d’éviter la détection de variations de très faible amplitude quand l’écart type du signal est proche de zéro. A l’inverse, la borne supérieure permet de détecter des changements même quand l’écart type estimé a une valeur très élevée.

De la même manière, $seuil_2$ est calculée par :

$$seuil_2 = \begin{cases} seuil_{2\ max} & \text{si } \Delta.l.Mx_{k_{seg}} \geq seuil_{2\ max} \\ \Delta.l.Mx_{k_{seg}} & \text{si } seuil_{2\ min} < \Delta.l.Mx_{k_{seg}} < seuil_{2\ max} \\ seuil_{2\ min} & \text{si } \Delta.l.Mx_{k_{seg}} \leq seuil_{2\ min} \end{cases} \quad \text{Eq. 14}$$

$seuil_2$ est une fonction de $seuil_c$ et du délai fixé pour la détection, Δ . Toute variation de type créneau d’amplitude $seuil_c$ est détectée si sa durée est supérieure à Δ périodes d’échantillonnage.

Enfin, $seuil_1$ est calculée par

$$seuil_1 = \begin{cases} seuil_{1max} & \text{si } \frac{Mx_{k_{seg}}}{2} \geq seuil_{1max} \\ \frac{Mx_{k_{seg}}}{2} & \text{si } seuil_{1min} < \frac{Mx_{k_{seg}}}{2} < seuil_{1max} \\ seuil_{1min} & \text{si } \frac{Mx_{k_{seg}}}{2} \leq seuil_{1min} \end{cases} \quad \text{Eq. 15}$$

de manière à ce que sa valeur reste toujours inférieure à la valeur de l'écart type du signal.

La tendance extraite sur le même enregistrement de pression artérielle systolique que celui de la Figure 11 est présentée Figure 12. Les valeurs prises par les paramètres de réglage augmentent fortement durant la 2^{ème} partie de l'enregistrement et vont même parfois jusqu'à saturer. Les variations de la pression artérielle systolique sont correctement décrites par la tendance. Celle-ci est plus filtrée car les valeurs prises par $seuil_2$ sont plus élevées que celles prises quand la fonction d'adaptation est un cycle d'hystérésis.

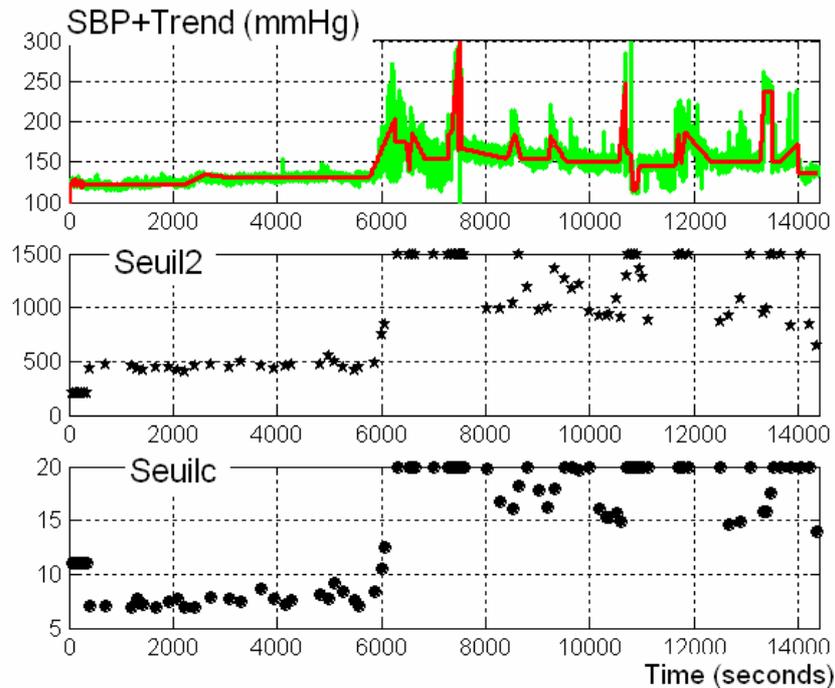


Figure 12: Tendance extraite par la méthode adaptative utilisant une fonction d'adaptation linéaire. La figure du haut présente la pression artérielle systolique enregistrée sur un patient pendant 4 heures et la tendance extraite. La figure du milieu et celle du bas montrent les valeurs prises par $seuil_2$ et $seuil_c$ à chaque nouvelle segmentation.

2.3.2.2.3. Comparaison entre les deux méthodes

Une analyse visuelle des résultats sur un ensemble d'enregistrements montre que les résultats obtenus à l'aide des deux méthodes sont satisfaisants. Les variations significatives sont correctement détectées.

Les hypothèses sous-jacentes aux fonctions d'adaptation des deux méthodes sont différentes. La première, utilisant un cycle d'hystérésis, suppose deux états possibles pour le patient : un état où

la variabilité du signal est faible et un autre où elle est plus importante. Ces états correspondent soit à des états physiologiques (le patient est endormi, du fait d'une sédation, ou non), soit à un contexte de soins (le patient est ventilé en mode contrôlé, ou en mode assisté). L'écart type du signal permet de déterminer de manière automatique l'état dans lequel se trouve le patient.

La deuxième fonction d'adaptation considère qu'une variation est significative si cette variation est supérieure au niveau de bruit. Si le niveau de bruit, estimé par l'écart type des résidus, est élevé, alors la variation doit être d'amplitude élevée pour être détectée. Le signal devient sa propre référence pour détecter si une tendance est croissante, décroissante ou stable. Le terme croissant ou décroissant n'a plus une signification absolue comme pour l'adaptation par cycle d'hystérésis (la variation est supérieure à une valeur donnée) mais prend une signification relative (significatif par rapport à).

Dans la suite de ce travail, nous avons choisi de travailler avec la méthode d'adaptation par cycle d'hystérésis. En effet, il nous semble que la deuxième méthode ôte un peu de son pouvoir explicatif à la tendance car les épisodes croissants ou décroissants sont plus difficilement interprétables.

2.3.3. Conclusion sur la méthode d'extraction de tendance

La méthode développée permet d'extraire en ligne la tendance d'un signal. L'information fournie est semi-qualitative : l'évolution temporelle est décrite à l'aide de termes symboliques, mais la valeur du signal aux extrémités des épisodes est conservée. La méthode ne nécessite pas de filtrage préalable des données et peut gérer les données manquantes. Elle met en évidence les ruptures de type échelon dans le signal. Le classement en primitives stable, croissant, décroissant est effectué à partir de l'accroissement mesuré au cours d'un épisode, et non pas par la valeur de la pente. Ceci permet une meilleure détection des dérives lentes.

Les inconvénients de la méthode sont les suivants :

Pour la version initiale et la version adaptative par cycle d'hystérésis, il est nécessaire de régler les seuils pour chaque signal, ce qui peut constituer un handicap pour les procédés sur lesquels un grand nombre de variables est surveillé. La version adaptative avec adaptation des seuils par une fonction paramétrique constitue une amélioration pour ces procédés.

La détection des instants de début et de fin des épisodes n'est pas très précise. Ces instants dépendent des segments générés par l'algorithme de segmentation. Une modification des seuils de segmentation peut donc modifier sensiblement les instants de début et de fin d'épisodes, en particulier pour les signaux fortement bruités.

La tendance est décrite par trois primitives, ce qui permet une bonne description des signaux linéaires par morceaux. Si l'évolution d'une variable est de type quadratique, (augmentation faible puis plus rapide ensuite), la méthode la décrit par un seul épisode croissant. La représentation par superposition de la tendance sur le signal montre alors une nette différence entre les deux, ce qui peut surprendre un observateur.

2.4. Aide à la surveillance de patients hospitalisés en réanimation par analyse de tendances

La tendance extraite offre une aide visuelle pour l'analyse des signaux. Les changements temporels dans les signaux sont mis en évidence par les épisodes croissants et décroissants. Mais la tendance, de par la transformation numérique symbolique qu'elle réalise, peut aussi servir de support à des systèmes de diagnostic.

Comme nous l'avons précisé en introduction, la surcharge cognitive dont souffre le personnel soignant vient de la quantité d'information à analyser suite à une alarme ainsi que du grand nombre de fausses alarmes se déclenchant dans ces services. Tout système facilitant l'analyse de la situation et filtrant certaines fausses alarmes permet d'alléger la charge cognitive du personnel soignant. Dans cette optique, la tendance extraite des signaux a été utilisée afin :

- de reconnaître de manière automatique, à partir des signaux, certaines situations ou évènements survenant sur les patients

- de construire des indices de changement temporel sur les signaux, permettant de mettre en évidence, à l'aide d'un code de couleur allant du vert au rouge, les périodes stables et les périodes instables du patient. Le terme «instable» fait référence au vocabulaire utilisé par les médecins pour caractériser l'état d'un patient.

- de proposer un système de déclenchement d'alarmes moins sensibles aux variations transitoires perturbant les signaux

- de filtrer les alarmes de saturation pulsée en oxygène, SpO_2 , par analyse conjointe des autres variables physiologiques, et diminuer ainsi le taux de fausses alarmes associé à ce paramètre.

Dix paramètres physiologiques, enregistrés chaque seconde sur un patient, ont été considérés dans la suite de ce travail : la pression artérielle systolique (PAS), diastolique (PAD) et moyenne (PAM), la saturation pulsée en oxygène (SpO_2), la fréquence cardiaque (FC), la pression maximale dans les voies aériennes (Pmax), la fréquence respiratoire (FR), la ventilation minute (VM), le volume expiré (VT), le débit maximal dans les voies aériennes (Dmax).

La validation des travaux a été effectuée sur une base de données documentée composée de 25 enregistrements, effectués sur 23 patients hospitalisés dans l'unité de réanimation Nord de l'hôpital Lyon-Sud. Chaque enregistrement dure 2 ou 4 heures. 18 patients sont ventilés mécaniquement en mode débit contrôlé. Parmi ces 18, 15 sont sédatisés et 3 sont en levée de sédation. 10 patients sont ventilés en mode assisté et sont en phase de sevrage du respirateur. Un observateur externe au service de réanimation est resté près du patient et a noté tous les évènements cliniques pertinents survenant au cours du recueil des signaux (soins infirmiers, alarmes, visites, modification de thérapie ...)

2.4.1. Détection automatique d'évènements à partir d'une analyse multivariable des paramètres physiologiques

La détection automatique d'évènements consiste à reconnaître sur les signaux la signature de l'occurrence d'un évènement. La signature de l'évènement est décrite à l'aide d'un modèle défini à partir des épisodes formant la tendance et des résidus. Le modèle décrit une forme temporelle multivariable. Une succession d'épisodes extraits sur un signal permet de décrire une forme

temporelle monovariante complexe. L'apparition simultanée de formes temporelles monovariantes sur différents signaux correspond à une forme multivariante. La procédure de détection est réalisée par « pattern matching » : un événement est reconnu quand la tendance et le résidu extraits sur les paramètres physiologiques matchent les entrées du modèle ([CHA 06a]).

A titre d'exemples, trois types d'événements ont été modélisés :

- un artéfact sur la pression artérielle due à un flush sur le cathéter artériel
- une aspiration trachéale
- un changement d'état du patient.

2.4.1.1. Modélisation des événements

Nous allons dans un premier temps donner un ensemble de définitions nécessaires à la description d'un modèle, puis décrire les modèles associés aux trois événements à reconnaître.

2.4.1.1.1. Définitions

2.4.1.1.1.1. Amplitude et durée d'un épisode :

Un épisode est défini sur l'intervalle de temps $[k_d \dots k_f]$ par l'équation **Eq. 1**. Son amplitude et sa durée sont définis comme suit :

$$Amp = |y_f - y_d| \quad \text{Eq. 16}$$

$$Dur = k_f - k_d \quad \text{Eq. 17}$$

2.4.1.1.1.2. Episode instable :

L'information numérique fournie par le résidu est transformée en information symbolique de la manière suivante : l'écart type du résidu est calculé sur une fenêtre glissante de 60 périodes d'échantillonnage à l'aide de l'équation **Eq. 11**. Si celui-ci est supérieur à la valeur du 95^{ème} percentile de la fonction de répartition de l'écart type (le calcul de cette valeur a été explicitée au paragraphe 2.3.2.2.2.2), celui-ci est instable. Un résidu successivement instable sur une durée supérieure à 60 périodes d'échantillonnage forme un épisode instable. La notion d'instabilité du signal a été proposée par Calvelo et al. ([CAL 99]).

2.4.1.1.1.3. Episodes concomitants :

Deux épisodes définis sur $[k_{d1} \dots k_{f1}]$ et sur $[k_{d2} \dots k_{f2}]$ sont concomitant(Δ) si $k_{d1} - \Delta \leq k_{f2} \leq k_{f1} + \Delta$ ou si $k_{d2} - \Delta \leq k_{f1} \leq k_{f2} + \Delta$

La période temporelle Δ permet de prendre en compte les imprécisions sur les instants de début et fin des épisodes extraits.

2.4.1.1.1.4. Transitoire décroissant-croissant:

Un transitoire *décroissant-croissant* est une forme temporelle monovariante composée de trois épisodes successifs : $\{stable\}\{croissant\}\{décroissant\}$ ou $\{décroissant\}\{croissant\}\{stable\}$

2.4.1.1.2. Modèles

2.4.1.1.2.1. Flush sur le cathéter artériel

Le modèle s'écrit de la manière suivante :

[PAS ou PAM ou PAD {*croissant*, Amp>80mmHg}] concomitant(10) avec [PAS ou PAM ou PAD {*croissant*, Amp>80mmHg}]

Ainsi, un artefact sur la pression artérielle dû à un flush sur le cathéter est détecté si des épisodes croissants d'amplitude supérieure à 80 mmHg sont détectés simultanément sur au moins deux des trois signaux décrivant la pression artérielle (PAS, PAM, PAD). La période temporelle $\Delta = 10T_s$ permet de prendre en compte les imprécisions sur les instants de début et fin des épisodes extraits. Le nombre de variables matchant le modèle fournit un indice de confiance (2 ou 3).

2.4.1.1.2.2. Aspiration trachéale

Une aspiration trachéale est modélisée par :

[Pmax {*décroissant*, yf<seuil_{Pmax}} ou VE { *décroissant*, yf<seuil_{VE}} ou VM { *décroissant*, yf<seuil_{VM} }]

concomitant(10) avec [Pmax ou VE ou VM ou FR ou Dmax { *transitoire décroissant-croissant* }] ou concomitant(10) avec [Pmax ou VE ou VM ou FR ou Dmax {*instable*}].

Une aspiration trachéale est détectée si un épisode décroissant sous une valeur seuil est détecté sur au moins une variable parmi Pmax, VE ou VM, de manière concomitante avec un épisode instable ou avec un transitoire décroissant-croissant sur Pmax, VE, VM, FR or Dmax.

Un indice de confiance dans la détection est proposé, en ajoutant une valeur à chaque forme temporelle monovariable. Ainsi, un transitoire décroissant_croissant et une instabilité ont une valeur de 1. Une chute a une valeur de 2 si la valeur finale est inférieure à un certain seuil et une valeur de 3 pour un seuil plus petit. La valeur attribuée à un paramètre correspond à la valeur maximale relevée sur ce paramètre. Par exemple, si sur un même paramètre, on observe simultanément une chute sous une valeur seuil et une instabilité, la valeur obtenue sur le paramètre est la valeur de la chute car celle-ci est supérieure à celle de l'instabilité.

Une aspiration trachéale est reconnue si la valeur totale de l'événement (somme des valeurs de tous les paramètres observées simultanément) est d'au moins 3, qu'au moins deux paramètres différents interviennent dans le calcul de la valeur totale et qu'on a détecté au moins une chute sur un paramètre. Ainsi, pour reconnaître une aspiration trachéale, la condition minimale est que soient présents simultanément une chute d'un des paramètres sous une valeur seuil et une instabilité ou un transitoire sur un autre paramètre (valeur totale égale à 3). La valeur maximale pouvant être obtenue est 11, quand on détecte simultanément une chute de Pmax, de VE et de VM et une instabilité ou un transitoire décroissant-croissant sur Dmax et FR.

2.4.1.1.2.3. Changement d'état d'un patient

Un changement d'état est modélisé par :

[Var1 {*stable*, Dur>300s} {*croissant ou décroissant*}] concomitant(30) avec [Var2 {*stable*, Dur>300s} { *croissant ou décroissant* }]

Un changement d'état est reconnu si un épisode croissant ou décroissant précédé d'un épisode stable de longue durée (supérieure à 300 périodes d'échantillonnage soit 5 minutes) est détecté sur au moins deux variables physiologiques différentes pendant la même période de temps. La valeur de la période temporelle Δ vaut ici 30 T_s , afin de prendre en compte les décalages temporels éventuels dus aux liens causaux entre les différentes variables. Le nombre de variables impliquées dans la détection fournit un indice de confiance dans la détection (2 à 10).

2.4.1.2. Résultats obtenus sur données enregistrées sur des patients hospitalisés en réanimation.

La procédure de détection d'évènements a été testée sur les données de la base d'enregistrements décrite page 42. La tendance et le résidu des 10 variables physiologiques considérées ont été extraits en utilisant la méthode adaptative par cycle d'hystérésis. Les modèles d'évènements ont été appliqués hors ligne sur les signaux et les instants correspondant à la détection d'un évènement, ainsi que l'indice de confiance associé, ont été enregistrés.

Une validation des résultats a été effectuée par analyse visuelle de la manière suivante : pour chaque enregistrement, les 10 variables physiologiques enregistrées sont présentées à un observateur, ainsi que les évènements notés au cours du recueil, mais la tendance extraite et le résidu ne sont pas visibles. L'observateur peut zoomer sur n'importe quel partie de l'enregistrement. Les périodes de temps où un évènement a été détecté par la procédure de détection sont repérées sur les signaux. L'observateur doit expertiser chaque évènement détecté suivant 3 classes : vrai, faux, indéterminé. Ensuite, une analyse globale de l'enregistrement est effectuée pour repérer des évènements qui n'auraient pas été notés au cours du recueil et que la méthode de détection n'aurait pas détectés (évènement non détecté).

2.4.1.2.1. Artéfact sur la pression artérielle dû à un flush sur le cathéter artériel

27 flushs ont été détectés par la méthode, dont 26 ont été classés comme vrais et un comme indéterminé par l'observateur. Parmi les 27 flushs, 23 ont été détectés avec un indice de confiance de 3 sur 3. 3 flushs n'ont pas été détectés.

2.4.1.2.2. Aspirations trachéales

47 aspirations trachéales ont été détectées, dont 43 ont été classées comme vraies, 3 comme fausses et 1 comme indéterminés. 26 ont été détectées avec un indice de confiance supérieur ou égal à 5 sur 11. 2 n'ont pas été détectées par le système.

2.4.1.2.3. Changements d'état

109 changements d'état ont été détectés, dont 86 ont été classés comme vrais, 9 comme faux et 14 comme indéterminés. 50 ont été détectés avec un indice de confiance supérieur ou égal à 3 sur 10 (au moins 3 variables impliquées dans la détection).

La Figure 13 présente un exemple de détection d'un changement d'état sur un enregistrement. Huit paramètres physiologiques sur lesquels sont superposées les tendances extraites sont présentés, la pression artérielle systolique, pression artérielle diastolique, la Spo2, la fréquence cardiaque, la pression maximale dans les voies aériennes, le volume expiré, la ventilation minute et la fréquence respiratoire sur une durée d'environ une demi-heure. Les instants où un changement d'état sont représentés par des étoiles.

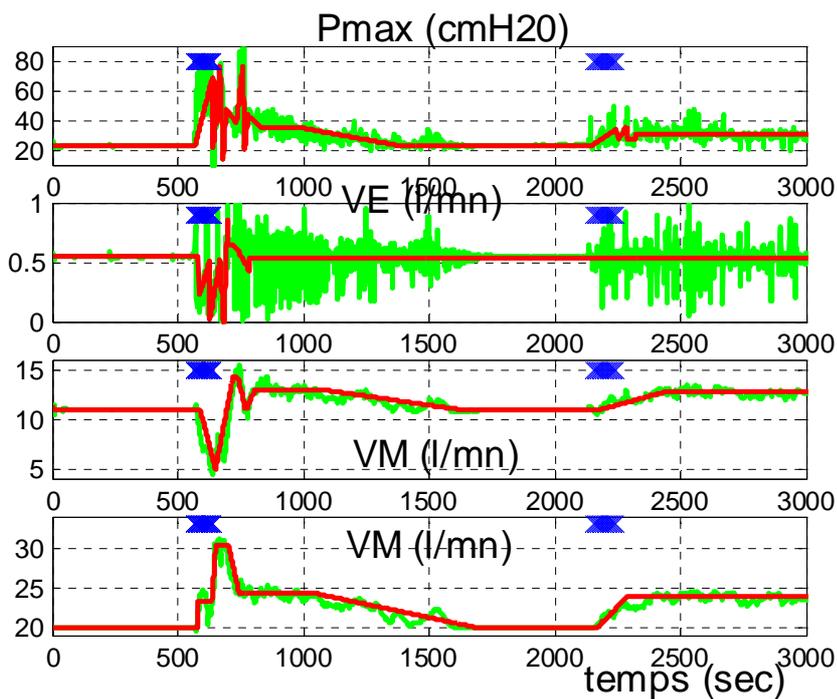
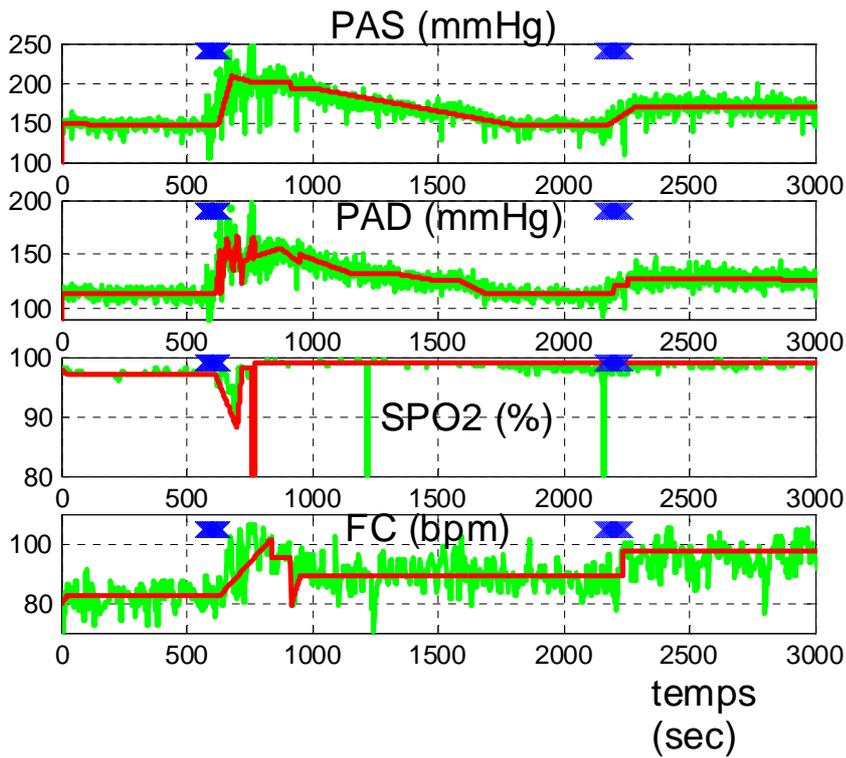


Figure 13: Exemple de détection de changements d'état

Les résultats obtenus semblent satisfaisants. Les performances de la méthode de détection d'évènements dépendent essentiellement de la qualité des modèles proposés, ainsi que de la pertinence des informations extraites par la méthode d'extraction de tendance et résidus adaptative. Ces bons résultats fournissent donc une validation pour la méthode adaptative.

2.4.2. Calcul d'indice de changement temporel permettant de mettre en évidence les périodes stables et instables du patient

2.4.2.1. Indice monovariabile

Un indice de changement est une valeur symbolique comprise entre 0 et 1, calculée à chaque période d'échantillonnage, fournissant une indication sur l'évolution temporelle d'une variable. L'indice de changement est calculé à partir des informations fournies par la tendance : épisodes et résidus. Trois indices de base sont calculés pour une variable et ensuite fusionnés en un seul. Le premier est fondé sur l'amplitude et la durée d'un épisode, le deuxième sur l'écart type du résidu et le troisième sur la succession de deux épisodes. Chaque indice a une signification linguistique et peut être vu comme la fonction d'appartenance du signal à un ensemble flou caractérisant un changement particulier de la variable. La fusion des trois indices en un seul caractérise l'appartenance du signal, à chaque période d'échantillonnage, à l'ensemble flou « changement temporel ».

Dans la suite, la transformation numérique symbolique d'une variable x est réalisée à l'aide d'une fonction linéaire bornée définie par l'équation **Eq. 18**.

$$f_{a,b}(x) = \begin{cases} 0 & \text{if } x \leq a \\ \frac{x-a}{b-a} & \text{if } a < x < b \\ 1 & \text{if } x \geq b \end{cases} \quad \text{Eq. 18}$$

avec a et b deux paramètres de réglages.

Le premier indice, $EpInd$, est calculé pour chaque épisode croissant ou décroissant. L'amplitude et la durée d'un épisode (**Eq. 16**, **Eq. 17**) sont transformés en information symbolique à l'aide de la fonction définie en **Eq. 18**.

$$\begin{aligned} AInd &= f_{a_{amp}, b_{amp}}(Amp) \\ Dind &= f_{a_{dur}, b_{dur}}(Dur) \end{aligned} \quad \text{Eq. 19}$$

Ces deux informations symboliques traduisent l'appartenance de l'épisode à l'ensemble flou « épisode d'amplitude significative », « épisode de durée significative ». Les deux informations sont ensuite fusionnées en un indice de changement, $EpInd$, à l'aide d'un opérateur disjonctif flou (L'opérateur choisi est ici la somme bornée).

$$EpInp = \min(1, Aind + Dind) \quad \text{Eq. 20}$$

La signification de la règle de fusion aboutissant à l'indice $EpInd$ est la suivante : un changement temporel associé à un épisode est caractérisé par un épisode dont la durée est significative ou dont l'amplitude est significative.

Les paramètres a_{amp} et b_{amp} de la fonction utilisés pour la transformation symbolique de l'amplitude dépendent du signal considéré. De manière à ne pas multiplier les paramètres de réglage, ils sont choisis comme une fonction de $seuil_c$: $a_{amp} = \alpha \cdot seuil_c$, $b_{amp} = \beta \cdot seuil_c$, α et β gardant les mêmes valeurs quel que soit le signal ($\alpha=2$, $\beta=4$). Notons que la valeur de $seuil_c$ n'est pas fixe, mais correspond à celle fixée par l'algorithme d'extraction de tendance en version adaptative. L'indice de changement intègre donc l'état détecté du patient dans son calcul. Les paramètres a_{dur} et b_{dur} valent respectivement 900Ts et 2000Ts.

La valeur de l'indice $EpInd$ associé à l'épisode est affectée durant toute la durée de l'épisode, c'est-à-dire pour toute période d'échantillonnage k comprise entre k_d et k_f . Si l'épisode est stable, la valeur affectée est zéro.

Si primitive = croissant ou décroissant

$$EpInp(k) = \min(1, Aind + Dind) \forall k_d \leq k \leq k_f \quad \text{Eq. 21}$$

Sinon $EpInp(k) = 0$

Le deuxième indice, $ResInd$, traduit un changement temporel associé au résidu. L'écart type du résidu est estimé à chaque période d'échantillonnage à l'aide d'une fenêtre glissante de taille 60 périodes d'échantillonnage à l'aide de l'équation Eq. 11. La valeur de l'écart type est transformée en une valeur symbolique à l'aide de la fonction Eq. 18 et permet d'obtenir le deuxième indice $ResInd$. Il traduit l'appartenance du signal à l'ensemble flou « valeur significative de l'écart type du résidu ». La règle de fusion implicite traduit qu'un changement temporel associé au résidu est caractérisé par de fortes variations sur le résidu.

$$ResInd(k) = f_{a_{std}, b_{std}}(\sigma_{res}(k)) \quad \text{Eq. 22}$$

Les paramètres de a_{std} et b_{std} de la fonction sont réglés suivant les percentiles de la fonction de répartition de l'écart type (explicitée au paragraphe 2.3.2.2.2), de manière à avoir un réglage indépendant du signal considéré ($a_{std}=90^{\text{ème}}$, $b_{std}=95^{\text{ème}}$)

Le troisième indice $SuccEpInd$ prend en compte les successions d'épisodes et traduit le fait qu'un changement est d'autant plus important qu'il est précédé par une période de stabilité. Toute succession d'épisodes du type [*stable*, k_{ds} , k_{fs} , y_{ds} , y_{fs}], [*croissant (décroissant)*, k_{dc} , k_{fc} , y_{dc} , y_{fc}], est décrite à l'aide de deux attributs flous :

l'un traduisant l'appartenance de l'épisode stable à l'ensemble « épisode stable de longue durée » $SEpInd = f_{a_s, b_s}(|k_{fs} - k_{ds}|)$

l'autre traduisant l'appartenance de l'épisode croissant ou décroissant à l'ensemble « épisode d'amplitude significative ». $CrEpInd = f_{a_c, b_c}(|y_{fc} - y_{dc}|)$

L'indice de changement est ensuite obtenu par fusion des deux attributs à l'aide d'un opérateur flou de type conjonctif (l'opérateur choisi est le produit). La règle de fusion aboutissant à l'indice $SuccEpInd$ a la signification suivante : « un changement temporel associé à une succession d'épisodes est caractérisé par un épisode croissant ou décroissant d'amplitude significative et précédé par un épisode stable de longue durée ». La valeur de l'indice associé est affectée durant toute la durée de l'épisode croissant ou décroissant.

Si primitive $i = \{\text{croissant}\}$ ou $\{\text{décroissant}\}$ et primitive $i-1 = \{\text{stable}\}$

$$SuccEpInp(k) = SEpInd \times CrEpInd \forall k_{di} \leq k \leq k_{fi} \quad \text{Eq. 23}$$

Sinon $EpInp(k) = 0 \forall k_{di} \leq k \leq k_{fi}$

Les paramètres de réglage a_c et b_c sont réglés en fonction de $seuil_c$, avec a_c et b_c inférieurs aux seuils a_{amp} et b_{amp} réglant l'indice $AInd$, de manière à accentuer l'importance d'un changement sur le signal survenant après une longue période de stabilité ($a_c = seuil_c$, $b_c = 2 \cdot seuil_c$). Les paramètres a_s et b_s sont réglés à $300T_s$ (5 minutes) et $600T_s$ (10 minutes).

Les trois indices de changement, $EpInd$, $ResInd$ et $SuccEpInd$, sont ensuite fusionnés en un seul indice de changement, $ChangeInd$, à l'aide d'un opérateur flou disjonctif. La règle de fusion aboutissant à l'indice de changement monovarié, $ChangeInd$, exprime qu'il se produit un

changement temporel sur le signal si au moins un des trois indices a une valeur importante, c'est-à-dire si le signal est décrit par un épisode croissant ou décroissant de forte amplitude ou de longue durée ou si la valeur de l'écart type des résidus est importante ou si le signal est décrit par un épisode croissant ou décroissant précédé par un épisode stable de longue durée. L'opérateur de fusion choisi est le maximum.

$$ChangeInd(k) = \max(EpInd(k), ResInd(k), SuccEpInd(k)) \quad \text{Eq. 24}$$

2.4.2.2. Indice multivariable

L'évolution de chaque variable peut être caractérisée par son indice de changement, dont la valeur est comprise entre 0 et 1. L'utilisation d'un code de couleur associé à la valeur de l'indice fournit un support visuel, qui permet de mettre en évidence les périodes où celle-ci change fortement.

D'autre part, l'indice, sans dimension, peut facilement être fusionné entre plusieurs variables pour décrire l'évolution d'un état. Ainsi, nous avons choisi de fusionner les indices de changement de variables décrivant les mêmes fonctions physiologiques, afin de créer deux indices de changement multivariables :

L'indice de changement respiratoire, R , correspondant à la fusion des indices monovariables de 5 paramètres physiologiques associés à la fonction respiratoire: la fréquence respiratoire, le volume expiré, la ventilation minute, la pression maximale dans les voies aériennes, le débit maximal dans les voies aériennes.

L'indice de changement hémodynamique, H , correspondant à la fusion des indices monovariables de 4 paramètres physiologiques associés à la fonction circulatoire: la fréquence cardiaque, la pression artérielle systolique, la pression artérielle diastolique, la pression artérielle moyenne.

L'opérateur de fusion flou exprime un compromis entre les variables. L'opérateur choisi est la moyenne arithmétique. Le maximum de l'indice de changement de chaque variable physiologique est calculé sur une fenêtre de taille L , appelée fenêtre de recouvrement. Les maxima des différentes variables sont ensuite moyennés à chaque période d'échantillonnage. Ainsi, l'indice de changement multivariable calculé à partir de j variables s'exprime par :

$$MultiInd_j(k) = \frac{1}{j} \sum_{n=1}^j \{ \max_{i \in [k-L; k]} ChangeInd_n(i) \} \quad \text{Eq. 25}$$

L'utilisation d'une fenêtre de recouvrement permet de s'affranchir des imprécisions sur les instants de début et fin des épisodes et de prendre en compte les décalages temporels dus aux liens causaux entre les variables. Nous avons fixé la taille de la fenêtre L à 30 périodes d'échantillonnage.

La Figure 14 montre l'indice de changement respiratoire obtenu sur un enregistrement de 4 heures. Les 4 figures du haut correspondent aux paramètres respiratoires VM, VT, FR et Pmax, sur lesquels est superposé la tendance extraite, la figure du bas présente l'indice de changement respiratoire. Les changements observés sur les variables sont mis en évidence par le code de couleur. Ainsi, trois périodes ressortent particulièrement : une en début d'enregistrement et deux autour de 10000 secondes. Elles correspondent à des variations simultanées des paramètres physiologiques respiratoires, dues à des aspirations trachéales. Ces aspirations ont par ailleurs été reconnues par le système de détection d'évènements.

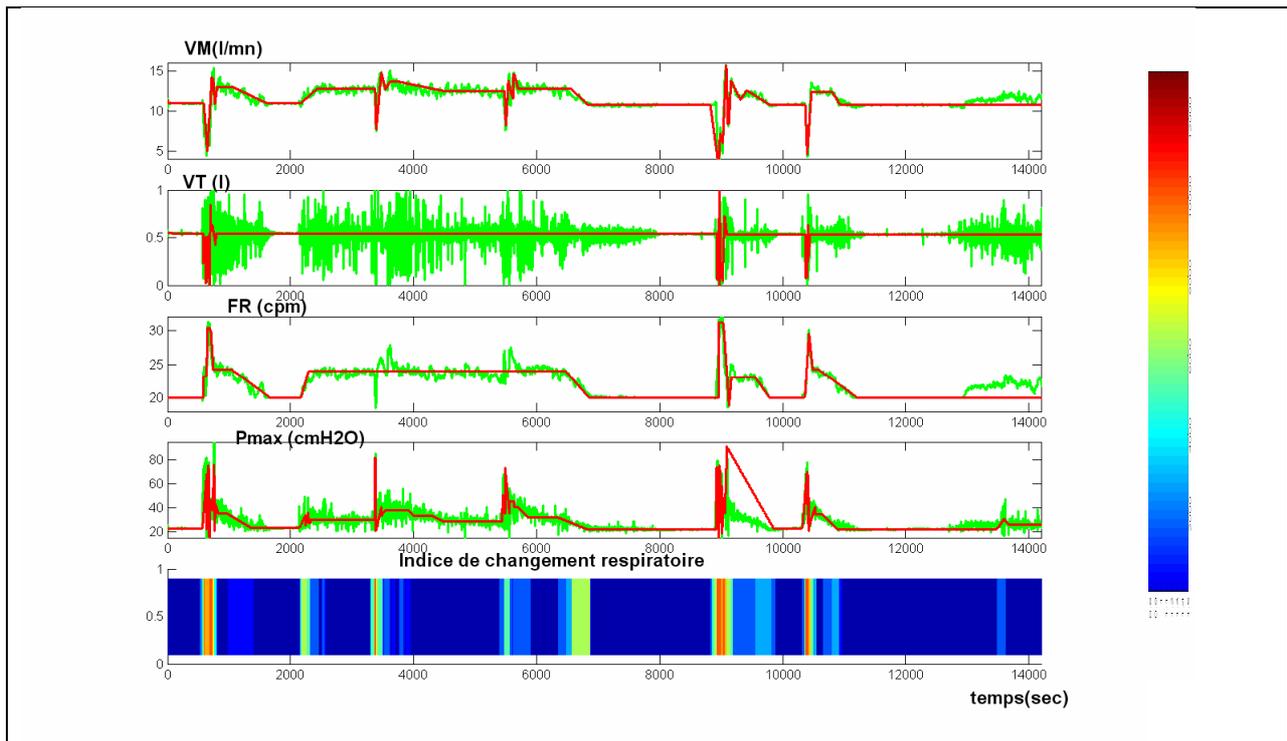


Figure 14 : Indice de changement respiratoire obtenu au cours de 4 heures d'enregistrement sur un patient.

2.4.3. Filtrage d'alarme de SpO_2 par analyse conjointe des autres variables physiologiques.

Les services de réanimation souffrent d'une pollution sonore importante, due à la simplicité des systèmes d'alarmes, se déclenchant par franchissement de seuils. Ces systèmes sont d'une part très sensibles aux variations transitoires affectant les signaux. D'autre part, aucune relation entre les variables n'est prise en compte pour confirmer ou infirmer l'alarme. Afin de pallier ces inconvénients, nous avons développé un système d'alarme fondé sur l'extraction de tendance. Celle-ci sert dans un premier temps de support au déclenchement d'une alarme en monovariable. Suite au déclenchement, l'analyse de la tendance extraite sur les autres signaux permet de classer l'alarme en deux catégories : vraie (prévenir le personnel) ou fausse (ne pas alerter le personnel). Les alarmes sont donc filtrées d'une part grâce au filtrage de signal effectué par l'algorithme de segmentation, d'autre part par l'interprétation multivariable effectuée sur les signaux.

Dans la suite de ce mémoire, nous présenterons les résultats obtenus sur une variable particulière : la saturation pulsée en oxygène mesurée par l'oxymètre de pouls (SpO_2). La SpO_2 permet de surveiller le taux de saturation en oxygène du patient de manière continue et non invasive, à l'aide d'un capteur à infra rouge placé en général au doigt. C'est une information vitale pour le patient : une alarme non prise en compte par le personnel peut avoir des conséquences extrêmement graves. Cependant, cet appareil est à l'origine d'un grand nombre de fausses alarmes, dues à la sensibilité de la mesure aux perturbations extérieures. L'objectif d'un système de filtrage d'alarmes de SpO_2 est de réduire le nombre de fausses alarmes sans rater une seule vraie alarme.

La SpO_2 , mesure indirecte de la bonne oxygénation du patient, peut être vue comme une information de sortie. Il existe une relation de cause à effet entre les variables associées à

l'activité respiratoire et l'activité circulatoire du patient et cette variable. Par conséquent, une chute de la saturation en oxygène correspondant à une vraie alarme (mauvaise oxygénation du patient) doit s'accompagner ou être précédée de variations sur les variables hémodynamiques (fréquence cardiaque, pression artérielle) et/ou respiratoires (fréquence respiratoire, volume expiré, ...). Cette hypothèse est utilisée pour développer le système de filtrage d'alarmes ([CHA 06b]). Ce modèle de connaissance est volontairement très simple. Il s'applique à tout patient, quelle que soit sa pathologie. Les règles de filtrage n'ont donc pas de restriction d'application.

2.4.3.1. Description du système d'alarme

2.4.3.1.1. Principe du système d'alarme

1. Déclenchement à un instant k_a d'une alarme de SpO_2 sur franchissement de seuil.

Pour la procédure de déclenchement de l'alarme, la tendance est extraite sur la SpO_2 à chaque période d'échantillonnage jusqu'à l'instant courant. Une alarme est déclenchée à un instant k_a si la valeur finale du dernier épisode extrait et la valeur du signal franchissent le seuil d'alarme. L'alarme est arrêtée quand la valeur finale du dernier épisode et le signal franchissent le seuil d'alarme. La valeur finale du dernier épisode est obtenue par extrapolation du signal suivant l'approximation linéaire en cours au temps courant (cf Figure 2). Celle-ci peut être différente du signal, d'où la nécessité de confirmer l'alarme par le signal.

2. Forçage de la segmentation jusqu'à l'instant k_a pour toutes les variables physiologiques

A l'instant k_a , une nouvelle approximation linéaire, approchant le signal au sens des moindres carrés est calculée sur l'ensemble des points stockés dans la matrice des points anormaux. Celle-ci contient l'ensemble des points pour lesquels la valeur de la Cusum est supérieure à $seuil_1$ jusqu'à l'instant k_a . Si cette matrice est vide, l'approximation linéaire courante est conservée. Le forçage de la segmentation permet d'obtenir un signal correctement approché par des segments de droites, jusqu'à l'instant k_a .

3. Extraction de la tendance et du résidu jusqu'à l'instant k_a pour toutes les variables physiologiques, en utilisant l'approximation linéaire calculée à l'étape précédente

4. Calcul des indices de changements monovariables et multivariables jusqu'à l'instant k_a .

5. Analyse de l'alarme à partir de trois règles de décision floues, utilisant la tendance de la SpO_2 et les indices de changement multivariables, sur un horizon temporel d'une durée K_d précédent l'alarme : $[k_a - K_d ; k_a]$.

2.4.3.1.2. Règles de décision

Deux cas sont à envisager sur l'occurrence d'une alarme de SpO_2 :

Cas 1 : celle-ci survient alors que le patient était jusqu'alors correctement oxygéné (valeur au dessus de 95%) et chute rapidement sous 90% (seuil d'alarme).

Cas 2 : celle-ci survient alors que la valeur de la SpO_2 était déjà faible, bien que supérieure au seuil d'alarme (hypoxie légère installée).

L'hypothèse émise sur l'apparition de variations sur les variables hémodynamiques ou respiratoires concomitantes avec l'occurrence d'une alarme de SpO_2 peut ne pas être justifiée dans le cas 2. Dans ce cas, il n'y a pas de changement d'un état de bonne oxygénation vers un état de mauvaise oxygénation, explicable par des changements de l'activité respiratoire ou

circulatoire. Trois règles de décision sont proposées pour prendre en compte diverses situations, chacune délivrant une information de sortie comprise entre 0 (fausse alarme) et 1 (vraie alarme). Les conclusions de chaque règle sont fusionnées pour fournir la décision finale.

Règle 1 : Alarme suite à une hypoxie légère installée

Cette situation est reconnue par l'observation de la valeur de la tendance de la SpO₂ sur l'intervalle d'analyse $[k_a - K_d ; k_a]$. La conclusion de la règle, R1, est un attribut flou, déterminant l'appartenance du signal à l'ensemble « hypoxie installée ». Il est calculé de la manière suivante :

$$R1 = \frac{\sum_{k=k_a-K_d}^{k_a} \mu_{1k} * \mu_{2k}}{K_d - (T / 2)} \quad \text{Eq. 26}$$

A chaque période d'échantillonnage k, le signal segmenté y_k est transformée en une valeur symbolique μ_{1k} , comprise entre 0 et 1, en fonction de sa position par rapport à la valeur 95%. μ_{1k} traduit l'appartenance de y_k à l'ensemble « valeur en dessous de 95% ».

$$\mu_{1k} = 1 - f_{94\%,95\%}(y_k) \quad \text{Eq. 27}$$

avec f définie par **Eq. 18**.

Un coefficient d'oubli μ_{2k} lui est affecté, en fonction de l'éloignement de k par rapport à l'instant d'alarme k_a .

$$\mu_{2k} = f_{k_a-K_d, k_a-K_d+T}(k) \quad \text{Eq. 28}$$

avec $T = K_d/5$

R1 est la moyenne sur l'horizon temporel de la valeur symbolique du signal μ_{1k} pondérée par son facteur d'oubli μ_{2k} .

Règle 2 : Alarme due à une déconnection du capteur

La déconnection du capteur de SpO₂ a une signature temporelle particulière, reconnaissable à partir de sa tendance. La variable chute brutalement sous une valeur inférieure à 90%. Si l'alarme de SpO₂ est associée à la forme temporelle suivante, formée de deux épisodes, l'alarme est due à une déconnection, :

$$\{\text{décroissant}, k_d, k_d + Ts, y_d > 90\%, y_f < 82\%\}, \{\text{stable}, k_d + Ts, k_a, y_f < 82\%\}.$$

La conclusion de la règle R2 est une valeur binaire. Elle prend la valeur 0 si la forme temporelle est détectée, et 1 sinon.

Règle 3 : Alarme associée aux indices de changements multivariés

La 3^{ème} règle filtre les alarmes en fonction de la valeur des indices de changement hémodynamique (H) et respiratoire (R) calculés sur l'horizon temporel précédant l'alarme.

La conclusion de la règle, R3, est un attribut flou, exprimant l'appartenance à l'ensemble « présence de variations significatives sur les variables hémodynamiques ou respiratoires au cours de l'intervalle d'analyse précédant l'alarme ». R3 est calculé par :

$$R3 = \max[f_{seuil1M,seuil2M}(R_M), f_{seuil1M,seuil2M}(H_M), f_{seuil1m,seuil2m}(Rm), f_{seuil1m,seuil2m}(Hm)] \quad \text{Eq. 29}$$

avec $R_M = \max_{k \in [k_a - K_d]} Rk$, $H_M = \max_{k \in [k_a - K_d]} Hk$, $R_m = \min_{k \in [k_a - K_d]} Rk$,
 $H_m = \min_{k \in [k_a - K_d]} Hk$

La valeur maximale et la valeur minimale de l'indice hémodynamique (HM, Hm) et de l'indice respiratoire (Rm, RM) sur l'intervalle d'analyse $[k_a - K_d ; k_a]$ sont transformées en attribut flou caractérisant leur appartenance à l'ensemble « valeurs significatives ». Les attributs sont ensuite agrégés à l'aide d'un opérateur flou conjonctif, le maximum. La signification de la règle de fusion aboutissant à R3 est la suivante : « des changements significatifs sont apparus sur les signaux respiratoires ou hémodynamiques au cours de l'intervalle d'analyse ». Un changement significatif est caractérisé par un changement important de courte durée (explicité par le maximum) ou par des petits changements se produisant pendant toute la durée de l'intervalle d'analyse (explicité par le minimum).

2.4.3.1.3. Fusion des trois règles de décision

Les conclusions des 3 règles de décision sont fusionnées en un attribut flou R, exprimant l'appartenance de l'alarme à l'ensemble « vraie alarme ». La règle de fusion classe l'alarme comme vraie alarme si l'alarme survient après une hypoxie faible installée (R1), ou si le capteur n'est pas déconnecté (R2) et qu'il existe des variations significatives sur les variables hémodynamiques ou respiratoires au cours de l'intervalle d'analyse (R3).

R est calculé à l'aide d'opérateur disjonctif (max) et d'opérateur conjonctif (min) de la manière suivante :

$$R = \max(R1, \min(R2, R3)) \quad \text{Eq. 30}$$

La décision finale est prise en fixant un seuil sur R, *seuil*R. Si R est supérieur au seuil de décision, l'alarme est vraie, sinon elle est fausse.

2.4.3.2. Résultats sur données réelles

Le système de filtrage d'alarme a été appliqué en ligne sur l'ensemble des enregistrements de la base. Les instants de début et fin d'alarme, ainsi que la décision du système d'analyse (alarme vraie-fausse) ont été enregistrés en ligne. Une analyse comparative hors ligne a ensuite été effectuée entre les alarmes générées par le système fondé sur la tendance et celles générées par le système de monitoring classique. La décision prise par le système a été confrontée à la décision prise par un expert, sur chacune des alarmes, a posteriori.

2.4.3.2.1. Comparaison des alarmes du système de monitoring et du système fondé sur la tendance

Au cours des enregistrements, le système de monitoring a généré 117 séquences d'alarmes. Une séquence d'alarme correspond à une chute de la SpO₂ sous 90% pendant une durée supérieure à 10 secondes. Parmi ces 117 séquences d'alarmes, 95 sont concomitantes avec une séquence d'alarme du système fondé sur la tendance et 22 sont non concomitantes. Une séquence d'alarme est dite concomitante avec une autre si l'intersection des deux intervalles de temps qui les composent, augmentées d'une fenêtre temporelle de 30s aux deux extrémités, est non nulle. La durée médiane des alarmes non concomitantes est de 14 secondes. Une vérification des résultats à l'aide du fichier d'événements complété en ligne par l'observateur externe a montré qu'aucune de ces alarmes ne correspondaient à une alarme ayant nécessité une intervention médicale sur le patient.

Le système d'alarme fondé sur la tendance a généré 77 séquences d'alarmes, 70 concomitantes avec le système de monitoring classique et 7 non concomitantes. Les 7 alarmes non concomitantes correspondent :

- soit à des changements d'état transitoires sur le patient : la SpO_2 passe d'une valeur élevée à une valeur inférieure à 90% et y reste pendant un temps inférieur à 10 sec. Ces transitoires font suite à une geste médical effectué sur le patient, comme une aspiration trachéale.

- soit à des périodes où la valeur de la SpO_2 est proche du seuil d'alarme et le franchit parfois pendant une durée inférieure à 10 sec.

La durée médiane des alarmes est de 128 sec, contre 80 sec pour le système de monitoring classique. L'augmentation de la durée d'une alarme est due au filtrage du signal effectué par l'algorithme de segmentation. Quand le système à base de tendance déclenche une unique séquence d'alarme, le système de monitoring déclenche dans le même temps des alarmes intermittentes car l'alarme s'interrompt dès que le signal repasse au-dessus du seuil d'alarme et reprend ensuite.

Le retard médian entre le déclenchement d'une alarme du monitoring et celui d'une alarme du système fondé sur la tendance est de 1 sec.

Le système fondé sur la tendance, grâce à l'algorithme de segmentation utilisant la Cusum, permet de filtrer les transitoires de courte durée, et réduire ainsi le nombre de fausses alarmes. Une analyse théorique des alarmes filtrées par le système et du retard engendré par le système a été effectuée en [CHA 06c]. Les conclusions sont en concordance avec les résultats obtenus sur données réelles.

2.4.3.2.2. Performance du système d'analyse d'alarmes

Parmi les 77 séquences d'alarmes générées par le système fondé sur la tendance, 72 ont été analysées à posteriori par un expert du domaine de la surveillance de patient en réanimation. L'expert a fourni pour chacune des alarmes une conclusion binaire : vraie alarme, fausse alarme. Une alarme expertisée correspond à un épisode décroissant de SpO_2 sous le seuil de 90%, à partir de la tendance extraite hors ligne (L'extraction de tendance a été appliquée jusqu'à la fin de l'enregistrement). L'expert dispose de l'ensemble de l'enregistrement et des variables pour analyser les alarmes. Parmi les 72 alarmes expertisées, 37 sont classées comme fausses et 35 comme vraies par l'expert.

5 alarmes générées en ligne par le système fondé sur la tendance sont sans correspondance avec les alarmes expertisées à l'aide de la tendance hors ligne. Ceci est due aux différences observables entre la tendance extraite en ligne, recalculée à chaque période d'échantillonnage à l'aide de l'extrapolation par le dernier segment calculé lors de la dernière segmentation, et la tendance hors ligne, calculée à partir des segments obtenus après chaque segmentation. Ces cinq alarmes correspondent à des périodes où la SpO_2 passe légèrement sous le seuil d'alarme pendant une courte durée.

La décision automatique par fusion des conclusions des 3 règles est réglée par 6 paramètres : $seuil1m$, $seuil2m$, $seuil1M$, $seuil2M$, dont la valeur est comprise entre 0 et 1, paramétrant la règle 3, $seuilR$, compris entre 0 et 1, le seuil à partir duquel la conclusion floue est traduite en valeur nette : alarme vraie, fausse et K_d , la durée d'analyse précédant l'alarme. Si l'on impose la relation $seuil2M=seuil1M+0.1$, $seuil2m=seuil1m+0.1$, le nombre de paramètres à régler se réduit à 4.

Fixons $K_d = 6000$ périodes d'échantillonnage, soit 10 minutes. Soit $seuil2m = 0.2$, $seuil2M = 0.6$. Le Tableau 1 montre les résultats obtenus sur les 72 alarmes :

	Expert = 1	Expert = 0
Système = 1	35	7
Système = 0	0	30

Tableau 1 : Concordance entre l'expert et le système d'analyse d'alarmes

Parmi les 72 alarmes, 14 ont été classées par la règle 1, 26 par la règle 2 et 32 par la règle 3.

La sensibilité du système, définie comme le pourcentage d'alarmes expertisées comme fausses et classées comme fausses par le système, est 81% et sa spécificité, définie comme le pourcentage d'alarmes expertisées comme vraies et classées comme vraies par le système, est 100%.

Une analyse de la sensibilité des performances du système aux paramètres de réglages a été réalisée. Les résultats sont présentés Figure 15. L'abscisse de la figure présente les valeurs de $seuilR$, les ordonnées les valeurs de $seuil2M$, par pas de 0.1. Les points mettent en évidence les valeurs de $seuilR$ et $seuil2M$ pour lesquels les mêmes performances que précédemment ont été obtenues (spécificité=100%, sensibilité=81%, qui correspondent aux performances optimales). Les performances optimales sont obtenues si $(seuilR, seuil2M) \in [0.5, 0.7] \times [0.5, 0.6] \cup \{0.7, 0.4\}$. Une augmentation de la valeur de $seuilR$ ou de $seuil2M$ au-delà de ces valeurs diminue la spécificité (au moins une vraie alarme est classée comme fausse par le système), une diminution au-delà de ces valeurs diminue la sensibilité.

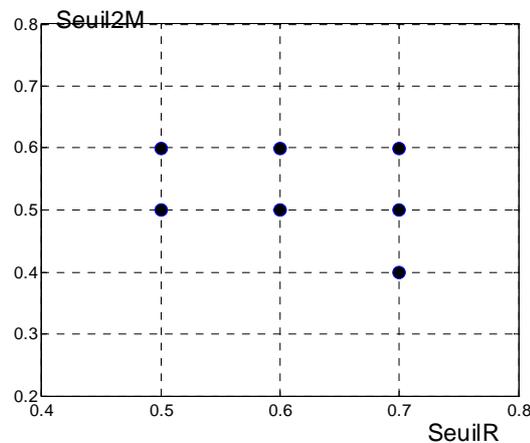


Figure 15 : Analyse de sensibilité par rapport aux seuils $seuilR$ et $seuil2M$

Les performances sont peu sensibles à $seuil2m$. Quand $(seuilR, seuil2M) = (0.7, 0.6)$, les mêmes performances sont obtenues quand $seuil1M \in [0.2, 0.4]$

L'analyse de sensibilité montre que, bien que le nombre de paramètres à régler soit nombreux, la méthode de filtrage est assez peu sensible à leur valeur. Cela laisse supposer que la méthode donnera de bons résultats sur de nouvelles données. Cependant, à ce stade de l'étude, aucune validation du système de filtrage, n'a pu être effectuée sur de nouvelles données. Un nouveau recueil devra être effectué avant de pouvoir conclure définitivement sur les performances de la méthode.

Afin d'évaluer la pertinence de l'hypothèse associée à la règle 3 : « une vraie alarme s'accompagne de changements sur les paramètres hémodynamiques ou respiratoires », seule la règle 3 a été appliquée pour filtrer l'ensemble des alarmes. Les résultats sont présentés Tableau 2.

	Expert = 1	Expert = 0
Système = 1	34	20
Système = 0	1	17

Tableau 2: Concordance entre l'expert et le système d'analyse d'alarmes quand seule la règle 3 est utilisée

Le pourcentage d'alarmes bien classées vaut 71%. La spécificité reste élevée (97%), mais la sensibilité chute sous 50% (46%). Les résultats obtenus confirment bien l'hypothèse qu'une vraie alarme s'accompagne de changements sur les autres variables. Cependant, son corollaire, « une fausse alarme ne s'accompagne d'aucun changement », n'est vérifié qu'une fois sur 2. Ceci s'explique par le modèle de connaissance, volontairement très général, permettant de filtrer les alarmes. Aucune restriction n'est apportée au modèle. Celui-ci s'applique à tout patient, quelle que soit sa pathologie. La contrepartie de sa grande généralité est sa difficulté à filtrer les fausses alarmes. En effet, une déconnection du capteur de SpO₂ est généralement due à une agitation du patient, et au mouvement que cette agitation engendre. Cet état d'agitation peut parfois être observé sur d'autres variables physiologiques (sur la pression artérielle notamment), ce qui génère une augmentation des indices de changements et donc la classification en vraie alarme. L'ensemble des trois règles est donc nécessaire pour obtenir un bon filtrage.

2.4.4. Fonctionnement en ligne du système d'aide à la surveillance de patients

Le système d'aide à la surveillance de patient est fondé sur la méthodologie d'extraction en ligne de la tendance d'une variable. Il inclut trois fonctionnalités supplémentaires : la reconnaissance automatique d'événements, le calcul et l'affichage d'indices de changement et le filtrage des alarmes de SpO₂. Son fonctionnement en ligne est le suivant :

- à chaque période d'échantillonnage, la procédure d'extraction de tendance est réalisée, telle que décrite en 2.3, sur les 10 variables physiologiques. A l'exception de la SpO₂, l'extraction de tendance progresse pour chaque variable, à chaque fois que l'algorithme de segmentation calcule un nouveau segment. La tendance, le résidu et l'indice de changement monovariable sont calculés jusqu'à cet instant, noté k_{seg} , pour la variable venant d'être segmentée.

La tendance de la SpO₂ est extraite à chaque période d'échantillonnage jusqu'à l'instant courant, en utilisant l'extrapolation du signal par la dernière approximation linéaire calculée. Le résidu et l'indice de changement ne sont calculés qu'à chaque nouvelle segmentation de la SpO₂. Quand une alarme est détectée sur la SpO₂, la procédure de filtrage d'alarme décrite en 2.4.3 est mise en œuvre. Le système « prend une photo » de la situation au moment où survient l'alarme, puis la procédure d'extraction de tendance se poursuit sur chaque variable de manière inchangée. L'approximation linéaire calculée sur l'ensemble des variables suite au forçage de la segmentation n'intervient pas dans la suite de l'extraction de tendance. La tendance extraite à un instant donné est la même, qu'une alarme de SpO₂ se soit produit précédemment ou non. La

photo prise sur l'ensemble des variables au moment de l'alarme contient la tendance et le résidu extraits sur chaque variable jusqu'à l'instant d'occurrence de l'alarme.

La reconnaissance d'évènement multivariable et l'indice de changement multivariable sont calculés en ligne. Ces informations ne peuvent être calculées que si la tendance et le résidu de toutes les variables intervenant dans le calcul ont été calculées. Soient n variables, $var_1, var_2, \dots, var_n$ intervenant dans le calcul d'une information I et $kseg_{var1}, kseg_{var2}, \dots, kseg_{varn}$ le dernier instant où la variable correspondante a été segmentée. L'information I peut être calculée en ligne jusqu'à l'instant k_{calcul} , tel que $k_{calcul} = \min_{j=1 \text{ à } n} (kseg_{var_j})$. Ceci inclut un retard qui peut être

important entre l'instant courant et le dernier instant où le système a pu calculer l'information I . Les informations multivariables peuvent néanmoins être calculées jusqu'à l'instant courant, sur occurrence d'un évènement externe : alarme de SpO_2 ou demande du personnel soignant. La tendance de toutes les variables ainsi que le résidu et les indices de changement mono variables sont alors extraits jusqu'à l'instant courant par forçage de la segmentation. Les procédures de détection d'évènement et de calcul d'indices multivariables peuvent être appliqués jusqu'à l'instant courant.

2.5. Conclusion et perspectives

Ce chapitre a présenté une méthode pour extraire en ligne la tendance d'un signal, et son utilisation à des fins d'aide à la surveillance. La méthode a été développée dans le cadre de la surveillance de patient hospitalisé en réanimation mais son champ potentiel d'application est plus vaste. Elle peut être appliquée à tout procédé physique pour lequel aucun modèle formel n'est disponible et dont la signature des anomalies se traduit par des évolutions temporelles caractéristiques sur les signaux enregistrés.

La méthode est réglée par trois paramètres dont le réglage ne nécessite qu'une connaissance minimale du signal : son ordre de grandeur et le type de transitoire que l'on souhaite filtrer. Les développements ultérieurs, l'agrégation d'épisodes 3 à 3 et la version adaptative fonction de l'écart type, ont rendu la méthode indépendante du signal considéré, car ils utilisent des valeurs relatives. Les attributs permettant de classer trois épisodes successifs dans les classes « à agréger », « à ne pas agréger », s'expriment en pourcentage du plus grand ou du plus long épisode. La fonction d'adaptation des paramètres permet de fixer les paramètres de réglage proportionnellement à l'écart type. Seul le facteur de proportionnalité et le retard à la détection, qui ne dépendent pas du signal, sont à régler. La connaissance sur le signal n'intervient que pour fixer les bornes minimales et maximales de la fonction de saturation.

La deuxième partie décrivant l'utilisation de la tendance à des fins d'aide à la surveillance semble plus spécifique à l'application. Les résultats satisfaisants obtenus constituent dans une certaine mesure une validation de la méthode d'extraction de tendance puisque nous ne disposons pas de référence experte, précisant les périodes temporelles où une variable est stable, croissante ou décroissante, à laquelle confronter nos résultats.

La méthode de détection d'évènement par pattern matching n'est pas originale. Elle a été utilisée précédemment par d'autres personnes sur d'autres procédés ([HUN 99], [GAM 06]). Cependant, un des intérêts de la méthode d'extraction de tendance proposée est de garder une information quantitative sur le signal, ce qui permet la création de modèles plus élaborés que ceux uniquement fondés sur l'information symbolique associée à la tendance.

La construction d'indices de changements mono et multi variables et leur utilisation comme support visuel pour l'opérateur chargé de la surveillance pourrait s'avérer utile pour la surveillance de procédé fonctionnant autour d'un point d'opération constant, et pour lesquels un changement dans les variables doit alerter l'opérateur. Le réglage des indices de changement, volontairement choisi de manière à être indépendant du signal considéré, rend son adaptation à d'autres procédés très aisée. Enfin, un système de filtrage d'alarmes similaire à celui développé, utilisant les indices de changements et les liens entre les variables, pourrait être mis en œuvre sur un procédé fonctionnant autour d'un point d'opération constant. Une modification observée sur une variable sans variations détectées sur les autres variables lui étant liées permet de conclure à un défaut capteur.

Au-delà de l'application de la méthode à d'autres systèmes, les perspectives de recherche sur l'utilisation de la tendance pour l'aide au diagnostic sont multiples. Elles concernent plus particulièrement le diagnostic d'anomalies par « pattern matching » et le développement de méthodes utilisant la tendance extraite.

2.5.1. Reconnaissance d'évènements par « pattern matching » à partir de modèles flous

La reconnaissance d'évènements à partir de modèles de connaissance a été abordée dans ce travail. Les modèles proposés sont dynamiques (association de plusieurs épisodes) et multivariés (prise en compte de plusieurs variables). Un indicateur de la certitude de la détection a été proposé, qui prend en compte le nombre de variables intervenant dans la détection. Il est possible d'aller plus loin dans la proposition d'un indicateur de confiance, en décrivant l'occurrence d'un évènement à l'aide de modèles flous. Les modèles proposés utilisent deux types d'information : l'information qualitative fournie par les primitives, l'information quantitative associée à un épisode (durée, valeurs du signal aux extrémités). Les modèles proposés traitent l'information numérique par des règles nettes (durée égale à, valeur supérieure à, ...). Une perspective de recherche est de transformer les règles nettes en règles floues, en fuzzifiant au préalable l'information quantitative associée aux épisodes et en mettant en œuvre des méthodes d'inférence floue pour conclure sur l'occurrence d'un évènement avec un indicateur de confiance associé à la détection. Cet indicateur traduira la fonction d'appartenance de la forme à la classe « évènement détecté ».

2.5.2. Création d'un alphabet de la dynamique du signal

Un premier degré d'abstraction de la dynamique du signal est obtenu par la décomposition en épisodes auxquels est associée une primitive. Un niveau supérieur d'abstraction peut être proposé en décrivant l'association de plusieurs épisodes sous forme de lettres et proposer ainsi un alphabet de la dynamique. En effet, un épisode seul peut ne pas être suffisamment descriptif. Par exemple, un épisode croissant précédé d'un épisode stable n'a pas la même signification que ce même épisode précédé d'un épisode décroissant. La description de la dynamique du signal à l'aide d'un alphabet composé de lettres formées par des successions d'épisodes permet une meilleure interprétation de l'évolution.

La transformation d'un signal en une succession de lettres nécessite :

- une sélection exhaustive de formes, auxquelles sont associées des lettres, permettant de décrire le signal en toutes conditions

- le développement d'une procédure de reconnaissance de lettre à partir d'épisodes successifs. Deux méthodologies peuvent être envisagées : une guidée par la connaissance, permettant la reconnaissance des lettres par des règles expertes, l'autre guidée par les données, en utilisant des techniques de reconnaissance de formes. Les méthodes pourront utiliser la logique floue. Les lettres composant l'alphabet seront vues comme des sous-ensembles flous, la détection consistant à calculer la fonction d'appartenance de la forme à reconnaître à chacun des sous ensembles.

2.5.3. Proposition d'une mesure de distance symbolique permettant de relier une forme temporelle multivariable définie par des lettres avec un modèle de référence

Le diagnostic d'anomalies peut être effectué en comparant la forme temporelle d'un ou plusieurs signaux au modèle de référence d'une anomalie. Le modèle de référence décrit la signature de l'anomalie comme une succession de lettres. Si la signature est connue, la détection de l'anomalie consiste à vérifier que la forme temporelle présente sur les signaux est similaire à celle d'une signature connue. La détection se fait par mesure de similarité entre la signature de référence et le signal enregistré. Quand le signal et la référence sont décrits par une succession de lettres, la procédure de détection suppose la création d'une mesure de distance adaptée, permettant la comparaison entre ces deux informations. La mesure de distance utilisera la logique floue et prendra en compte la fonction d'appartenance de la forme aux sous ensembles flous formés des lettres de l'alphabet.

2.5.4. Mise en œuvre de techniques de fouille de données afin de construire automatiquement les signatures de référence d'anomalies

La transformation d'un flot continu de données en une suite de lettres constitue une simplification et une réduction d'information qui rend possible l'utilisation de techniques de fouille de données. L'objectif de cette recherche est de mettre en œuvre des techniques de fouille de données adaptées permettant d'extraire des modèles de référence d'anomalies à partir d'une base de données constituée de séries temporelles multivariées, où l'occurrence d'une anomalie a pu être détectée à priori par un expert sur les données.

Cette phase constitue une phase d'apprentissage à partir des données permettant l'élaboration de modèles. La procédure de détection faisant suite utilise la mesure de distance floue définie en 2.5.3 ou les modèles flous définis en 2.5.1.

3. Diagnostic par reconnaissance de formes. Application au diagnostic de choc hémorragique et à l'analyse du sommeil humain

Dans ce chapitre, nous présentons l'utilisation de techniques de reconnaissance de formes pour le diagnostic de systèmes médicaux. Après une description rapide du principe du diagnostic par reconnaissance de formes, nous décrirons deux applications :

Le diagnostic automatique du choc hémorragique de blessé traumatisé. Ce travail a été réalisé dans le cadre de la thèse de Guillaume Becq, soutenue en Décembre 2004 ([BEC 04]), en collaboration avec le CRSSA (Centre de Recherche du Service de Santé des Armées), qui a commandé cette étude et le TimC (co encadrement de la thèse de Guillaume Becq par Pierre Baconnier). Ce travail a aussi servi de support au master recherche spécialité Automatique de Grégory Brouillet, présenté en Juin 2003 ainsi qu'au stage de fin d'études de Lukas Zoubek de Février à Juin 2003.

L'analyse du sommeil humain, dans le cadre de la thèse de Lukas Zoubek en cours, co-encadrée avec Suzanne Lesecq et effectuée en co-tutelle avec l'université technologique d'Ostrava en République Tchèque. Ce travail est réalisé en collaboration avec la société PhiTools qui commercialise un logiciel d'analyse de phases du sommeil.

3.1. Principe du diagnostic par reconnaissance de formes

Reconnaître une forme consiste à associer un élément (une forme), défini par un ensemble d'attributs (ou caractéristiques), à une classe donnée. Par exemple, on peut reconnaître un fruit, en fonction de sa forme et de sa couleur.

Réaliser le diagnostic d'un système par reconnaissance de formes consiste donc à décrire le système à un instant donné par n caractéristiques, qui constituent le vecteur forme, et construire une fonction de décision permettant de classer cette forme en une classe parmi d classes possibles. Les classes correspondent aux différents états que l'on cherche à reconnaître. Le système à un instant donné est ainsi représenté par un point dans un espace de n paramètres, nommé espace de représentation. La fonction de décision partitionne l'espace de représentation en d régions, chaque région correspondant à un état donné. L'appartenance d'un point à une région particulière de l'espace de représentation détermine la classe à laquelle il appartient.

Le principe du diagnostic par RDF est décrit par la Figure 16.

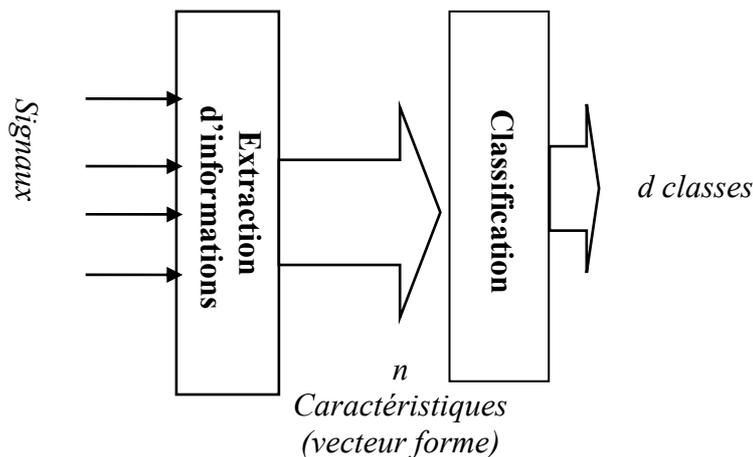


Figure 16 : Principe du diagnostic par reconnaissance de formes

Un ensemble de capteurs permettent l'enregistrement de signaux sur le système. Les signaux sont filtrés et mis en forme. Les caractéristiques sont ensuite extraites des signaux et forment les entrées de la fonction de décision qui classe la forme observée à l'instant t en une des classes (états) possibles.

Construire un système de diagnostic par reconnaissance de formes consiste donc dans un premier temps à choisir les caractéristiques du vecteur forme (déterminer l'espace de représentation) puis à apprendre la fonction de décision à partir d'une base de données d'apprentissage (définir les frontières des différentes régions)

Les différentes phases de l'élaboration d'un système de diagnostic par RDF sont :

- la construction d'une base de données d'apprentissage
- l'extraction des caractéristiques
- la sélection des caractéristiques pertinentes
- l'apprentissage de la fonction de décision
- la validation du système.

3.1.1. Construction de la base d'apprentissage

La base d'apprentissage doit être construite avec soin, car les performances des fonctions de décision dépendent de la qualité des exemples utilisés pour l'apprentissage. L'ensemble des états que l'on cherche à reconnaître doit être représenté dans la base par un nombre d'exemples suffisants et correctement expertisés. Les exemples doivent correspondre à des enregistrements effectués pendant des périodes de temps où le système est stationnaire dans un état, en évitant si possible les périodes de transitions d'un état vers un autre, au cours desquelles l'état du système est indéterminé.

3.1.2. Extraction des caractéristiques

Les informations enregistrées sur le système via les capteurs sont des signaux. L'extraction de caractéristiques consiste à extraire des signaux préalablement filtrés les informations pertinentes pour reconnaître les états que l'on recherche. Un signal enregistré au cours du temps implique une dimension temporelle. Or, le classement en différentes classes par la fonction de décision est

une opération statique, où le temps n'intervient pas. Le système est représenté à un instant k par n caractéristiques auxquels on associe une classe. L'extraction des caractéristiques consiste donc à découper les signaux en fenêtres temporelles dont on extrait les informations décrivant le système à l'instant k. L'hypothèse de stationnarité doit être vérifiée pour effectuer une estimation fiable de la caractéristique. Les fenêtres temporelles peuvent être de durée fixe, avec ou sans recouvrement, ou de durée variable, faisant suite à une procédure de segmentation en périodes stationnaires.

Les caractéristiques peuvent être ensuite soumises à des transformations afin de rendre toutes les entrées de la fonction de décision homogènes, c'est-à-dire de même ordre de grandeur.

Notons que les caractéristiques des exemples de la base d'apprentissage doivent être extraites avec beaucoup de soins, la présence de valeurs erronées pouvant dégrader les performances en déformant les classes et donc introduire une erreur sur les frontières de décision calculées lors de la phase d'apprentissage.

3.1.3. Sélection de caractéristiques pertinentes

Le choix des caractéristiques formant le vecteur forme a une grande incidence sur les performances du système de diagnostic. Un mauvais choix de caractéristiques peut conduire à l'obtention de classes mal séparées (recouvrement des régions), et ainsi à des performances médiocres de classification. Le choix des caractéristiques pertinentes peut être guidé par la connaissance (les caractéristiques sont choisies par un expert du domaine), ou guidé par les données, comme nous le verrons plus tard.

3.1.4. Apprentissage de la fonction de décision

La fonction de décision D est apprise à l'aide de la base d'apprentissage. La base d'apprentissage est composée d'un ensemble de N individus, $X=(x_1, x_2, \dots, x_N)$, avec x_j un vecteur forme composé des n caractéristiques $x_j=(x_{j1}, x_{j2}, \dots, x_{jn})$. On parle d'apprentissage supervisé quand la classe à laquelle appartient chaque individu est connue a priori (donnée par un expert). Dans ce cas, la base d'apprentissage Y est formé d'un ensemble de vecteurs formes X et d'un ensemble d'étiquettes Z, $Y=(X : Z)$. Dans la suite, nous nous restreindrons à ce cas particulier.

La fonction de décision D est un classifieur. C'est une fonction de R^n vers $Z^d=\{\omega_1, \omega_2, \dots, \omega_d\}$, l'ensemble des classes. Soit x, la forme à classer. $D(x) = \omega_i$ avec $i \in \{1, \dots, d\}$

Dans le cas de l'apprentissage supervisé, l'objectif de la fonction de décision est de copier la décision de l'expert. Le choix de la fonction de décision dépend du problème de classification (classes nettes ou floues) et de la répartition des points dans l'espace des paramètres (classes linéairement séparables ou non). Quelques exemples de classifieurs sont détaillés ci-dessous.

3.1.4.1. Classifieurs utilisant la règle de Bayes

Certains classifieurs utilisent la règle de Bayes ([FUK 90], [DUB 90]). Soit x, le vecteur forme à classer dans une des classes ω_i , $i=1$ à d.

L'attribution du vecteur x à la classe ω_i est effectuée à partir des probabilités conditionnelles a posteriori, $P(\omega_i / x)$ définies par **Eq.31**, en prenant en compte des coûts d'erreur de classification.

$$P(\omega_i / x) = \frac{p(x / \omega_i) \cdot P(\omega_i)}{p(x)} \text{ avec } p(x) = \sum_{k=1}^d p(x / \omega_k) \cdot P(\omega_k) \quad \text{Eq. 31}$$

où $P(\omega_i / x)$ est la probabilité à postériori d'avoir la classe ω_i , sachant x , $P(\omega_i)$ est la probabilité d'avoir ω_i à priori, $p(x / \omega)$ est la densité de probabilité de x sachant ω_i .

Dans le cas de coûts binaires (coût de ne pas se tromper nul, coûts de se tromper identiques, égal à 1, quelle que soit l'erreur de classification), la forme x est attribuée à la classe la plus probable. La règle de décision s'écrit :

$$D(x) = \omega_i \text{ si } \ln(P(\omega_i / x)) = \max_{k=1 \text{ à } d} (\ln(P(\omega_k / x))) \quad \text{Eq. 32}$$

L'apprentissage de la fonction de décision consiste donc à estimer les densités de probabilité $p(x / \omega_k)$, pour $k=1$ à d , à partir des données de la base d'apprentissage. Deux types d'approches sont possibles :

- la densité de probabilité $p(x / \omega_k)$ est supposée connue. L'apprentissage consiste à en estimer les paramètres. On parle alors de méthode paramétrique.

Le modèle choisi est en général le modèle gaussien multidimensionnel. Les paramètres à estimer sont les moyennes et matrices de variance covariance pour chacune des classes. Si les matrices de variance covariance sont supposées être identiques quelle que soit la classe, la règle de décision génère des frontières linéaires dans l'espace des paramètres. Si elles sont supposées différentes, les frontières sont quadratiques. Ces méthodes s'appliquent quand les formes des classes dans l'espace des paramètres sont de type ellipsoïdales (classes linéairement séparables).

- la densité de probabilité $p(x / \omega_k)$ est supposée inconnue. On utilise alors des méthodes non paramétriques, qui estiment la densité de probabilité directement à partir des données. Parmi ces méthodes se trouvent la méthode des k plus proches voisins (kPPV) et l'estimateur de Parzen à l'aide de noyaux. Ces méthodes ont l'avantage de ne faire aucune hypothèse sur la répartition des données dans l'espace des paramètres, et peuvent donc être utilisées quelle que soit la forme des classes (classes non linéairement séparables). Les frontières générées par la règle de décision sont de formes quelconque. Cependant, ces méthodes nécessitent des réglages à priori de paramètres (nombre de voisins k , choix de la fonction noyau). En utilisation (classification d'un nouveau cas), elles sont gourmandes en mémoire (tous les points de la base d'apprentissage doivent être conservés), et en temps de calcul.

3.1.4.2. Classifieurs fondés sur un calcul direct des frontières

3.1.4.2.1. Réseaux de neurones

Le réseau de neurones artificiel est un algorithme qui réalise une fonction entre plusieurs entrées et plusieurs sorties par la mise en association d'unités fonctionnelles appelées neurones artificiels ([HER 94], [THI 97])

Chaque neurone a la particularité de recevoir plusieurs entrées et de ne disposer que d'une seule sortie. La sortie du neurone est une fonction des entrées pondérées par des poids.

On parle de perceptron multicouche lorsque le réseau de neurones est composé de plusieurs couches (une couche faisant référence à un ensemble de neurones n'ayant pas de connections entre eux). Pour un problème de classification d'un vecteur forme composé de n caractéristiques en d classes, le réseau de neurones est formé d'une couche d'entrée composé de n neurones, chaque neurone étant relié à une des n caractéristiques du vecteur forme, d'une couche de sortie

composé de d neurones, chaque neurone étant relié à une des classes à reconnaître et de couches cachées (une couche suffit en général), composée d'un nombre de neurones quelconque.

L'apprentissage du réseau de neurones par rétropropagation du gradient de l'erreur consiste à modifier les poids de chaque neurone de manière à minimiser l'écart entre la sortie calculée par le réseau et la sortie désirée (la classe attribuée à la forme par l'expert) pour l'ensemble des exemples de la base d'apprentissage. L'algorithme d'apprentissage converge en général vers une structure stable mais qui peut correspondre à une solution locale. L'utilisation de plusieurs initialisations aléatoires des poids du réseau permet d'obtenir le réseau le plus performant.

Les frontières générées par un réseau de neurones dépendent de la structure du réseau et sont de formes quelconques. L'utilisation d'un réseau de neurones ne nécessite aucune hypothèse préalable sur la répartition des données dans l'espace des paramètres. Le choix de la structure la plus performante et l'apprentissage du réseau de neurones sont des tâches coûteuses en temps. Par contre, le temps de prise de décision en utilisation (classification de nouveaux cas) est rapide et le nombre d'informations à sauvegarder est restreint (la valeur des poids du réseau).

3.1.4.2.2. Induction d'arbres de décisions

L'induction par arbre de décision consiste à découper l'espace des paramètres en sous régions de plus en plus pures en terme de classes à partir d'un processus récursif de division. Le problème de classification est ainsi décomposé en une suite de tests imbriqués portant sur une variable ou une combinaison de variables [QUI 93].

La fonction de décision apprise à partir des données est décrite par un arbre de décision, dont chaque nœud correspond à un test sur la valeur d'une caractéristique et dont les feuilles sont l'appartenance de la forme à une classe. L'arbre est construit de manière automatique à partir des données de la base d'apprentissage.

Un des atouts de la méthode est l'intelligibilité des règles qu'elle produit, ce qui permet l'extraction explicite de connaissance à partir d'un ensemble de données. La méthode s'applique sans restriction sur la répartition des données. Elle est rapide en utilisation. Les régions de décision correspondent à des associations d'hypercubes.

3.1.5. Validation du système de diagnostic

La validation du système de diagnostic consiste à vérifier les capacités du système à classer de nouveaux exemples. Ainsi, le pourcentage de exemples mal classés par le système dans la base d'apprentissage, appelée erreur apparente ou erreur en apprentissage, ne peut pas constituer un critère de validation. Seul le pourcentage de nouveaux exemples mal classés, l'erreur réelle ou erreur en test, peut fournir un indice de performance. Il est donc nécessaire de réserver, dans la base d'apprentissage, des exemples qui serviront ultérieurement à la validation. La base de données est divisée en deux parties : une base d'apprentissage, qui permet l'apprentissage des fonctions de décisions et une base de test, qui permet l'estimation de l'erreur réelle. Les performances en apprentissage des fonctions de décision s'améliorent avec la taille de la base d'apprentissage alors que la précision de l'estimation de l'erreur réelle augmente avec la taille de la base de test. Si la base de données ne comporte pas suffisamment d'exemples, le fait de la scinder en deux parties peut nuire à la qualité de l'apprentissage. On peut alors avoir recours à des techniques de validation croisée. La base de données est scindée en x paquets de taille égale. $x-1$ paquets sont regroupés pour former la base d'apprentissage et le paquet restant sert à la validation. Une permutation circulaire sur les x paquets permet d'obtenir x estimations de

l'erreur, en vérifiant toujours la contrainte que les exemples servant à l'apprentissage ne sont pas utilisés pour la validation. La moyenne des x valeurs d'erreurs obtenues permet une estimation précise de l'erreur réelle.

3.2. Diagnostic de choc hémorragique sur blessé traumatisé

3.2.1. Objectifs

Le sujet de ce travail a été proposé par le CRESSA, dans le cadre d'une recherche amont sur la récupération de blessés sur champs de bataille. L'idée du projet est de fournir au soldat un gilet portable, équipé de capteurs mesurant les signaux physiologiques, capable de fournir une indication sur son état de santé, suite à une blessure.

Dans les services d'urgence hospitaliers ou dans les centres militaires de triage de blessés, le personnel médical doit déterminer très rapidement si un patient est dans un état qui nécessite une intervention médicale immédiate ou si il peut attendre. En médecine d'urgence, le traumatisme est la première cause de mortalité chez les jeunes blessés [CHAM 03]. La probabilité de survie d'un patient traumatisé dépend de la quantité de sang perdu, qui génère un choc hémorragique. Sans soins médicaux, l'état d'un patient ayant subi une forte perte de sang évolue d'un stade de choc hémorragique compensé vers un stade de choc hémorragique progressif (ou non compensé) puis vers un stade irréversible ([PLA 94]).

L'objectif de ce travail est d'étudier la faisabilité d'un système portable capable de diagnostiquer automatiquement l'état de choc hémorragique d'un patient, ayant les propriétés suivantes :

Le système ne nécessite aucune connaissance médicale à priori sur le patient

Le système est équipé de capteurs non invasifs (ne nécessitant aucune chirurgie), permettant d'enregistrer les signaux physiologiques, voire de capteurs possibles à intégrer dans un gilet portable

Le système est capable de fournir une information sur l'état du patient (*rien à signaler, choc compensé, choc non compensé, choc irréversible*) en ligne, à intervalles réguliers.

Le système doit intégrer la chaîne complète de traitement, depuis l'acquisition des signaux physiologiques via les capteurs, leur filtrage, l'extraction des caractéristiques et la décision. L'étude consiste à choisir les signaux physiologiques et les caractéristiques pertinentes, à développer des procédures d'extraction de ces caractéristiques en ligne et de proposer et évaluer les performances de la fonction de décision.

3.2.2. Matériel

3.2.2.1. Expériences

Un protocole expérimental sur des porcs charcutiers d'une vingtaine de kilos a été proposé au comité d'éthique du Centre de Recherche du Service de Santé des Armées et réalisé sur 17 animaux. Après anesthésie de l'animal, une spoliation sanguine contrôlée est effectuée à un débit constant de 5 à 7 ml/min de façon à provoquer une perte de 50% du volume sanguin total en 90 minutes. La spoliation sanguine est maintenue jusqu'au décès de l'animal, qui survient en 1h30 à 3 heures à l'issue d'une phase plus ou moins prolongée de choc hémorragique irréversible.

3.2.2.2. Signaux

Au cours de l'expérience, les signaux physiologiques suivants sont enregistrés :

- l'électrocardiogramme - *ECG* - enregistré à 500Hz
- la pression artérielle invasive -*PA*- (cathéter carotidien), à 500 Hz
- la pression veineuse centrale -*PVC*- (cathéter jugulaire) à 500Hz
- deux ondes de pouls, l'un sur le groin à l'aide d'un oxymètre Kontron à 500 Hz - *PulseK* , l'autre sur l'oreille à l'aide d'un oxymètre Biopac, à 500Hz -*PulseB*.
- La saturation pulsée en oxygène - *SpO₂* - à 15,625 Hz
- L'effort respiratoire thoracique -*Tho*- à 125 Hz
- L'effort respiratoire abdominal - *Abd*- à 125 Hz
- La température interne *Tint*, à 15,625 Hz
- La température cutanée *Tcut*, à 15,625 Hz.

Les signaux de pressions artérielle et veineuse ainsi que la température interne sont obtenus à l'aide de capteurs invasifs. Les autres proviennent de capteurs non invasifs.

3.2.2.3. Caractéristiques

Les caractéristiques sont extraites des signaux correctement filtrés, à partir de fenêtres temporelles de durée Δt fixe, sans recouvrement. Deux jeux de caractéristiques sont extraits : l'un dit invasif, contenant les caractéristiques extraites de signaux mesurés par des capteurs invasifs, l'autre dit portable, contenant les caractéristiques extraites de signaux mesurés par des capteurs non invasifs. Toutes les caractéristiques ont été extraites en accord avec l'expert médical. Elles donnent des informations sur les fonctions respiratoire et circulatoire.

Les caractéristiques invasives retenues sont : la pression artérielle systolique (PAS), la pression artérielle diastolique (PAD), la pression artérielle moyenne (PAM), l'écart type de la pression artérielle (σ_{PA}), la différentielle de pression (Δ_{PA}), le rapport basses fréquences sur hautes fréquences de la pression veineuse ($LFHF_{PVC}$), la température interne.

Les caractéristiques portables retenues sont : l'écart type de l'ECG (σ_{ECG}), la fréquence cardiaque (FC), le rythme respiratoire mesuré au niveau du thorax (RRtho) et au niveau de l'abdomen (RRabd), le volume courant mesuré au niveau thorax (Vtho) et au niveau abdomen (Vtabd), la saturation pulsée en oxygène (SpO_2), l'écart type de l'onde de pouls mesuré par l'oxymètre Kontron (σ_{PoulsK}), et de celui mesuré par l'oxymètre Biopac (σ_{PoulsB}), le rapport basses fréquences sur haute fréquence de l'onde de pouls, mesurée par l'oxymètre Kontron ($LFHF_{PulsK}$) et par l'oxymètre Biopac ($LFHF_{PulsB}$), la température cutanée (T_{cut}).

Une analyse sur la taille de fenêtre temporelle Δt la plus appropriée à cette étude a montré que les meilleurs résultats en classification étaient obtenus avec $\Delta t=60s$. La taille de la fenêtre a une incidence sur la qualité d'estimation des caractéristiques, et plus particulièrement sur les paramètres respiratoires qui sont d'autant mieux estimés que la fenêtre est longue.

3.2.2.4. Expertise

Quatre classes ont été retenues pour la réalisation de la classification par un expert. Elles correspondent aux différents états rencontrés au cours du choc hémorragique : Rien à signaler, Choc compensé, Choc décompensé, Choc irréversible.

L'expert a sélectionné un ensemble de caractéristiques qu'il jugeait pertinentes pour réaliser cette classification, provenant de capteurs invasifs et de capteurs portables {PAM, PAS, PAD, FC, Tint, Tcut, RRabd, RRtho, VTabd, VTTho}. Il a utilisé un raisonnement causal en faisant glisser une fenêtre d'analyse d'une durée de sept minutes et a attribué une classe parmi les quatre par période d'une minute. Chaque enregistrement sur animal est ainsi décomposé en une succession d'états de choc hémorragique d'une durée de 1 minute. Le temps moyen passé dans chacune des classes est à peu près équivalent, le nombre d'exemples par classe est donc sensiblement le même.

3.2.3. Méthodes

Des techniques de sélection de caractéristiques pertinentes, conduites par les données, ont été appliquées, afin de déterminer quelles sont les caractéristiques à retenir parmi celles proposées, permettant le diagnostic automatique de choc hémorragique. La technique d'extraction de caractéristiques Selective Forward Search (SFS) a été appliquée en utilisant les caractéristiques proposées en 3.2.2.3. Bien que cette technique ne soit pas optimale et qu'elle ne prenne pas en compte les liens entre les différentes caractéristiques, nous avons choisi cette technique pour sa simplicité de mise en oeuvre et sa simplicité d'analyse des résultats. La technique de sélection de Selective Backward Search (SBS) a été utilisée pour confirmer les résultats.

3.2.3.1. Sélection de caractéristiques

Soient f_1, f_2, \dots, f_n n caractéristiques à sélectionner. Soit F , un sous ensemble de ces n caractéristiques et \bar{F} le sous ensemble des caractéristiques non contenues dans F .

$$F \cup \bar{F} = \{f_1, f_2, \dots, f_n\}$$

$$F \cap \bar{F} = \emptyset$$

Soit J , un critère à optimiser et $J(F)$, le critère J calculé à l'aide des caractéristiques contenues dans F . La sélection de caractéristiques SFS est une technique itérative qui sélectionne à chaque pas i le sous ensemble de caractéristiques F_i qui maximise J .

3.2.3.1.1. Selective Forward Selection (SFS)

La méthode consiste, à chaque pas i , à incrémenter de un le nombre de caractéristiques contenues dans F_{i-1} . Soit F_{i-1} le sous-ensemble de caractéristiques sélectionnées au pas $i-1$, qui maximise J . F_{i-1} contient $i-1$ caractéristiques sélectionnées aux pas précédents. \bar{F}_{i-1} contient les $n-i+1$ caractéristiques qu'il reste à sélectionner. Au pas i , une nouvelle caractéristique f_i est sélectionnée parmi \bar{F}_{i-1} telle que $J(F_{i-1} \oplus f_i) = \max(J(F_{i-1} \oplus f_k))$ avec $f_k \in \bar{F}_{i-1}$

Au départ, F_0 est initialisé à $F_0 = \{\emptyset\}$.

3.2.3.1.2. Critère

Le critère J à optimiser est une fonction de l'erreur de classification en validation. L'objectif de l'étude étant l'analyse de faisabilité d'un système capable de diagnostiquer un état de choc hémorragique sans connaissance à priori sur le patient, à partir d'une fonction de décision apprise sur des données provenant d'autres patients, nous avons choisi comme méthode d'estimation de l'erreur de classification une méthode de validation croisée adaptée à notre problème. La base de données est décomposée en 14 sous-ensembles, chaque sous-ensemble étant composé de l'enregistrement sur un animal. 13 enregistrements sur animaux sont regroupés pour former la base d'apprentissage, l'enregistrement sur l'animal restant servant de base de test. Une

permutation circulaire est réalisée sur les 14 enregistrements afin d'obtenir des performances en validation sur chaque animal. Nous obtenons ainsi une erreur en validation « dans le pire des cas », où aucune donnée provenant de l'animal de test n'est utilisée pour l'apprentissage. Un tirage aléatoire est réalisé sur les données provenant des 13 animaux de la base d'apprentissage de manière à obtenir un nombre égal d'exemples par classe.

Le critère J à optimiser est ainsi la moyenne des erreurs de classification pour chaque animal.

$$J = \frac{1}{N} \sum_{i=1}^N err_{T_i} \quad \text{Eq. 33}$$

$$\text{avec } err_{T_i} = \frac{\text{card}\{\text{exemple } j / E(\text{exemple } j) \neq C(\text{exemple } j)\}}{n_i}$$

où N vaut 14, $E(\text{exemple}_j)$ est la classe attribuée par l'expert à l'exemple j, $C(\text{exemple}_j)$ est la classe attribué par le classifieur C à l'exemple j et n_i est le nombre d'exemples de l'enregistrement de l'animal i.

3.2.3.2. Classifieurs

Plusieurs classifieurs ont été mis en œuvre afin d'évaluer leurs performances sur notre problème : un classifieur naïf (classifieur bayésien où les lois de probabilités sont supposées gaussienne et où les variables sont supposées indépendantes les unes des autres), un classifieur linéaire, un classifieur quadratique, un classifieur par k plus proches voisins (dont une version floue), un classifieur par estimateur de Parzen avec noyau Gaussien, un réseau de neurones et un classifieur par induction d'arbres de décision de type C4.5. Chacun part d'hypothèses différentes sur la répartition des points dans l'espace des paramètres et découpe l'espace des paramètres en des régions dont la forme des frontières diffère. Un classifieur aléatoire (classement au hasard) a été utilisé comme référence de comparaison.

Les classifieurs présentés dans l'étude ainsi que leur abréviations sont présentés Tableau 3.

Nom du classifieur	Abréviation (paramètre)
linéaire	Lin
quadratique	Quad
naïf	Naïf
k plus proches voisins	kPPV (k)
estimateur de Parzen	Parzen (α)
aléatoire	Aléa
perceptron multi couche	PMC
arbre de décision C4.5	C4.5
k plus proches voisins flous	kPPV(k, Kinit, m)

Tableau 3 : Classifieurs utilisés et leur abréviations

3.2.4. Résultats

La sélection des caractéristiques pertinentes a été réalisée avec un classifieur quadratique. Celui-ci a été choisi pour sa rapidité computationnelle en apprentissage et en validation. Nous avons par la suite montré que ce classifieur est de plus très compétitif pour notre problème.

La Figure 17 montre la progression de la sélection obtenue sur l'ensemble des caractéristiques (invasives et portables). L'erreur en apprentissage, err_A , correspond à la moyenne des erreurs obtenues sur les 14 ensembles d'apprentissage (erreur apparente). L'erreur réelle err_T correspond au critère J que l'on cherche à optimiser, défini par **Eq.33**.

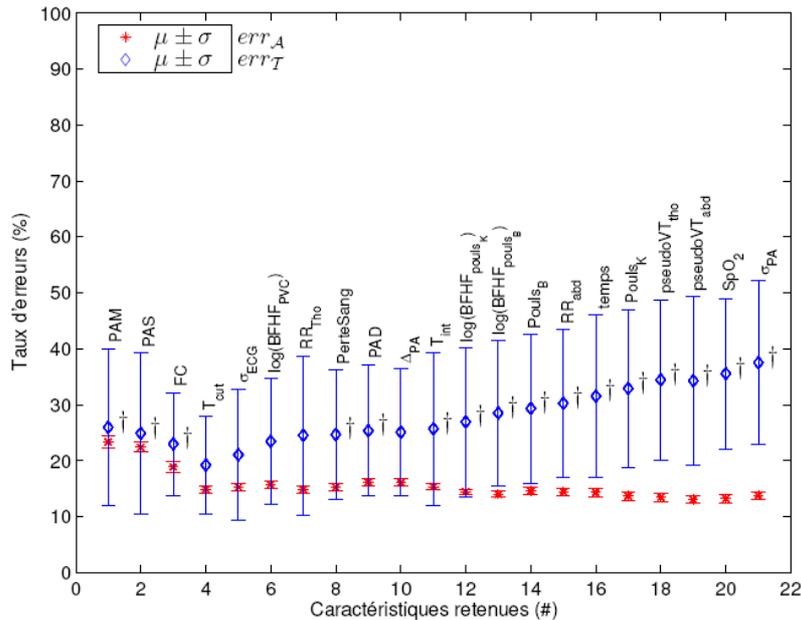


Figure 17 : Sélection ascendante de caractéristiques par un classifieur quadratique sur l'ensemble des caractéristiques disponibles par *leave one animal out*. Les valeurs notées d'une croix indiquent une différence significative entre les échantillons de l'ensemble marqué et ceux de l'ensemble de référence {PAM, PAS, FC, Tcut} correspondant à l'erreur réelle la plus faible. Le test effectué est un test de Wilcoxon.

Le critère atteint un minimum égal à 20% lorsque quatre caractéristiques sont retenues {PAM, PAS, FC, Tcut}. La machine ne peut apprendre un meilleur modèle que celui obtenu avec ces quatre caractéristiques et ceci bien qu'elle ait accès à l'ensemble des variables utilisées par le médecin pour son expertise. Ces quatre caractéristiques font toutes partie de l'ensemble sélectionné par l'expert. Il semblerait que l'expert ait essentiellement fondé sa décision sur la valeur de la pression artérielle. Les 20 % d'erreurs que fait la machine peuvent être expliqués par les ambiguïtés existantes aux frontières des différentes classes ainsi que par les erreurs de classification de l'expert. En effet, de par l'expérimentation, le passage d'un état à un autre passe par une phase transitoire au cours de laquelle il est difficile à l'expert d'affecter une classe avec certitude. Pour la machine, ces phases transitoires génèrent des recouvrements de classes adjacentes. L'analyse de la matrice de concordance, mettant en relation les classes attribuées par l'expert avec celle obtenues par la machine confirment que les erreurs se produisent entre les classes adjacentes.

La comparaison des résultats obtenus par différents classifieurs à partir des quatre caractéristiques {PAM, PAS, FC, Tcut} montrent que les performances moyennes sont de 25% d'erreur (Figure

18). Les meilleurs classifieurs sur ce problème sont le classifieur quadratique et le réseau de neurones qui ne font que 20% d'erreur.

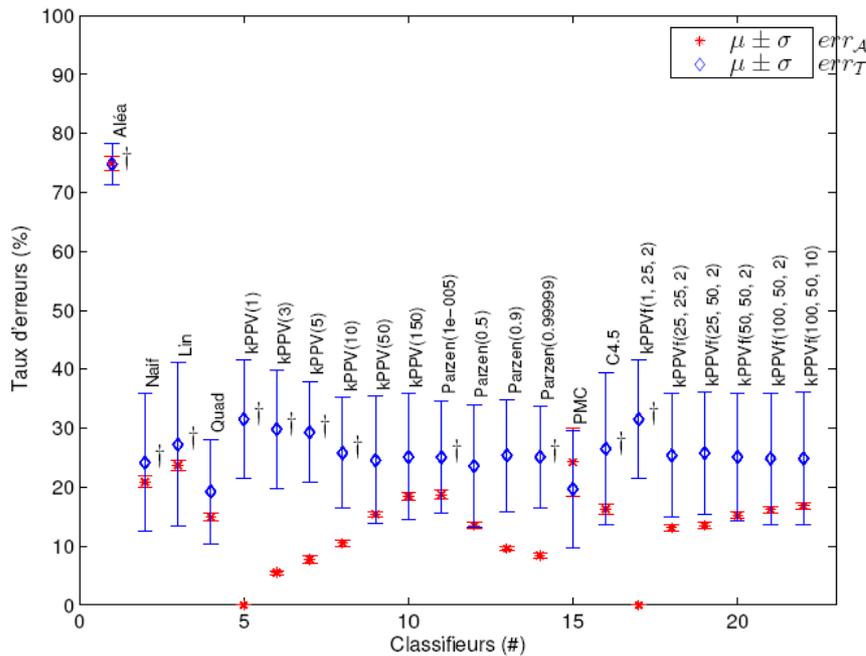


Figure 18 : Comparaison des performances obtenues par les différents classifieurs à partir du jeu de caractéristiques {PAM, PAS, FC, Tcut}. La croix indique une différence significative entre les échantillons de l'ensemble marqué et ceux obtenus par un classifieur quadratique, correspondant à l'erreur en test la plus faible. Le test effectué est un test de Wilcoxon.

L'objectif du système étant l'élaboration d'un système portable, la procédure de sélection de caractéristiques a été appliquée sur les caractéristiques portables uniquement (Figure 19). Les quatre premières caractéristiques retenues sont {FC, RR_{abd}, T_{cut} et Poul_s_k}. Notons qu'il n'y a pas d'amélioration significative après la sélection de Tcut (test de rang de Wilcoxon au seuil 5% par comparaison avec le modèle ayant obtenu le critère J le plus faible).

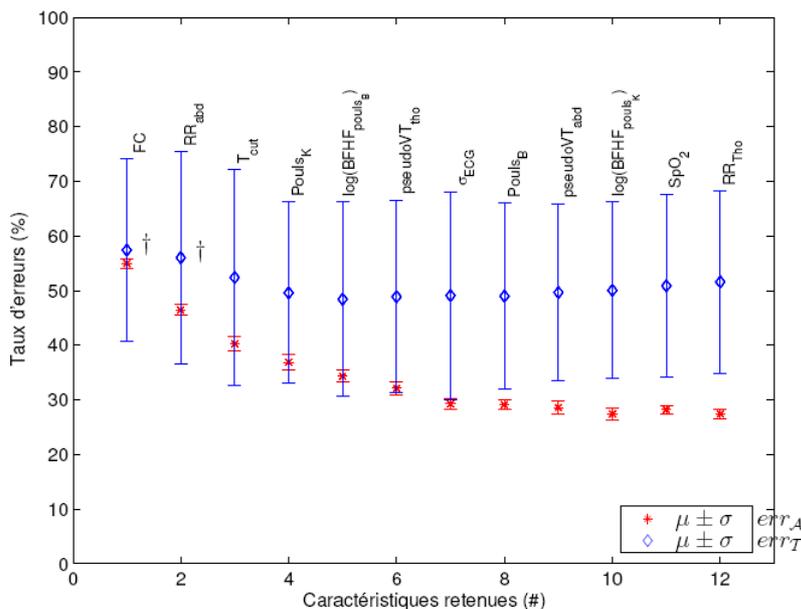


Figure 19 : Sélection ascendante de caractéristiques par un classifieur quadratique sur l'ensemble des caractéristiques portables disponibles par leave one animal out. Les valeurs notées d'une croix

indiquent une différence significative entre les échantillons de l'ensemble marqué et ceux de l'ensemble de référence {FC, RRabd, Tcut, PoulsK, log(LFHF_{PoulsB})}, correspondant à l'erreur en test la plus faible. Le test effectué est un test de Wilcoxon.

La comparaison de tous les classifieurs montre que le PMC obtient les meilleurs résultats avec 40.9% d'erreurs en validation (Figure 20). Le large écart type obtenu, et ceci quel que soit le classifieur, est dû à la grande diversité de résultats obtenue sur les différents animaux (certains sont bien classés par la machine alors que d'autres ont un taux d'erreur très élevé).

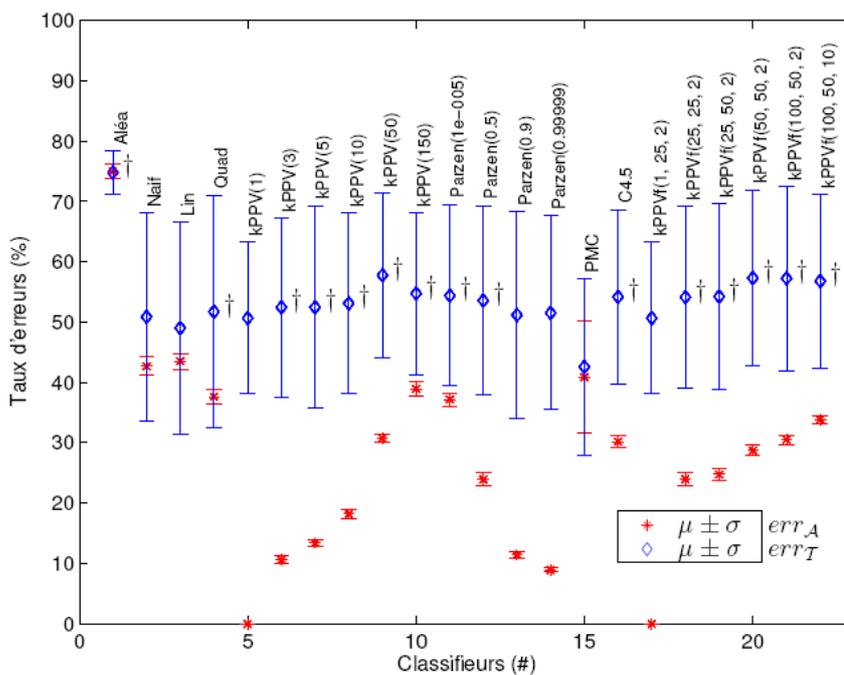


Figure 20 : Comparaison des performances obtenues par les différents classifieurs à partir des caractéristiques portables retenues. La croix indique une différence significative entre les échantillons de l'ensemble en question et ceux obtenus par un perceptron multicouche, correspondant à l'erreur en test la plus faible. Le test effectué est un test de Wilcoxon.

La procédure SFS a été appliquée avec un classifieur PMC. Les caractéristiques sélectionnées ont été {PAM, PAS, FC, Tcut} pour l'ensemble des caractéristiques et {FC, RRabd, Tcut, Spo2} pour les caractéristiques portables. La similarité entre les sous-ensembles obtenus avec le PMC et le classifieur quadratique accorde du crédit au choix de ces caractéristiques. Elles ont par ailleurs été jugées pertinentes par l'expert médical.

3.2.5. Visualisation de l'évolution du choc hémorragique

Les classifieurs appris à partir des données d'apprentissage découpent l'espace des paramètres en quatre régions, chacune correspondant à une classe de choc hémorragique. Afin de visualiser l'évolution de l'état de santé d'un individu, nous avons choisi de représenter la trajectoire du choc hémorragique dans un sous espace visible, de dimension 2 ou 3 (3 caractéristiques sont utilisées pour la représentation). Pour cela, un maillage du sous espace à trois dimensions est réalisé en découpant l'espace en cubes de dimension égale. Le sommet de chaque cube défini est associé à une des quatre classes en fonction de la décision prise par le classifieur. On réalise ainsi une

cartographie du sous espace des paramètres. Un nouveau vecteur forme sera affecté à la classe de la région dans laquelle il se situe.

Nous avons montré qu'en n'utilisant que les caractéristiques portables, trois caractéristiques suffisent pour déterminer la classe du choc. Aucune diminution significative de l'erreur de classification n'est obtenue par ajout d'une quatrième variable. Ceci nous permet donc de visualiser l'évolution de l'état de santé de l'animal sur les caractéristiques (FC, RRabd et Tcut), sans passer par un changement de représentation de type ACP. Cette représentation a l'avantage de faciliter le suivi de l'état de santé par un médecin qui connaît, à chaque période d'échantillonnage, la classe affectée au choc ainsi que la valeur des variables explicatives. Elle nous semble un outil d'aide au diagnostic utile pour un médecin régulateur. Un exemple de la représentation obtenue, les classes étant attribuées par un classifieur quadratique, est présenté Figure 21.

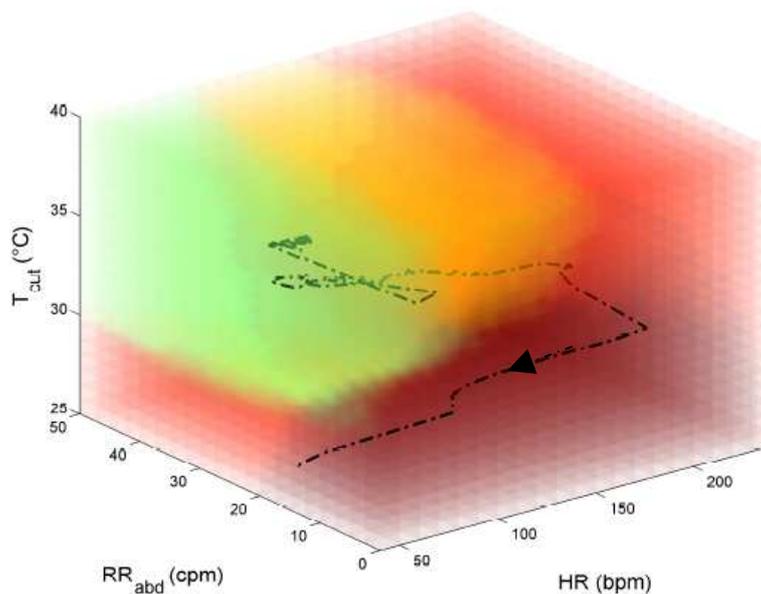


Figure 21 : Evolution dans un espace à trois dimensions de l'état de choc hémorragique d'un animal. Un point représente les valeurs de HR, Tcut et RR à un instant donné. Les régions correspondantes à différents états de choc hémorragique sont représentées par des couleurs allant du vert au rouge foncé. La flèche indique la direction du temps croissant.

L'évolution de l'état de choc peut aussi être visualisé dans un espace à 2 dimensions, qui correspond à une représentation plus habituelle. Pour ce faire, des coupes dans l'espace des trois caractéristiques sont réalisées, orthogonalement à une des caractéristiques. La trajectoire de l'état de santé est ensuite projetée sur ces coupes. Le résultat de telles projections est présenté Figure 22. Elle représente l'évolution de l'état de choc d'un animal subissant une spoliation sanguine, dans un espace à deux dimensions (RRabd et FC). Dans cet exemple, on peut observer le changement de contours des régions de classification au cours de l'expérimentation. Ces changements sont dus aux changements de coupes dans l'espace à trois dimensions, qui dépendent de l'évolution de la troisième variable, Tcut. Cette variable semble cachée pour un observateur mais la connaissance de sa valeur influe sur les contours des régions de classification. Ceci permet de réaliser un diagnostic en prenant en compte trois variables, tout en améliorant la représentation, c'est-à-dire en facilitant l'interprétation de l'évolution pour un observateur

externe. Le choix des couleurs, variant du vert au rouge foncé en fonction de la gravité du choc, a été effectué pour faciliter l'interprétation des résultats.

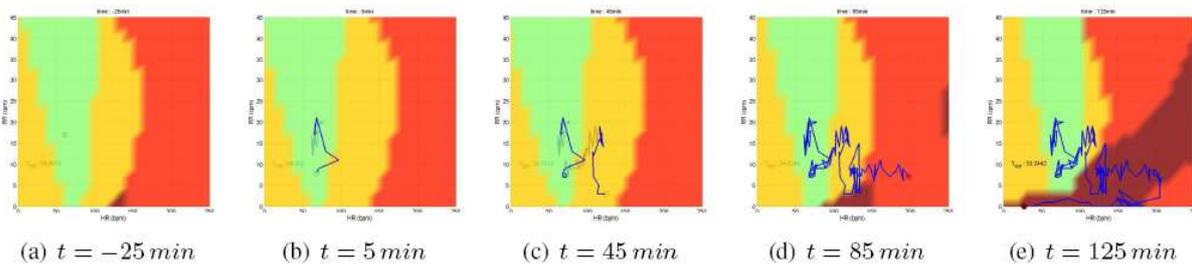


Figure 22 : Projection de l'état dans un espace à deux dimensions (FC, RR) à différents instants au cours du choc hémorragique. L'instant $t=0$ min correspond au début de la spoliation sanguine. L'expérimentation débute 25 minutes avant. L'état évolue dans un espace à trois dimensions (FC, RR, Tcut) sur lequel on réalise des coupes perpendiculairement à l'axe Tcut.

3.2.6. Conclusion et perspectives

Si les résultats obtenus en utilisant toutes les caractéristiques montrent que la machine peut faire aussi bien que l'expert quand elle peut utiliser les mêmes informations que lui, les résultats obtenus avec les caractéristiques portables semblent moins satisfaisants. L'utilisation de plusieurs classifieurs de natures différentes aboutit à des performances comparables, ce qui permet de conclure que le problème provient bien des données et non de la méthode utilisée.

Cette difficulté de la machine à obtenir une classe correcte à partir des caractéristiques portables peut s'expliquer par le fait que le diagnostic de choc hémorragique est réalisé essentiellement à l'aide de la mesure de la pression artérielle. Or, aucune des caractéristiques portables extraites ne donnent une indication de sa valeur. La classification est réalisée à l'aide de caractéristiques moins discriminantes. Pour améliorer les résultats, il faudrait proposer de nouvelles caractéristiques, comme le temps de transit de pouls, la variabilité cardiaque mesurée sur cinq minutes, ou envisager d'autres capteurs portables.

La difficulté à obtenir une bonne classification par la machine provient aussi de la manière dont les expériences ont été conduites. En effet, de par la spoliation sanguine continue, les variables physiologiques sont en constante évolution. Ainsi, les phases transitoires de passage d'une classe à l'autre peuvent être de durée importante. Il est en fait impossible pour l'expert médical de déterminer le passage d'une phase à une autre avec certitude, ce qui génère des erreurs d'expertise. Cela s'observe d'ailleurs sur les données recueillies, où l'on observe de la part de l'expert, un retour en arrière dans la classification du niveau de choc. Ainsi, l'expert classe parfois les données en classe 3 (choc non compensé) pour revenir plus tard sur sa décision et classer des données postérieures en classe 2 (choc compensé). La proposition de faire des paliers de spoliation sanguine n'a pas été approuvée par l'expert médical car d'autres mécanismes physiologiques entrent alors en jeu.

Afin de s'affranchir de cette difficulté, diverses procédures de nettoyage des données d'apprentissage ont été appliquées, l'une utilisant les expertises, les deux autres fondées sur les données. Ainsi, nous avons dans un premier temps éliminé de la base d'apprentissage toutes les données pour lesquelles l'expert changeait de décisions pour deux classifications successives (zone d'instabilité de décision). Le nombre d'exemples éliminés correspond à 11% de la base de données. Nous avons dans un deuxième temps utilisé des techniques de nettoyage par 1ppv et par

condensation, dont le détail est décrit dans [COR 02]. Cependant, aucune des ces trois techniques n'a permis d'améliorer significativement les résultats.

Dans cette étude, nous nous sommes attachés à nous placer dans un contexte proche de l'utilisation future du système portable. L'idée est la création d'un système de diagnostic portable dans le cas d'application militaire, ou rapidement installé dans le cas de la médecine d'urgence, fournissant un diagnostic sans aucune information médicale préalable sur le patient (sans aucun pré examen effectué par un médecin). Ainsi, nous avons choisi un critère de validation des résultats le plus proche possible de la réalité de terrain. Les pourcentages d'erreur obtenus quand on utilise la moitié des données provenant de l'enregistrement d'un animal pour l'apprentissage et que l'on teste les résultats sur l'autre moitié de l'enregistrement sont bien inférieurs à ceux obtenus avec notre méthode de validation (15% avec toutes les caractéristiques, 17% avec les caractéristiques portables), mais ne correspondent pas au problème posé.

Les résultats obtenus montrent la faisabilité du système pour la médecine d'urgence. On peut envisager dans ce cas l'utilisation d'un Holter tension qui permet la mesure de pression artérielle de manière non invasive environ chaque cinq minutes et qui est un appareil rapide à installer. Par contre, cet équipement n'est pas intégrable dans un gilet portable par des soldats. La visualisation dynamique proposée pour le suivi de l'état du blessé semble néanmoins intéressante pour aider le médecin militaire à évaluer l'urgence de l'évacuation d'un blessé, en mettant en évidence les patients dont l'état est stable et ceux dont l'état se dégrade rapidement.

3.3. Analyse du sommeil humain par reconnaissance de formes

L'analyse du sommeil humain est effectuée par analyse polysomnographique. Celle-ci consiste à enregistrer sur le patient plusieurs signaux physiologiques - l'électroencéphalogramme ou EEG, l'électrooculogramme ou EOG et l'électromyogramme ou EMG - au cours d'une nuit de sommeil et à analyser ensuite ces signaux pour déterminer les différents stades du sommeil. La nuit de sommeil est décomposée en périodes de 20 secondes, appelées epochs. Chacune de ces epochs sont classées en une des 5 phases du sommeil humain, en fonction de la forme des signaux : éveil, phase 1, phase 2, phase 3 ou 4, sommeil paradoxal. Une nuit de sommeil est ainsi traduite sous la forme d'un hypnogramme décrivant la succession des différentes phases de sommeil du patient au cours de la nuit. Cet hypnogramme est un outil efficace de diagnostic des troubles du sommeil. Encore maintenant, l'analyse polysomnographique est effectuée par des médecins spécialistes du domaine, mais de nombreuses recherches sont effectuées pour remplacer cette analyse visuelle par une analyse automatique. L'objectif de ce travail de recherche est de participer à l'amélioration des performances des systèmes d'analyse polysomnographique automatiques en déterminant, à l'aide de techniques de fouille de données utilisant la reconnaissance de formes, quels sont les signaux les plus utiles et quelles sont les techniques de traitement de signal les plus appropriées pour reconnaître les différentes phases du sommeil.

3.3.1. Matériel

3.3.1.1. Base de données

Nous disposons d'une large base de données composée de 47 nuits d'enregistrements provenant de 41 patients sains sur lesquels 4 signaux EEG, un signal EOG et un signal EMG ont été

enregistrés à une fréquence de 128 Hz. Chacun des enregistrements a été visuellement analysé et transformé en un hypnogramme par deux experts indépendants. Chaque epoch, d'une durée de 20 secondes, a été classée en une des 5 phases de sommeil (éveil, PI, PII, PIII&IV, SP). Seules les epochs classées dans la même phase par les deux experts ont été utilisées, afin de minimiser le risque d'erreur d'expertise. Elles représentent 84% de l'ensemble de la base. Les phases de sommeil n'ayant pas toutes la même durée au cours d'une nuit, certaines phases sont représentées par beaucoup plus d'exemples. La base de données a donc été transformée en une base de taille plus petite, où chaque phase est représentée par un nombre équivalent d'exemples, afin d'éviter les erreurs de classification dues à cette différence de représentation.

Le Tableau 4 présente le nombre d'epochs dans chaque phase de sommeil présent dans la base de données initiale et dans la base que nous allons utiliser pour ce travail.

	éveil	P I	P II	P III&IV	SP
Base de données initiale	5 232	1 989	32 966	7 701	15 366
Base de travail	1 914	1 879	2 206	1 902	2 099

Tableau 4 : Nombre d'epochs présents dans la base de données initiale et dans la base de données transformée.

La base de données est composée au total de 10 000 epochs. Celle-ci est elle-même décomposée en 10 sous-ensemble, S_1, S_2, \dots, S_{10} , composés chacun de 1000 epochs, où chaque phase est représentée de manière équivalente. La taille des sous ensembles a été fixée à 1000 suite à une étude portant sur le nombre minimal d'exemples nécessaires à un bon apprentissage et une bonne validation ([BEC 05]). Deux types de classifieurs, kPPV et noyaux de Parzen, ont été appris sur des bases d'apprentissage de taille variable, x , allant de 10 exemples à 1500 et validés sur des bases de test de taille variables, y , allant de 10 à 1500 exemples. Le pourcentage d'erreur de classification sur la base de test pour chaque x (taille de la base d'apprentissage) et chaque y (taille de la base de test) a été estimé à l'aide de 30 essais (30 tirages aléatoires avec remise de x points et y points). Les résultats ont montré que l'erreur de classification sur la base de test se stabilisait à partir de 500 exemples dans la base d'apprentissage et la base de test. (Les mêmes résultats (test t , $p=0.001$) sont obtenus quelle que soit la valeur de x ou y entre 500 et 2000). L'étude nous permet d'affirmer que l'erreur de classification calculée sur un ensemble S_i composé de 1000 exemples, le classifieur étant appris sur un paquet S_j de 1000 exemples, fournit une estimation correcte de l'erreur réelle.

3.3.1.2. Caractéristiques extraites des signaux

Les caractéristiques sont extraites des signaux sur des fenêtres temporelles de durée fixe, sans recouvrement, correspondantes aux epochs classées par les experts. Leur durée est de 20 secondes. Pour chacun des signaux, les caractéristiques suivantes ont été extraites, elles correspondent à une description du signal dans le domaine temporel ou fréquentiel. Avant de les présenter, rappelons la nature de l'information enregistrée par chacun des signaux :

l'EEG mesure l'activité électrique cérébrale.

l'EOG mesure les différents mouvements oculaires.

l'EMG, placée au niveau du menton, mesure la tonicité de la peau.

3.3.1.2.1. Electroencéphalogramme - EEG :

Dans le domaine fréquentiel :

La puissance relative du signal dans cinq bandes fréquentielles, calculée par transformée de Fourier, qui donne une indication sur les composantes fréquentielles du signal

$P_{rel}(EEG, \delta_{FT})$ avec $\delta_{FT} = [0.5 ; 4.5]$ Hz,

$P_{rel}(EEG, \theta_{FT})$ avec $\theta_{FT} = [4.5 ; 8.5]$ Hz,

$P_{rel}(EEG, \alpha_{FT})$ avec $\alpha_{FT} = [8.5 ; 11.5]$ Hz,

$P_{rel}(EEG, \sigma_{FT})$ avec $\sigma_{FT} = [11.5 ; 15.5]$ Hz,

$P_{rel}(EEG, \beta_{FT})$ avec $\beta_{FT} = [15.5 ; 32.5]$ Hz.

Dans le domaine temporel:

Les moments du signal

- l'écart type, indicateur de l'amplitude des variations autour de la moyenne

$$std_{EEG} = \left[\frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 \right]^{\frac{1}{2}} \quad \text{Eq. 34}$$

avec n , le nombre de période d'échantillonnage dans l'époque, y_i un échantillon du signal, et \bar{y} la

moyenne arithmétique du signal pendant l'époque, calculée par $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$

- le skewness, indicateur de la symétrie de la répartition du signal autour de sa moyenne

$$skew_{EEG} = \frac{M_3}{M_2 \sqrt{M_2}} \quad \text{Eq. 35}$$

avec $M_k = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^k$, le $k^{\text{ième}}$ moment du signal

- le kurtosis, indicateur de la présence de valeurs extrêmes dans le signal, défini par

$$kurt_{EEG} = \frac{M_4}{M_2^2} \quad \text{Eq. 36}$$

Le 75^{ième} percentile du signal, indicateur de sa valeur maximale, plus robuste aux artefacts que le maximum

L'entropie du signal, mesure du mélange (ou du désordre du signal), définie par

$$Ent_{EEG} = - \sum_{j=1}^N \frac{n_j}{n} \ln \frac{n_j}{n} \quad \text{Eq. 37}$$

avec n , le nombre de période d'échantillonnage dans l'époque, N , le nombre de bandes d'amplitude considérées, et n_j , le nombre de périodes d'échantillonnage dont la valeur du signal se trouve dans la $j^{\text{ième}}$ bande d'amplitude.

3.3.1.2.2. Electromyogramme – EMG

Dans le domaine fréquentiel : la puissance relative du signal dans les hautes fréquences.
Dans le domaine temporel : l'écart type, le skewness, le kurtosis, l'entropie.

3.3.1.2.3. Electrooculogramme – EOG

Dans le domaine temporel : l'écart type, le skewness, le kurtosis, l'entropie

3.3.1.3. Transformation des données

Avant l'application d'une transformation de type z-score sur les données, ramenant l'ordre de grandeur de chacune des caractéristiques à des valeurs équivalentes, certaines caractéristiques ont subi des transformations visant à réduire les « queues » de leur distribution. En effet, certaines caractéristiques prennent parfois des valeurs très importantes, ce qui peut générer des erreurs de classification pour certaines fonctions de décision. Ces transformations, déjà proposées pour le traitement de l'EEG par [GAS 82], sont des fonctions de type logarithmique ou racine carrée. Nous avons pu vérifier que les performances de la majorité des classifieurs présentés au paragraphe 3.1.4 sont significativement améliorées (t test, p=0.01) après application de ces transformations sur certaines caractéristiques.

3.3.2. Méthodes

Nous avons appliqué la méthode de recherche de caractéristiques pertinentes ascendante SFS. Les résultats ont été vérifiées avec la méthode SBS, Slective Backward Search, qui décrémente à chaque pas le nombre de caractéristiques sélectionnées, en éliminant celle dont le retrait affecte le moins la valeur du critère de sélection.

3.3.2.1.1. Critère à maximiser

Le critère J à maximiser est une fonction du pourcentage d'épochs correctement classées par un classifieur C. La base de donnée S a été décomposée en 10 sous-ensemble $S = \{S_1, S_2, \dots, S_{10}\}$. Chaque sous-ensemble S_k contient 1 000 epochs. Un classifieur C est appris sur un sous-ensemble S_k et validé sur les 9 autres sous-ensembles $S_{\bar{k}} \in \bar{S}_k$, avec $\bar{S}_k = S - S_k$. Une fonction, Acc, mesurant la précision en validation est calculée sur chacun des 9 sous ensembles $S_{\bar{k}}$ suivant:

$$Acc(k, \bar{k}) = \frac{card\{[epoch_i \in S_{\bar{k}} / C(epoch_i) - E(epoch_i) = 0]\}}{card[S_{\bar{k}}]} \quad \text{Eq. 38}$$

où $epoch_i$ est une epoch de $S_{\bar{k}}$, $C(epoch_i)$ est la classe affectée à $epoch_i$ par le classifieur C, appris sur le sous ensemble k . $E(epoch_i)$ est la classe attribuée à $epoch_i$ par l'expert.

Une permutation circulaire est effectuée sur les 10 sous ensembles S_k . Le classifieur C est appris 10 fois à partir des différents sous ensemble S_k . 90 valeurs de $Acc(k, \bar{k})$ sont ainsi obtenues. Le critère J utilisé pour sélectionner les caractéristiques est :

$$J = \frac{1}{10} \cdot \sum_{k=1}^{10} \left(\frac{1}{9} \cdot \sum_{\substack{j=1 \\ j \neq k}}^{10} Acc(k, j) \right) \quad \text{Eq. 39}$$

$J(F_i)$ est la valeur obtenue par le critère J en utilisant les caractéristiques contenues dans le sous-ensemble F_i .

Le terme entre parenthèse correspond à la précision moyenne obtenue sur les 9 sous ensembles de validation quand le classifieur C est appris sur un ensemble d'apprentissage. J correspond à la précision moyenne sur les jeux de validation lorsque le classifieur C est appris sur les 10 jeux d'apprentissage différents. Ainsi, la précision calculée par J est indépendante du jeu d'apprentissage et du jeu de test. L'écart type de la précision peut être calculée par :

$$std_{Acc} = \left[\frac{1}{89} \sum_{k=1}^{10} \left(\sum_{\substack{j=1 \\ j \neq k}}^{10} (Acc(k, j) - J)^2 \right) \right]^{\frac{1}{2}} \quad \text{Eq. 40}$$

std_{Acc} est un indicateur de la précision des résultats. Il peut être utilisé dans un test statistique de moyenne différente t, afin de déterminer si les résultats obtenus à partir de différents classifieurs ou différentes caractéristiques sont statistiquement différents.

Chaque sous-ensemble S_k comprenant un nombre équivalent d'exemples dans chaque classe, le critère J est un compromis entre chaque classe. La méthode sélectionne les caractéristiques permettant un bon résultat de classification dans les cinq classes, sans favoriser une classe par rapport à l'autre.

3.3.3. Résultats

Une analyse des performances de différents classifieurs a montré que le meilleur classifieur est un perceptron multicouche, composé d'une couche d'entrée égale au nombre de caractéristiques du vecteur forme, d'une couche cachée formée de six neurones dont la fonction d'activation est une sigmoïde et d'une couche de sortie dont le nombre de neurones est égal au nombre de classes à reconnaître. Le classifieur quadratique obtient des résultats légèrement inférieur (de l'ordre de quelques pourcents).

L'analyse et la comparaison des résultats obtenus sont effectuées à partir du critère J (Eq.39) exprimant le pourcentage de concordance entre la machine et les experts et de la matrice de concordance entre les experts et la machine. Celle-ci est une matrice comportant en ligne la classification proposée par les experts et en colonne la classification obtenue par la machine. Chaque case (i,j) de la matrice affiche le nombre d'exemples classés en i par l'expert et en j par la machine, calculés en pourcentage d'exemple classée en i par l'expert. Le chiffre est la moyenne sur les 10 ensembles d'apprentissage, $S = \{S_1, \dots, S_k, \dots, S_{10}\}$, des pourcentages obtenus à partir de tous les exemples compris dans la base de test.

L'objectif de l'étude est de déterminer les signaux nécessaires à enregistrer sur un patient et les caractéristiques à extraire pour obtenir une bonne classification d'une nuit de sommeil. Nous avons donc, dans un premier temps, comparé les résultats que l'on obtient quand seul l'EEG est enregistré, qui est l'information la plus importante pour classer le sommeil, puis en ajoutant les deux autres signaux EOG et EMG.

Le Tableau 5 correspond à la matrice de concordance obtenu quand seule la puissance relative de l'EEG dans les différentes bandes spectrales est utilisée. La valeur du critère J obtenu est 70.61% de concordance en validation. On observe que, si les phases II et III&IV sont assez bien discriminées, il y a confusion entre la phase I et la phase de sommeil paradoxal.

	E	P I	P. II	P. III&IV	SP
E	77.3	10.3	3.2	1.3	7.6
P.I	13.3	32.1	7.4	0.6	46.4
P.II	1.3	2.8	81.6	10.1	4
P. III&IV	0.2	0.1	7.5	91.7	0.2
SP	6.4	21.8	2.9	0.4	68.3

Tableau 5 : Matrice de concordance obtenue quand seule la puissance relative de l'EEG dans les différentes bandes spectrales est utilisée.

Tableau 6 présente les résultats obtenus quand une procédure de recherche ascendante de caractéristiques pertinentes (SFS) est effectuée sur les caractéristiques extraites à partir de l'EEG uniquement.

	E	P I	P. II	P. III&IV	SP
E	81.2	8.6	4	1.9	4.1
P.I	11.4	32.9	9.2	0.8	45.4
P.II	1.6	2.6	86.3	6.8	2.5
P. III&IV	0.4	0.0	6.4	92.9	0.03
SP	4.9	21.3	3.5	0.5	69.56

Tableau 6 : Matrice de concordance obtenue avec les caractéristiques Pre_{EEG} dans les différentes bandes spectrales, std_{EEG} et $kurt_{EEG}$.

Le pourcentage de concordance en validation est 73.06%. Les caractéristiques sélectionnées sont, en premier, la puissance spectrale relative dans les différentes bandes fréquentielles, puis l'écart type suivi du kurtosis. L'utilisation du 75^{ième} percentile ou du skewness n'améliore pas les performances obtenues. L'apport des deux caractéristiques, écart type, kurtosis, permet d'améliorer le classement en éveil, phase II et phase III&IV, mais la discrimination entre phase I et sommeil paradoxal reste médiocre. 45% des epochs classées en sommeil paradoxal par la machine correspondent en fait à des phases I. Le seul signal EEG ne permet pas une bonne discrimination entre phase I et sommeil paradoxal, il est nécessaire d'enregistrer d'autres signaux sur un patient.

Une sélection ascendante des caractéristiques a été réalisée en utilisant les caractéristiques extraites des trois signaux, EEG, EOG et EMG. La Figure 23 montre les caractéristiques sélectionnées à chaque pas par la méthode ascendante. Après la sélection des puissances relatives

de l'EEG dans les différentes bandes fréquentielles, les caractéristiques sélectionnées sont l'entropie de l'EMG, l'entropie de l'EOG, la puissance relative de l'EMG dans les hautes fréquences, puis le kurtosis EOG. L'ajout de ces caractéristiques permet de faire passer le critère J de 70,61% à 79.4% de concordance. La valeur maximale de J ($J=80.7\%$) est atteinte quand on ajoute à ces caractéristiques le 75^{ième} percentile de l'EEG et l'écart type de l'EOG. L'ajout d'autres caractéristiques n'augmente plus le taux de concordance de manière significative (test t, $p=0.01$)

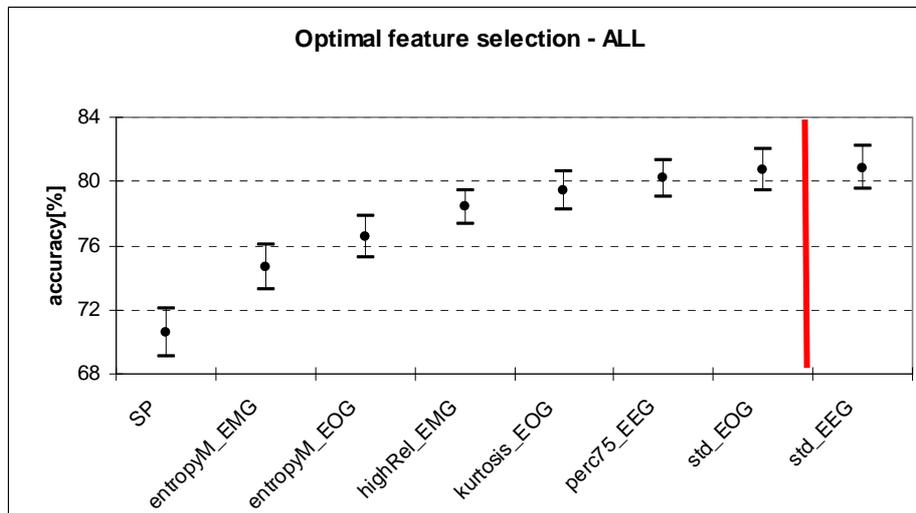


Figure 23: Caractéristiques sélectionnées par la méthode SFS, l'ensemble des caractéristiques à choisir regroupant toutes les caractéristiques extraites sur les trois signaux. La barre rouge délimite les caractéristiques optimales. Aucune amélioration significative n'est obtenue par ajout d'autres caractéristiques (test t, $p=0.01$).

	E	P I	P. II	P. IIIouIV	SP
E	83.6	8.5	2.4	2.1	3.2
P.I	8.2	62.8	6.6	0.6	21.5
P.II	0.9	4.2	85.5	6.4	2.7
P. III&IV	0.4	0.05	6.7	92.6	0.05
SP	2.3	16.9	2.4	0.2	77.9

Tableau 7 : Matrice de concordance obtenue avec les caractéristiques sélectionnées par SFS

La matrice de concordance (Tableau 7) montre que le pourcentage d'époches correctement classés en phase I a très nettement augmenté. Il est passé de 33% à 62.9%, soit un gain de 30%. Le pourcentage d'époches correctement classés en sommeil paradoxal a lui augmenté de 10%. Les taux de concordance pour l'éveil, phase II et phase II ou IV, déjà importants quand seul l'EEG est utilisé, ont gardé des valeurs du même ordre de grandeur.

L'étude met en évidence l'importance des signaux EMG et EOG pour obtenir une bonne classification des phases du sommeil. Il est à noter que la construction du critère de sélection a une grande influence sur les résultats obtenus. Ainsi, le critère J choisi accorde le même poids à

chacune des phases du sommeil. Un critère de validation J choisi de manière à obtenir le meilleur taux de classification sur une nuit de sommeil aurait favorisé la sélection des caractéristiques permettant une meilleure discrimination de la phase II, qui est majoritairement présente dans une nuit de sommeil (50% du temps de sommeil passé en phase II), et aurait conclu que l'EEG suffit pour une bonne classification.

La classification de toutes les epochs de tous les enregistrements de la base de données a ensuite été réalisée à l'aide d'un banc de classifieurs. Les 10 PMC appris à l'aide des 10 sous ensembles S_1, S_2, \dots, S_{10} , sont utilisés pour classer chaque epoch. La classe attribuée correspond à la classe majoritaire parmi eux. La Figure 24 montre le pourcentage d'epochs de la base de données ayant obtenu un score s (s classifieurs ayant attribué la même classe). 70% des epochs de la base sont classées à l'unanimité dans la même classe par les 10 classifieurs. Ces résultats confirment l'étude effectuée en amont, concluant qu'une base d'apprentissage composée de 1000 epochs était suffisante pour correctement apprendre le modèle de décision.

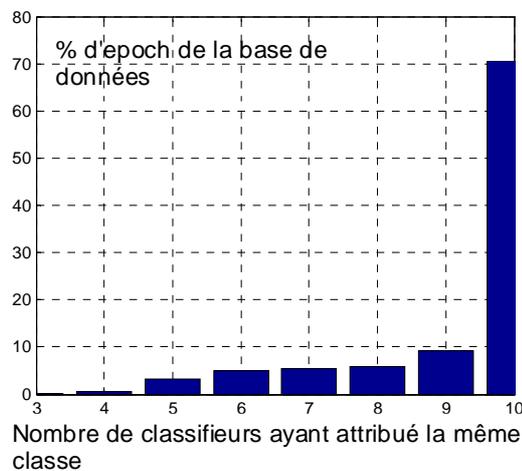


Figure 24 : Pourcentage d'epochs de la base de données ayant obtenu un score s

Le pourcentage de concordance obtenue sur l'ensemble des epochs de la base de données est égal à 84.8%. La Figure 25 montre la répartition des résultats obtenus pour les 47 enregistrements, sous forme d'histogramme. Ainsi, 40 enregistrements ont un taux de concordance supérieur à 80%. L'analyse visuelle par un expert des signaux ayant obtenus les moins bonnes performances a montré la présence de nombreux artéfacts sur les signaux enregistrés, et plus particulièrement sur l'EEG.

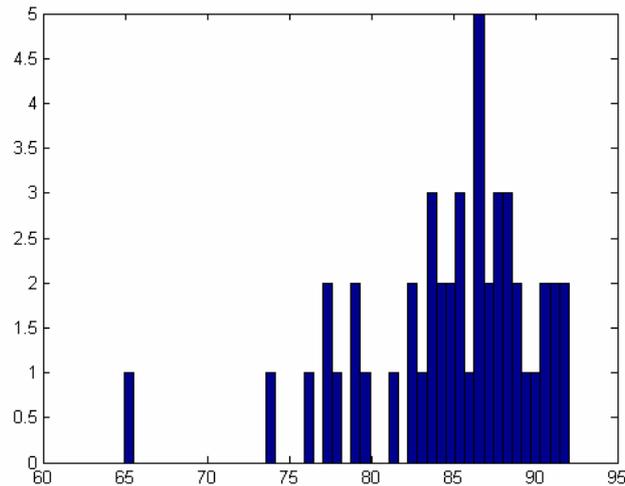


Figure 25 : Pourcentage de concordance obtenu pour chaque nuit de sommeil de la base de données, représenté sous forme d'histogramme.

3.3.4. Conclusions et perspectives

L'analyse du sommeil est un domaine pour lesquels les techniques de reconnaissance de formes donnent de bons résultats. Le taux de concordance obtenu ici est de l'ordre de 80%, ce qui est assez élevé, lorsque l'on prend en compte le taux de désaccord entre médecins qui est de l'ordre de 20%. La classification que réalise le médecin quand il construit un hypnogramme est en lui-même un problème de reconnaissance de formes. La forme des différents signaux, que le médecin va analyser avec ses propres caractéristiques visuelles, détermine la phase du sommeil. La difficulté de la classification automatique réside dans le fait de décrire le signal avec des caractéristiques numériques proches des caractéristiques visuelles utilisées par le médecin.

Le principe des méthodes automatiques actuellement appliquées est de mélanger dans la base d'apprentissage des epochs enregistrées à différents instants et provenant de patients différents. Le médecin prend lui en compte d'autres informations, qui ne sont pas utilisées par les méthodes présentées, et dont l'intégration dans les méthodes automatiques constituent de nouvelles pistes de recherche. Dans la suite, nous présentons un certain nombre de perspectives afin d'améliorer les performances des méthodes automatiques.

3.3.4.1. Détection d'artéfact

Les signaux physiologiques sont assez souvent « pollués » par des artéfacts de mesure, en général dus à des mouvements des patients. Ces mouvements peuvent parfois entraîner une déconnection du capteur. Lorsque des signaux artéfactés sont intégrés dans la base de données, la valeur des caractéristiques extraites est erronée, ce qui peut biaiser l'apprentissage des fonctions de décision (mauvaise estimation de la matrice de variance-covariance, par exemple). On peut envisager de travailler avec un expert lors de la phase de création de la base d'apprentissage afin de ne sélectionner que des signaux vierges de tout artéfact et permettre ainsi un apprentissage non biaisé des fonctions de décision. En cours d'utilisation, des techniques de rejet en distance pourraient ensuite être mises en œuvre pour écarter toute epoch trop éloignée de celles de la base d'apprentissage.

3.3.4.2. Reconnaissance automatique de grapho éléments

Lors de certaines phases du sommeil, certains événements transitoires apparaissent sur le signal d'EEG, comme les spindles ou les K complexes. L'occurrence de ces événements augmente la certitude qu'a le médecin de la phase reconnue. Une piste de recherche est, dans un premier temps, de construire un système de détection automatique de ces grapho éléments, à l'aide de méthodes utilisant la décomposition en ondelettes. Il s'agit ensuite de mettre en œuvre des méthodes de fusion d'information permettant d'inférer une décision à partir de l'appartenance de l'époque à la classe calculée par un classifieur et de la présence de ces grapho éléments.

3.3.4.3. Prise en compte d'informations spécifiques à un patient

L'apprentissage des fonctions de décision se fait à partir de caractéristiques extraites sur des signaux provenant de patients différents. La variabilité de chaque caractéristique de la base d'apprentissage dépend ainsi de la variabilité intra individu (pour un patient donné) à laquelle s'ajoute la variabilité inter individuelle (d'un individu à l'autre). Plus la variabilité inter individuelle est importante, plus les classes se dispersent et moins elles sont séparables. Les techniques de sélection de caractéristiques présentées précédemment favorisent ainsi les caractéristiques à plus faible variabilité inter individuelle.

Une piste de recherche est de déterminer si la variation inter individuelle de certaines caractéristiques peut être diminuée en utilisant des informations spécifiques au patient et une transformation adaptée. En faisant l'hypothèse que tout patient est en phase d'éveil pendant les 5 premières minutes de l'enregistrement, la question est de déterminer si et comment la connaissance de la valeur des caractéristiques pour un patient pendant la phase d'éveil peut permettre d'améliorer la classification automatique.

3.3.4.4. Prise en compte de l'information passée

En reconnaissance de forme, l'aspect dynamique d'un système n'est pas pris en compte. Le système est décrit à un instant donné par les caractéristiques extraites sur une fenêtre temporelle, et le diagnostic est inféré à partir de cette information instantanée. De manière imagée, le diagnostic par RDF consiste à prendre des photos du système à intervalles réguliers et à prendre une décision en fonction de l'information portée sur la photo. L'information portée par la photo précédente n'intervient pas dans la décision.

Or, dans le cas de l'analyse du sommeil, l'expert se réfère à l'information instantanée - la forme des signaux au cours de l'époque à classer – mais peut aussi utiliser l'information des époques précédentes. La prise en compte de l'information passée dans la décision automatique est une piste de recherche très intéressante. Plusieurs voies pourraient être explorées :

intégrer l'information passée au niveau des entrées du système de décision.

On peut envisager d'augmenter le nombre de caractéristiques en prenant en compte certaines d'entre elles au temps t et au temps $t-kTs$, k périodes d'échantillonnage avant. Cette méthode a cependant l'inconvénient d'augmenter la dimension de l'espace de représentation et donc la complexité de la fonction de décision.

Une autre voie est de considérer les caractéristiques extraites au cours de l'enregistrement comme des séries temporelles, sur lesquelles on peut appliquer des algorithmes de segmentation, afin de rechercher les zones de stabilité. La classification se ferait alors par intervalles de temps, et non plus époque par époque, sur les zones de stabilité. Les zones d'évolution des caractéristiques seraient à analyser plus finement afin de déterminer si il s'agit de zones de transitions.

intégrer l'information passée au niveau des sorties du système de décision

La connaissance de la classe associée à l'époque précédente peut permettre de mieux discriminer la classe à l'instant t . Le processus de sommeil correspond à une succession de phases, le passage de l'une à l'autre n'étant pas aléatoire mais obéissant à des mécanismes physiologiques. Ainsi, pour un patient sain, à partir d'une phase de sommeil donnée, certaines transitions vers une nouvelle phase sont beaucoup plus probables que d'autres. La connaissance des probabilités de passage dans une phase à l'instant $t+1$, connaissant la phase dans laquelle le patient se trouve à l'instant t , est une connaissance a priori qui pourrait être utilisée pour lever une ambiguïté entre plusieurs phases. L'objectif de la recherche serait de modéliser l'évolution des phases successives de sommeil chez des patients sains, à l'aide de chaînes de Markov par exemple, et d'utiliser cette information a priori dans un modèle de décision combinant la probabilité de passage d'une classe vers une autre connue a priori et la probabilité d'appartenance à une classe estimée à partir des caractéristiques via un classifieur bayésien. La prise en compte de cette information pourrait permettre de réduire la confusion actuelle entre phase I et sommeil paradoxal.

Il faut néanmoins être prudent avec ce type de méthode et restreindre son application à des classes de patients particuliers, en excluant certaines pathologies présumées. En effet, certaines pathologies du sommeil se traduisent par une modification des mécanismes physiologiques engendrant la succession des phases de sommeil. Certaines transitions très rares voire impossibles chez le patient sain peuvent devenir alors beaucoup plus probables. L'utilisation d'un modèle de connaissance non adapté conduirait alors à une augmentation des erreurs de classification.

4. Conclusions et perspectives

J'ai présenté dans ce manuscrit mes deux axes de recherche principaux, portant tous les deux sur la surveillance de systèmes continus sans modèle formel, l'un par analyse de tendances, l'autre par reconnaissance de formes. Le domaine d'application de ces travaux est le secteur médical, et plus particulièrement la surveillance de l'état d'un patient. Le choix de l'application m'a naturellement orientée vers des méthodes n'utilisant pas de modèles formels. En effet, la modélisation de systèmes médicaux par des modèles formels (ie des modèles décrivant les liens dynamiques entre variables par des équations différentielles) est une tâche excessivement ardue. Certes, il existe des modèles formels en médecine, tout particulièrement dans le domaine pharmaceutique où l'effet d'un médicament en réponse à une dose délivrée au patient est décrit par des modèles à compartiments. La variabilité inter-patient est gérée à l'aide de modèles de population où les paramètres du modèle sont décrits en fonction de caractéristiques propres au patient, comme son âge, son sexe, ... Mais, si l'on s'intéresse à la surveillance de l'état d'un patient, la tâche de modélisation se complexifie fortement car il s'agit alors de décrire des fonctions physiologiques. Or, encore maintenant, le fonctionnement du corps humain et la manière dont il assure certaines fonctions physiologiques ne sont pas parfaitement connus. Quelques modèles à base d'équations différentielles ont été proposés, pour décrire le fonctionnement du système cardio-vasculaire par exemple, mais ils sont très complexes, comportent un grand nombre de paramètres (qui peuvent varier en fonction du temps). Ils utilisent de plus des variables physiologiques qui ne sont pas toutes mesurables. Enfin, quand un patient souffre d'une pathologie, les liens dynamiques entre variables peuvent être modifiés, ce qui change alors la structure du modèle.

Ainsi, les méthodes proposées dans ce rapport sont des méthodes utilisant les mesures effectuées sur le patient et les liens entre ces mesures. Des modèles sont utilisés pour fusionner les variables et aboutir à une décision mais ce sont des modèles fondés sur la description, qui imitent la prise de décision d'un expert. Deux voies ont été choisies :

- celle de l'analyse de tendance qui consiste à transformer chaque variable mesurée en une succession d'épisodes semi qualitatifs décrivant l'évolution temporelle du signal, puis à fusionner ensuite les variables à l'aide de modèles utilisant les épisodes. L'avantage de la tendance est de mettre en évidence les transitoires dans un signal, qui sont ensuite utilisés pour la prise de décision. Les difficultés portent, d'une part, sur l'obtention d'une tendance représentant fidèlement les transitoires, c'est-à-dire réalisant une bonne description de l'évolution du signal, sans être polluée par le bruit de mesure, et d'autre part, sur la fusion d'informations non synchrones (les débuts et fins de chaque épisode ne coïncident pas d'une variable à une autre). Nous avons proposé une méthode d'extraction de tendance décrivant l'évolution temporelle d'une variable à l'aide de 3 primitives (stable, croissant, décroissant) bien adaptée aux variables physiologiques, ainsi que des solutions pour l'utiliser à des fins d'aide à la surveillance de patients hospitalisés en soins intensifs.
- Celle de la reconnaissance de formes, où les signaux sont découpés de manière synchrone (intervalle de temps fixe et commun à toutes les variables) et fusionnés à partir de leur valeur numérique. La prise de décision effectuée à un instant donné par le modèle de fusion utilise l'ensemble des informations extrait des signaux à ce même instant. L'évolution temporelle des informations n'est pas prise en compte dans la

décision. La difficulté porte sur le choix des bons descripteurs (sélection des caractéristiques pertinentes) et sur la construction d'un ensemble d'apprentissage représentatif du problème à résoudre. Nous avons mis en œuvre des méthodes de reconnaissance de formes pour réaliser des systèmes de diagnostic de l'état d'un patient (diagnostic de choc hémorragique, reconnaissance de phases de sommeil).

L'analyse de tendance a été initialement appliquée pour le diagnostic de procédés chimiques, mais on trouve récemment des applications dans le domaine de la surveillance de patients hospitalisés en unités de soins intensifs. Les variables physiologiques enregistrées en continu sur les patients présentent certaines particularités qui nécessitent le développement de méthodologies d'extraction de tendance adaptées. Ces variables sont perturbées par du bruit de mesure haute fréquence, par du bruit basse fréquence généré par des rythmes biologiques ainsi que par des artéfacts (variation brève mais de forte d'amplitude de la variable mesurée) dus à des erreurs de mesure. On observe aussi des variations transitoires non pertinentes (ne correspondant pas à une variation significative pour le médecin, c'est-à-dire pouvant être interprétée comme une évolution de l'état) se traduisant par une augmentation (ou une diminution) de la variable pendant une durée assez brève suivi d'un retour à la valeur d'origine. Les caractéristiques décrites ci-dessus correspondent à des variations non pertinentes, qui doivent être filtrées sur la tendance. A l'opposé, on observe sur ces variables des modifications très rapides de la moyenne s'apparentant à des variations de type échelon, dues à des déconnexions de capteurs ou d'appareils de soins, qui doivent être conservées sur la tendance.

Les méthodes proposées pour extraire la tendance de variables chimiques dérivent numériquement le signal pour obtenir le signe de la dérivée première et seconde. L'utilisation de la dérivée numérique nécessite un filtrage du signal, de manière à éliminer le bruit perturbant l'enregistrement. Comme nous l'avons dit ci-dessus, l'information à filtrer sur la tendance des variables physiologiques correspond à des variations basse fréquence (bruit biologique, transitoire non pertinent) dont l'élimination à l'aide d'un filtre passe bas nécessite de fixer la fréquence de coupure du filtre à une valeur très faible. Ceci a comme conséquence une forte distorsion du signal et notamment des ruptures de type échelon qui apparaissent sur le signal filtré comme des variations plus lentes. Les méthodes utilisant la valeur de la pente d'une droite de régression calculée sur une fenêtre temporelle glissante de taille fixe présentent les mêmes inconvénients. La taille de la fenêtre doit être suffisamment large pour permettre l'élimination des variations basse fréquence avec comme conséquence la déformation des variations de type échelon. Ces méthodes sont ainsi face à un dilemme : filtrer les variations basse fréquence non pertinentes pour décrire l'évolution de l'état du patient ou conserver les ruptures sur le signal. La méthode proposée par [REN 95] préconisant l'utilisation d'un réseau de neurones se heurte quant à elle à la nécessité de choisir un nombre de neurones en entrée plus important, de taille au moins égale au nombre de périodes d'échantillonnage correspondant à la durée du transitoire à éliminer, et donc à l'apprentissage d'un réseau beaucoup plus complexe.

La méthode d'extraction de tendance que nous avons proposée résout ce dilemme en découplant les deux problèmes :

- le filtrage des variations basse fréquence est assuré par l'algorithme de segmentation. Son réglage n'est pas effectué en termes de choix de fréquence de coupure mais par caractérisation des variations transitoires que l'on cherche à éliminer sur la tendance. L'utilisation de la CUSUM pour déterminer les instants de segmentation permet l'élimination des transitoires en fonction de la valeur de l'intégrale de la variation. On introduit implicitement la notion de persistance d'une variation, qui est une notion

naturellement utilisée par le personnel soignant. Une variation d'amplitude relativement faible est conservée sur la tendance si elle dure suffisamment longtemps, c'est-à-dire si elle persiste sur le signal. A l'inverse, l'apparition d'une variation d'amplitude importante mais de courte durée, de type artéfact, est éliminée.

- La détection des variations de type échelon dans le signal est assurée par le fait que l'algorithme de segmentation permet la discontinuité entre deux segments.

La modification du paramètre de réglage de la segmentation, $seuil_2$, n'a pas comme conséquence de déformer le signal filtré mais de modifier le temps de détection d'un changement. Les ruptures restent correctement décrites sur le signal segmenté quelle que soit la valeur du paramètre de réglage. Ainsi, plus le seuil de réglage de la segmentation $seuil_2$ est grand, plus les variations basse fréquence sont filtrées et plus le temps mis pour détecter un changement (de type échelon ou non) est long.

Une autre difficulté à résoudre propre aux signaux physiologiques est la modification de la variabilité du signal en fonction du contexte de soins. Celle-ci peut prendre des proportions très importantes sur certaines variables, comme les variables respiratoires par exemple. Quand le malade est ventilé artificiellement en mode contrôlé, la fonction de respiration est réalisée par le respirateur. La variabilité observée sur les paramètres respiratoires surveillés est alors très faible car la machine impose une respiration très régulière. A l'inverse, quand le malade respire spontanément, la variabilité des variables respiratoires augmente très fortement. La variance du signal peut être jusqu'à cent fois supérieure à la variance du signal en mode contrôlé par le respirateur. La méthodologie d'extraction de tendance que nous avons proposée utilise la notion de variation significative pour l'opérateur pour affecter une primitive à un épisode. Une variation est interprétée comme significative pour l'opérateur si elle est supérieure à la valeur du seuil de réglage $seuil_c$. Or, dans un contexte de variabilité du signal fortement changeante, la valeur définissant une variation significative peut changer. Une modification peut être significative pour l'opérateur quand la variabilité du signal est faible alors qu'une variation de même amplitude pourra ne plus l'être quand la variabilité est plus importante. Ceci nous a amené à développer une version adaptative de l'algorithme d'extraction de tendance qui ajuste ses seuils de réglage au contexte rencontré. Le contexte est estimé à chaque instant de segmentation du signal à l'aide de l'écart type du signal calculé sur un passé proche. L'estimation du contexte permet de déterminer si l'on est dans un contexte de faible variabilité ou de forte variabilité.

L'utilisation de la tendance dans un objectif de surveillance nécessite que celle-ci soit extraite en ligne, au fur et à mesure de l'acquisition des données. La tendance doit être extraite en utilisant les informations passées jusqu'à l'instant courant. Or, l'appréciation visuelle qu'un expert peut faire de l'évolution temporelle du signal à l'instant courant peut être remise en cause après l'acquisition de nouveaux échantillons. Ainsi, un signal qui semble être stabilisé après une période de croissance peut ultérieurement être vu comme globalement croissant si la tendance du signal redevient croissante. Ceci se traduit, en termes d'extraction de tendance, par le fait de pouvoir modifier à un instant donné les primitives affectées à des épisodes précédents. Le problème se pose alors de déterminer l'intervalle de temps au cours duquel l'algorithme est autorisé à modifier les primitives et de définir une procédure pour attribuer de nouveau les primitives. Dans la littérature, peu d'auteurs se sont penchés sur ce problème. [REN 95] propose d'utiliser une grammaire pour détecter les erreurs d'attributions dans les primitives. La solution proposée est adaptée à sa propre méthode qui décompose l'évolution d'une variable suivant 9 primitives mais ne peut pas être transposée à une méthode n'utilisant que 3 primitives telle que la nôtre. La solution que nous avons proposée consiste à revenir sur l'attribution de la primitive de

l'épisode $i-1$ précédent l'épisode courant i en utilisant des informations numériques et symboliques provenant des épisodes $i-2$, $i-1$ et i . Une procédure utilisant un réseau de neurones a été proposée qui a l'avantage d'être simple en termes de nombre d'opérations à effectuer et donc rapide. Elle est suivie d'une procédure d'agrégation qui transforme les trois épisodes distincts $i-2$, $i-1$ et i en un nouvel épisode courant i . Ainsi, l'épisode agrégé au temps courant, intégrant l'épisode initialement considéré comme un épisode distinct, sera à nouveau analysé par la procédure de réattribution de primitives au pas suivant (après la détection d'un nouvel épisode). La procédure est donc récursive, ce qui garantit la détection d'épisodes les plus longs possibles.

L'un des intérêts de la méthode développée est l'extraction d'une tendance semi-qualitative. L'information extraite ne se restreint pas à une succession d'épisodes décrits par un symbole mais intègre, en plus de l'information sur l'évolution temporelle de la variable, la valeur numérique du signal en début et fin d'épisode. Cette information est très importante dans le contexte de la surveillance de patients car le diagnostic s'effectue en prenant en compte la valeur des variables physiologiques ainsi que leur évolution temporelle. L'algorithme de segmentation qui sert de base à la méthode découpe le signal en une succession de droites dont les instants d'origine correspondent aux instants de début et de fin des épisodes et dont les ordonnées à l'origine correspondent aux valeurs de la variable en début et fin d'épisode. Ceci permet de ne pas reporter les valeurs bruitées du signal, voire les valeurs erronées correspondant aux artéfacts, sur la tendance. L'attribution des valeurs symboliques et numériques est réalisée en même temps. Ceci n'est pas le cas pour les méthodes détectant les primitives à chaque période d'échantillonnage (c'est-à-dire toutes les méthodes n'utilisant pas de procédure de segmentation), qui, pour extraire une information numérique, devraient ensuite aller rechercher sur le signal les valeurs correspondant aux extrémités des intervalles, au risque d'intégrer le bruit du signal sur la tendance.

La méthode proposée dans ce rapport découpe le signal en deux informations complémentaires : la tendance, qui décrit l'évolution temporelle générale du signal, et le résidu qui explicite la partie du signal qui a été filtrée par l'algorithme de segmentation. Le résidu peut être traité de manière indépendante de la tendance pour extraire des informations complémentaires. Ainsi, le calcul en ligne de l'écart type du résidu permet de mettre en évidence les intervalles de temps où la variabilité du signal est importante. Une valeur temporairement forte de l'écart type du résidu peut rendre compte de la présence d'artéfacts ou d'éléments transitoires qui ont été filtrés par l'algorithme de segmentation. Nous avons introduit à l'aide du résidu une information symbolique supplémentaire, l'épisode instable correspondant à une valeur importante de l'écart type du résidu, qui a pu être utilisée ensuite dans les modèles de diagnostic. La notion de forte variabilité du signal mesurée à l'aide de l'écart type du signal et son interprétation sous forme symbolique ont été proposés par [CAL 00]. Cependant, l'information d'instabilité qu'ils proposent inclut les périodes de forte variabilité du signal dues à la présence d'artéfacts ainsi qu'à des transitoires rapides, de type échelon, sans possibilité de discriminer les deux. L'épisode instable de notre méthode ne décrit qu'une période de forte variabilité associée à un artéfact, les variations de type rupture étant déjà décrites par la tendance.

Quelques utilisations de la tendance extraite à l'aide de la méthode développée sont proposées dans ce mémoire à des fins d'aide à la surveillance de patients hospitalisés en service de réanimation. Nous avons proposé une méthode pour reconnaître de manière automatique des événements survenant sur les patients à partir des signaux, en utilisant des techniques de pattern matching, qui sont des techniques couramment utilisées dans la littérature. Les signaux sont décomposés suivant leur tendance. Un modèle d'évènement décrivant la forme temporelle que

prennent les signaux sur occurrence de l'évènement est préalablement écrit. Un évènement est détecté quand toutes les entrées d'un modèle d'évènement sont présentes simultanément sur les signaux. Les modèles proposés dans la littérature pour le diagnostic de procédés chimiques n'utilisent que l'information symbolique, c'est-à-dire la succession des primitives. Ceci n'est pas suffisant dans le domaine de la surveillance de patient, où la valeur numérique des variables ainsi que les amplitudes des variations doivent être prises en compte. Deux verrous sont à lever : la prise en compte des erreurs d'attributions de primitives qui ont pu être commises au cours de l'extraction de la tendance et, quand on travaille avec des modèles multivariables, le fait que les variables ne soient pas découpées de manière synchrone. Les extrémités des intervalles de temps formant les épisodes ne sont pas les mêmes d'une variable à l'autre.

La solution proposée dans ce rapport pour lever le premier verrou est de proposer, pour un même évènement à reconnaître, plusieurs modèles. Une forme temporelle monovariable typique est déclinée suivant plusieurs formes, en prenant en compte l'erreur qui peut être commise lors de l'extraction de tendance. Ainsi, par exemple, la chute d'une variable sous un seuil est typique d'un évènement de type aspiration trachéale. On recherche la présence sur la variable d'un épisode décroissant sous une valeur seuil, mais aussi d'un transitoire décroissant-croissant ou d'un épisode instable (forte valeur de l'écart type du résidu) qui peut traduire la présence d'une chute de la variable mal décrite par la tendance. Afin de rendre compte dans la détection du fait que l'évènement ait été reconnu non pas à partir de la forme typique mais à partir d'une forme approchée, une valeur est associée à chaque forme. Cette valeur est d'autant plus élevée que la forme ressemble à la forme typique. L'indice global de détection, qui caractérise le degré de confiance que l'on a dans la détection de l'évènement, est la somme des valeurs des formes présentes sur les signaux lors de la détection. D'autres solutions, mieux formalisées, pourraient cependant être proposées et font partie des perspectives de ces travaux.

Le deuxième verrou pourrait être levé en forçant la synchronisation des variables. Les intervalles de temps de chaque épisode pourraient être redécoupés en sous intervalles plus courts, pour lesquels les instants de début et de fin seraient commun à toutes les variables. L'inconvénient de cette méthode est l'explosion du nombre d'intervalles à analyser, qui deviendrait rapidement très important dès que le nombre de variables augmente. Nous avons choisi d'introduire la notion d'épisodes concomitant(Δ). Deux épisodes sont concomitants si l'intersection en temps des deux épisodes auxquels a été ajoutée une fenêtre temporelle Δ aux deux extrémités est non nulle. Cela permet de manipuler facilement des épisodes extraits sur plusieurs variables, même si celles-ci sont en nombre important. Cette notion d'intervalle de temps Δ au cours duquel tout ce qui se produit sur différentes variables est supposé concomitant a été reprise pour définir des indices de changements en multivariable.

La reconnaissance de formes est une technique utilisée quand l'évolution d'une variable dans le temps n'est pas un élément pertinent pour le diagnostic. On ne cherche pas à traduire la forme d'un transitoire mais à utiliser les relations entre différentes variables. On ne s'intéresse ici qu'à la valeur des variables. Les particularités des variables physiologiques décrites précédemment (artéfacts, variations non pertinentes) vont poser un problème car elles vont augmenter la dispersion des classes ce qui entraînera des erreurs de classification. Ces problèmes peuvent être éliminés si l'on prend soin de filtrer au préalable les données de la base d'apprentissage. En cours de diagnostic, les artéfacts ou les variations non pertinentes peuvent ensuite être détectés à l'aide de techniques de rejet en distance ou de rejet en ambiguïté, ou encore à l'aide de techniques de classification flou. La variabilité inter-patient est un facteur qui va lui aussi augmenter la

dispersion des classes et qu'il n'est possible de résoudre qu'en choisissant les caractéristiques les moins patient dépendantes, ou en appliquant une transformation sur les données qui réduit cette variabilité, en intégrant dans la transformation des caractéristiques propres au patient. La difficulté est bien sûr de choisir les bonnes caractéristiques et les bonnes transformations. Celles-ci ne sont pas toujours mesurables sur le patient, comme nous avons pu le voir dans le cas du diagnostic de choc hémorragique.

Des perspectives de recherche sur chacun des deux thèmes - analyse de tendances, reconnaissance de formes - ont été proposées à la fin de chaque chapitre, portant sur des développements méthodologiques.

Ainsi, dans le cadre de l'analyse de tendance et de son utilisation pour le diagnostic, l'idée est d'aller plus loin dans l'explicitation (l'abstraction) de la dynamique du signal. L'évolution temporelle est actuellement décrite à l'aide d'épisodes temporels auxquels sont associés des primitives. Cependant, le contexte de l'épisode – l'épisode le précédant ou lui succédant- n'est pas pris en compte, bien que celui-ci joue un rôle important sur le sens que l'on peut donner à l'épisode. En effet, un épisode croissant précédé d'un épisode décroissant pourra décrire une oscillation, alors qu'un épisode croissant précédé d'un épisode stable pourra traduire un changement d'état. L'idée est donc de décrire le signal par un nombre fini de formes temporelles - ou lettres - formées par une succession d'épisodes, définissant un alphabet. Les mots, composés d'une suite de lettres, seront le support du diagnostic. L'originalité de cette proposition par rapport aux travaux existants est l'intégration de l'information numérique pour la construction de l'alphabet et dans les modèles de diagnostic, qui nécessiteront le développement de méthodes adaptées.

Dans le cadre du diagnostic par reconnaissance de forme, l'objectif est d'intégrer l'information passée dans la décision, soit en entrée du système de décision, en ne considérant plus les caractéristiques extraites à un instant donné comme seules entrées du système de décision mais comme une série temporelle que l'on peut segmenter, soit en sortie du système de décision en fusionnant les décisions prises aux instant précédents avec la décision courante.

Les dénominateurs communs des recherches présentées dans ce manuscrit sont la thématique de recherche – la surveillance de systèmes sans modèle formel – ainsi que les applications concernées, les systèmes médicaux. Ainsi, j'ai adopté une démarche tournée vers l'application : le point de départ de la recherche est l'énoncé d'un problème concret (aide à la surveillance de patients en réanimation, diagnostic de choc hémorragique, classification des phases de sommeil) dont la résolution amène la proposition de nouvelles méthodes. Les systèmes médicaux, de par leur diversité et leur complexité (artéfacts sur les signaux, non stationnarité, variabilité inter patient, ...) sont une source d'idées nouvelles. Cependant, les méthodes, bien que développées spécifiquement pour un problème donné, peuvent être appliquées à toute classe de système présentant des caractéristiques similaires. Ainsi, la méthode d'extraction de tendance a été appliquée avec succès sur des données provenant d'un évaporateur d'une usine de production de sucre de canne installée à Baufonds, sur l'île de la Réunion (températures, pression, concentrations) ([CHA 05b]). Une des problématiques liée à la surveillance de ces systèmes est la différence entre les temps de réponse des variables mesurées. Une perturbation sur le système se propage très rapidement sur les pressions mesurées alors que son effet perdure plusieurs heures sur les variables associées aux concentrations. Pour réagir correctement face à une perturbation affectant le procédé, l'opérateur doit garder en mémoire l'information passée, parfois sur des périodes de temps très longues. La décomposition en tendances permet de sauvegarder un historique concis des variables du procédé et facilite ainsi la prise de décision par l'opérateur. La

méthode a aussi été utilisée par Carlos Garcia-Beltan dans le cadre de sa thèse de doctorat comme outil de pronostic de défaillances. La tendance est utilisée pour prédire l'évolution future du signal et permet ainsi d'apprécier le temps moyen restant avant l'occurrence de la défaillance et de prévenir l'opérateur.

Au-delà de ces exemples, les procédés physiques, non nécessairement médicaux, sont parfois complexes, et difficilement modélisables. L'approche de diagnostic par modèle formel ne peut apporter de solutions, la démarche de surveillance n'utilisant que les signaux mesurés est alors une alternative. Il semble donc intéressant dans le futur d'élargir l'application des méthodes proposées dans ce document à d'autres procédés, et voir dans quelle mesure elles peuvent se substituer ou compléter une approche par modèle. Nous commençons actuellement une collaboration avec l'Université Technologique d'Helsinki en Finlande sur la supervision de machines servant à l'exploitation forestière. Un doctorant de cette université finlandaise est actuellement en stage au LAG pour quatre mois. Il applique notre méthode d'extraction de tendances sur des indicateurs de défauts qu'il a construit afin d'élaborer un système de supervision adapté à ces machines.

Les systèmes médicaux restent néanmoins un domaine de prédilection pour le développement d'outils d'aide à l'interprétation de données. La surveillance de patients en unités de soins intensifs est un secteur d'application très riche pour ce domaine de recherche. Ce thème intéresse un petit nombre de personnes dans la communauté internationale. Un groupe de travail informel, nommé MultICU, a été créé en 2003 à l'initiative du Pr. Jim Hunter de l'Université d'Aberdeen, dans le but de mettre en commun des données enregistrées sur des patients hospitalisés en soins intensifs et des outils pour les traiter. Une proposition de projet européen intégrant les différents partenaires de ce groupe a été déposée en Juillet 05, mais n'a pas été retenue. Le groupe est maintenant en attente de nouveaux appels à propositions auquel il pourrait répondre.

Il est à noter qu'avec l'émergence de nouvelles technologies, le secteur médical va être de plus en plus en demande d'outils d'aide à l'interprétation de données. En effet, ces nouvelles technologies amènent une nouvelle prise en charge du patient.

Ainsi, la télémédecine permet le suivi du patient à distance. Elle concerne les patients nécessitant une surveillance accrue, comme les personnes rentrant à leur domicile après une période d'hospitalisation ou les patients souffrant de pathologies chroniques. Des appareils permettent la mesure de variables physiologiques au domicile du patient, qui sont ensuite transmises au médecin via Internet. Le contact médecin-patient est moins fréquent, mais la quantité d'informations transmises au médecin est plus régulière et plus importante. L'adaptation d'un traitement peut se faire plus fréquemment, au fil des informations reçues. Cette augmentation de la quantité des informations à analyser augmente la charge cognitive associée au diagnostic médical, sans diminuer bien sûr l'exigence de qualité des soins. On imagine aisément l'intérêt que peut avoir pour le médecin un système capable de mettre en évidence, dans le flot de données reçues, certaines modifications des variables physiologiques, voire de proposer une adaptation de la thérapie.

De même, le développement de systèmes de mesure embarqués va permettre l'enregistrement de variables physiologiques en ambulatoire, auquel devront être associées des fonctions d'analyse des variables enregistrées, permettant de mettre en évidence des situations pathologiques. Le champ d'application de la surveillance et du diagnostic, jusqu'alors surtout restreint aux personnes hospitalisées dont l'état est suivi de près par des systèmes de monitoring, ou aux personnes équipées à domicile d'appareils de surveillance, va considérablement s'élargir. On peut

envisager un suivi constant des personnes à risques - personnes souffrant de pathologies chroniques, personnes âgées maintenues à domicile - permettant de détecter des situations de crise au plus tôt, ou au contraire, limitant les fausses alarmes et les interventions du SAMU. Dans cet esprit, un projet d'aide à la promenade individualisée (API) a été soumis à l'appel à projet Technologies pour la santé (TecSan 2006) de l'ANR, mais n'a malheureusement pas été retenu. L'objectif du projet API est le développement d'un gilet portable équipé de capteurs permettant la mesure de variables physiologiques (la fréquence cardiaque, le rythme respiratoire, l'actimétrie, la position via un GPS et la température extérieure) et équipé d'un système communicant avec la personne, visant à favoriser la marche pour une personne âgée en la rassurant sur son état et en l'encourageant. Un module de décision intégré dans le gilet portable doit caractériser l'état physiologique de la personne au cours de la promenade à l'aide des informations recueillies en ligne et d'un modèle de décision appris hors ligne. Compte tenu de son impact sociétal important, le projet sera probablement soumis à nouveau à un prochain appel à propositions.

A l'opposé des systèmes embarqués, l'avenir se porte aussi sur l'intégration de données multimodales pour la détection de situation à risques. Dans le cas d'une surveillance statique, on peut envisager coupler des informations vidéo avec des signaux physiologiques si on s'intéresse à la surveillance de personnes. Les applications sont nombreuses : surveillance de personnes âgées à domicile, surveillance de conducteurs (poids lourds, transport en commun), surveillance d'opérateurs ... Les deux sources d'informations, vidéo et signaux, sont complémentaires pour l'analyse d'une situation. Par exemple, une situation d'endormissement peut être détectée sur la vidéo par la fermeture prolongée des paupières, par des baillements et sur le signal EEG par des modifications du spectre fréquentiel. La problématique associée porte sur le développement d'algorithmes de reconnaissance du comportement humain à partir de chacun des signaux (vidéo, signaux physiologiques) séparément, dans un premier temps, puis de techniques de fusion d'informations, dans un second temps. Je démarre un projet de recherche sur ce thème, en collaboration avec une chercheuse du LIS (laboratoire des images et signaux), Alice Caplier. Les deux laboratoires, le LAG et le LIS, fusionneront en 2007 en un grand laboratoire, GIPSA, dont le LIS et le LAG seront deux départements. Nous avons obtenu pour ce projet un financement local de la fédération ELESAs, et une bourse de thèse fléchée de l'école doctorale EEATS de l'INPG, qui nous permet de débiter un travail de thèse à partir d'Octobre 2006. L'application retenue, qui servira de support au développement d'algorithmes de fusion d'informations vidéo et physiologiques, est la surveillance de conducteur automobile.

Pour conclure, l'évolution actuelle de la société laisse à penser que le besoin en systèmes de surveillance de l'état physiologique d'une personne sera encore plus important dans le futur, du fait du vieillissement de la population et de l'augmentation du nombre de personnes souffrant de pathologies qui en découle. Il est donc important de développer des méthodes de surveillance adaptées à ces systèmes, qui sont difficilement modélisables, mais de plus en plus facilement « mesurables » grâce aux progrès dans le domaine de l'informatique et des capteurs.

Références bibliographiques

- [BLO 06] Blodt, M., Regnier, J., Chabert, M., Faucher, J. "Fault indicators for stator current based detection of torque oscillations in induction motors at variable speed using time-frequency analysis" *Proceedings of the 3rd IET International Conference on Power Electronics, Machines and Drives PEMD 2006*, 4-6 Avril, Dublin Irlande, 2006
- [AGU 01] Aguilar-Martin J., Estruch R. S., Waissman J. "Knowledge-based signal analysis and case-based condition monitoring of a machine tool" *Proceedings of the Joint 9th IFSA World Congress and 20th NAFIPS International Conference*, jul. 25-28, Vancouver Canada pp. 286-91, 2001
- [ALS 02] Alsmadi SS, Kahya Y.P. "On line classification of lung sounds using DSP" *Proceedings of the Second Joint EMBS-BMES Conference 2002 24th Annual International Conference of the Engineering in Medicine and Biology Society*. Houston, TX, USA. 23-26 Oct., 2002.
- [AVE 90] Avent R., Charlton J., "A critical review of trend-detection methodologies for biomedical systems", *Critical Reviews in Biomedical engineering* vol. 17, pp.621-659, 1990
- [BAR 94] Bardou O; Sidahmed M "Early detection of leakages in the exhaust and discharge systems of reciprocating machines by vibration analysis" *Mechanical Systems and Signal Processing*. Vol. 8, n°5, pp.551-70, 1994
- [BAS 86] Basseville M. ; Benveniste A. "Detection of abrupt changes in signals and dynamical systems" *Springer-Verlag*, 1986
- [BAS 93] Basseville M., Nikiforov I. "Detection of abrupt changes" *Englewood cliffs*, NJ : Prentice-Hall, 1993
- [BAS 94 a] Baski B.R., Stephanopoulos G., "Representation of process trends part III: Multiscale extraction of trends from process data", *Comp. Chem. Engng.* Vol. 18, 267-302, 1994.
- [BAS 94 b] Bakshi, B.R., Stephanopoulos G., « Representation of process trends IV. Induction of real-time patterns from operating data for diagnosis and supervisory control », *Comp. Chem. Engng.* Vol. 18, p. 303-332, 1994.
- [BEC 00] Becq G. « Gestion des alarmes en oxymétrie de pouls en unités de soins intensifs » *Rapport de DEA, MIMB, LAG, UJF, Grenoble, Septembre 2000*
- [BEC 04] Becq Guillaume « Contribution au développement d'un système portable automatique d'aide à la détermination de l'état d'urgence d'un blessé polytraumatisé ; Apprentissage de classes de choc hémorragique » *Thèse de doctorat de l'Université Joseph Fourier, Déc. 2004*
- [BEC 05] Becq G., Charbonnier S., Chapotot F., Buguet A., Bourdon L., Baconnier P. "Comparison between five classifiers for automatic scoring of human sleep recordings" in *Studies in Computational Intelligence (SCI)*, Vol. 4, 113-127, *Springer-Verlag 2005* Volume 4 : Classification and clustering for knowledge discovery, Editors: Saman K. Halgamuge and Lipo Wang, Springer Verlag
- [BEC 97] Becker K., Thull B., Kasmacher-Leidinger H., Stemmer J., Rau G., Kalff G., Zimmermann H-J. "Design and validation of an intelligent patient monitoring and alarm system based on a fuzzy logic process model", *Artificial Intelligence in Medicine*, vol. 11, pp.33-53, 1997.
- [BEH 91] Behbehani, K.; Cross, R.R. "A controller for regulation of mean arterial blood pressure using optimum nitroprusside infusion rate" *IEEE Transactions on Biomedical Engineering*, Vol. 38 n° 6, pp. 679-687, 1991
- [BEN 89] Beneken J., Van der A A. J., "Alarms and their limits in monitoring" *J Clin Monit.*, Vol.5 pp. 205-210, 1989

- [BLA 03] Blayac R. « De l'extraction de séquences temporelles en ligne vers un système d'aide à l'interprétation d'alarmes en USI ». *Rapport de DEA Automatique*, LAG, INPG, Grenoble, Septembre 2003
- [BLE 95] Bleicner G. « Guide des outils d'évaluation en réanimation » *Arnette Blackwell*, Paris, 1995
- [BRO 03] Brouillet G. « Diagnostic automatique à base de logique floue de systèmes médicaux . Application au diagnostic en ligne de l'état de gravité d'un blessé » *Rapport de DEA Automatique*, LAG, INPG, Grenoble, Septembre 2003
- [CAL 00] Calvelo D., Chambrin M.-C., Pomorski D., Ravaux P., « Towards symbolisation using data-driven extraction of local trends for ICU monitoring », *Artificial Intelligence in Medicine*, vol. 1-2, p. 203-223, 2000.
- [CAL 99] Calvelo D., Chambrin M.-C., Pomorski D., Ravaux P., « ICU patient state characterization using machine learning in a time series framework », *Proceedings of AIMDM'99*, Lecture Notes in Artificial Intelligence, vol. 1620, p. 356-360, 1999.
- [CAR 03] Carrault G., Cordier M. -O., Quiniou R., Wang, F. "Temporal abstraction and inductive logic programming for arrhythmia recognition from electrocardiograms" *Artificial Intelligence in Medicine*, Vol. 28, n° 3 , pp. 231-263, 2003
- [CAV 04] Cavallini A; Conti M; Contin A; Montanari GC; Puletti F "A new algorithm for the identification of defects generating partial discharges in rotating machines" *Proceedings of the 2004 IEEE International Symposium on Electrical Insulation*. Indianapolis, IN, USA. 19-22 Sept., 2004.
- [CHA 00] Charbonnier S., Galichet S., Mauris G., Siché JP "Statistical and fuzzy models of ambulatory systolic blood pressure for hypertension diagnosis" *IEEE Transactions on Instrumentation and Measurement* Vol. 49, n° 5, Oct. 2000, pp. 998-1003
- [CHAM 03] Champion H., Bellamy R., Roberts P., Leppaniemi A. « A profile of combat injury » *The journal of TRAUMA Injury, Infection and Critical Care*, vol 54, n°5, S13-S17, 2003
- [CHA 03] Charbonnier S., « On Line Extraction of Successive Temporal Sequences from ICU High-Frequency Data for Decision Support Information », *Proceedings of the AIME03*, Lecture notes in Artificial Intelligence 2780, p. 1-10, 2003.
- [CHA 04a] Charbonnier S., Becq G., Biot L., « On line segmentation algorithm for continuously monitored data in Intensive Care Units », *IEEE Transactions on Biomedical Engineering*, vol. 51, n°3, p. 484-492, 2004.
- [CHA 05a] Charbonnier, L. Badji, S. Gentil "An intelligent alarm system based on temporal episodes for Intensive Care Units" 16th IFAC World Congress, Prague, 4-8 Juillet 05
- [CHA 05b] S. Charbonnier S., Garcia-Beltan C., Cadet C., Gentil S. "Trends extraction and analysis for complex system monitoring and decision support" *Engineering Applications of Artificial Intelligence* Vol 18, n°1, pp 21-36, 05
- [CHA 05c] Charbonnier S. "On Line Extraction of Temporal Episodes from ICU High-Frequency Data: a visual support for signal interpretation" *Computer Methods and Programs in Biomedicine*, 78, 115-132, 05
- [CHA 06a] Charbonnier S. "Multivariable event detection in Intensive Care Units", *6th IFAC Symposium on Modelling and Control in Biomedical Systems*, September 20-22, 2006, Reims, France
- [CHA 06b] Charbonnier S., Pean D., Gentil S. « Alarm Filtering in Intensive Care Units using Multivariable Analysis of Physiological Parameters" *6th IFAC Symposium on Fault detection, Supervision and safety of technical processes (SafeProcess 06)*, Beijing, China, August 30th - September 1st ,06

- [CHA 06c] S. Charbonnier, S. Gentil "A trend-based alarm system to improve patient monitoring in Intensive Care Units" Note interne, *article en soumission à Contrôle Engineering Practice*
- [CHA 99] Charbonnier S., Siché JP, Mallion JM "Toward a portable blood pressure recorder device equipped with accelerometers" *Medical Engineering and Physics*, vol. 21, pp. 343-352, 99
- [CHAM 04] Chambrin M.-C., Charbonnier S., Sashar S., Becq G., Badji L., « Automatic characterization of events on Spo2 signal: a comparison of two methods », *26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, San Francisco (USA), 2004.
- [CHE 05] Chee, F.; Savkin, A.V.; Fernando, T.L.; Nahavandi, S. "Optimal H₂/spl infin// insulin injection control for blood glucose regulation in diabetic patients" *IEEE Transactions on Biomedical Engineering*, Vol. 52, n°10, pp. 1625- 1631, 2005
- [CHE 90 b] Cheung J.T., Stephanopoulos G., « Representation of process trends. Part II: The problem of scale and qualitative scaling » *Comput. Chem. Engng.*, vol. 14 (4/5), p. 511-539, 1990.
- [CHE 90] cheung J. T.-Y., Stephanopoulos G., « Representation of process trends- Part I: A formal representation framework », *Computers chem. Engng*, vol. 14 (4/5), p. 495-510, 1990.
- [CHI 97] Chin-Te Chen; Wen-Li Lin; Te-Son Kuo; Cheng-Yi Wang "Adaptive control of arterial blood pressure with a learning controller based on multilayer neural networks" *IEEE Transactions on Biomedical Engineering*, Vol. 44, n° 7, pp. 601-609, 1997
- [COL 01] COLOMER J., MELENDEZ J. « A family of FIR differentiators based on a polynomial least squares estimation » *Proceedings of the European Control Conference*, 2001, pp. 2802-2807.
- [COL 02 a] Colomer J., Melendez J., Gamero F. I., « Pattern recognition based on episodes and DTW. Application to diagnosis of a level control system », *Proceedings of the 16th International Workshop on Qualitative reasoning QR2002*, p.37-43, Sitges (Espagne), 2002.
- [COL 02 b] Colomer J., Melendez J., Gamero F. I., « Qualitative representation of process trends for situation assessment based on cases », *Proceedings of 25th IFAC World Congress b'02*, Barcelona (Espagne), 2002.
- [COR 01] Cordier MO; Dousson C "Alarm driven monitoring based on chronicles" Fault Detection, Supervision and Safety for Technical Processes *SAFEPROCESS 2000*. Budapest, Hungary, 14-16 Jun,e 2000.
- [COR 02] Cornuéjols A., Miclet L. "Apprentissage artificiel, Concepts et algorithmes" *Ed. Eyrolles*, 2002
- [DAS 03] Dash S., Rengaswamy R., Venkatasubramanian V. "Fuzzy logic based trend classification for fault diagnosis of chemical processes" *Computers and Chemical Engineering*, vol. 27, pp. 347-362, 2003
- [DEL 94] Delapasse, J.S.; Behbehani, K.; Kuangchung Tsui; Klein, K.W. "Accommodation of time delay variations in automatic infusion of sodium nitroprusside" *IEEE Transactions on Biomedical Engineering*, Vol. 41, n°11, pp. 1083-1091, 1994
- [DEN 01] Denoeux T. « Diagnostic par reconnaissance de formes, Approches non probabilistes » dans Diagnostic, intelligence artificielle et reconnaissance des formes, Productique (IC2) *Editions Hermes Lavoisier Paris* Chap 3 pp.215-244, 2001
- [DEN 97] Denoeux, T. Masson, M. Dubuisson, B. « Advanced Pattern Recognition Techniques for System Monitoring and Diagnosis : a Survey" *JESA*, VOL 31; N° 9/10, pp. 1509-1540, 1997
- [DUB 01a] Dubuisson B. « Diagnostic, intelligence artificielle et reconnaissance des formes », Productique (IC2) *Editions Hermes Lavoisier Paris*, 2001
- [DUB 01b] Dubuisson B. « Automatique et statistiques pour le diagnostic » *Hermès Science Publications*, Paris, 2001

- [DUB 90] Dubuisson B. « Diagnostic et reconnaissance des formes » *Editions Hermes* Lavoisier Paris, 1990
- [DUB 96] Dubuisson B., Storoswiecki M., Cassar J-P, Denoeux T. (eds) “Surveillance des systèmes continus” Actes de l’Ecole d’été d’automatique , tomes I et II, session 14, 1996
- [EVS 00] Evsukoff A; Gentil S; Montmain J “Fuzzy reasoning in co-operative supervision systems” *Control Engineering Practice*. Vol. 8, n°4, pp. 389-407, 2000
- [EVS 98] Evsukoff A. « Le raisonnement approché pour la surveillance de procédés » *Doctorat de l'INPG*, 10 novembre 1998.
- [FEN 02] Fenton B, McGinnity M, Maguire L “Fault diagnosis of electronic system using artificial intelligence” *IEEE Instrumentation and Measurement Magazine*. Vol. 5 n°3, pp. 16-20, 2002
- [FRE 00] Frei, C.W., Derighetti, M., Morari, M.; Glattfelder, A.H.; Zbinden, A.M. “Improving regulation of mean arterial blood pressure during anesthesia through estimates of surgery effects” *IEEE Transactions on Biomedical Engineering*, Vol. 47, n° 11, pp. 1456-1464, 2000
- [FUK 90] Fukunaga K. “Introduction to statistical pattern recognition” *Academic Press*, San Diego, USA, 2nd Edition, 1990
- [FUR 95] Furutani, E.; Araki, M.; Maetani, S. “ Blood pressure control during surgical operations” *IEEE Transactions on Biomedical Engineering*, Vol. 42, n° 10, pp. 999-1006, 1995
- [GAM 06] Gamero F.I., Colomer J., Melendez J., Warren P. “Predicting aerodynamic instabilities in a blast furnace” *Engng. Applic. Artif. Intell.*, vol. 19, pp. 103-11, 2006
- [GAS 82] Gasser T., Bacher P., Mochs J. „Transformations towards distribution of broad band spectral parameters of the EEG“ *Electoencephalography and Clinical Neurophysiology*, pp. 119-124, 1982
- [GEN 05] Gentil S., Garcia-Beltran C., Charbonnier S., « Semi-qualitative temporal episodes prognosis for process supervision », *Proceedings of the IFAC World Congress*, Prague (Czech Republic), 2005.
- [GUL 05] Guler, I.; Derya Ubeyli, E. “Expert system for detection of electrocardiographic changes in patients with partial epilepsy using wavelet-based neural networks” *Expert Systems*. vol. 22, n°2, pp.62-71, 2005
- [HAI 04] Haiqiao Wu; Yi Liu; Yunliang Ding; Yongqing Qiu “Fault diagnosis expert system for modern commercial aircraft” *Aircraft Engineering and Aerospace Technology*. Vol. 76, n°4, pp.398-403, 2004
- [HAI 95] Haimowitz, P.L. Phillip, I. Kohane, “Clinical monitoring using regression-based trend templates”, *Artificial intelligence in medicine* vol.7 pp.473-496, 1995
- [HAI 95] Ira J. Haimowitz, Phillip Phuc Le and Isaac S. Kohane “Clinical monitoring using regression-based trend templates” *Artificial Intelligence in Medicine*, Vol. 7, n° 6, pp. 473-496, 1995
- [HAI 96] I. Haimowitz, P.L. Phillip, I. Kohane, Managing temporal worlds for medical trend diagnosis, *Artificial intelligence in medicine* vol.8 pp. 299-321, 1996
- [HEN 02] Henry M. « Détection en ligne de la tendance symbolique d’un signal biologique » *Rapport de DEA SIPT*, LAG, INPG, Grenoble, Septembre 2002
- [HER 94] Herault J. Jutten C. “Les réseaux de neurones et le traitement du signal” *Hermes*, 1994
- [HUN 99] Hunter J., McIntosh N., « Knowledge based event detection in complex time series data », *Proceedings of the AIDM'99, Lecture Notes in Artificial Intelligence*, vol.1620, p. 271-280, 1999.
- [IMH 98] M. Imhoff, M. Bauer, U. Gather, D. Lohlein, “Statistical pattern detection in univariate time series of intensive care on_line monitoring data”, *Intensive Care Medicine* vol.24, pp.1305-1314, 1998

- [ISA 93] Isaka, S.; Sebald, A.V. "Control strategies for arterial blood pressure regulation" *IEEE Transactions on Biomedical Engineering*, Vol. 40, n° 4, pp. 353-363, 1993
- [JAN 91] Janusz M., Venkatasubramanian V., « Automatic generation of qualitative description of process trends for fault detection and diagnosis », *Engng. Applic. Artif. Intell.*, vol. 4, p. 329-340, 1991.
- [JEO 06] Jeong, Myong K.; Lu, Jye-Chyi; Huo, Xiaoming; Vidakovic, Brani; Di Chen "Wavelet-Based Data Reduction Techniques for Process Fault Detection" *Technometrics*, Vol. 48, N° 1, pp. 26-40, 2006
- [JIA 99] Jiann Shing Shieh; Linkens, D.A.; Peacock, J.E. "Hierarchical rule-based and self-organizing fuzzy logic control for depth of anaesthesia" *IEEE Transactions on Systems, Man and Cybernetics, Part C*, Vol. 29, n°1, pp. 98-109, 1999
- [KAH 06] Kahaei, M. H.; Torbatian, M.; Poshtan, J. "Detection of bearing faults using Haar wavelets" *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*. E89 A(3): pp. 757-63, 2006
- [KAS 98] Kassidas A; Taylor PA; MacGregor JF "Off-line diagnosis of deterministic faults in continuous dynamic multivariable processes using speech recognition methods" *Journal of Process Control*. Vol. 8, n°5-6, pp.381-93, 1998
- [KAY 98] Kay S.M "Fundamentals of Statistical Signal Processing : detection theory." Volume II *Prentice Hall PTR*, 1998
- [KEO 97] Keogh E. « A Fast and Robust Method for Pattern Matching in Time Series Databases », *Proceedings of 9th International Conference on Tools with Artificial Intelligence TAI '97*, 1997.
- [KEO 97] Keogh E; Smyth P "A probabilistic approach to fast pattern matching in time series databases" *Proceedings of the Third International Conference on Knowledge Discovery and Data Mining -KDD 97*. Newport Beach, CA, USA. 14-17 Aug., 1997.
- [KEO 01] Keogh E; Chu S.; Hart D., Pazzani M. "An Online Algorithm for Segmenting Time Series" *Proceedings of the First IEEE International Conference on Data Mining (ICDM'01)*, San Jose, California, USA, November 29 - December 2, 2001
- [KIA 93] Kienitz, K.H.; Yoneyama, T. "A robust controller for insulin pumps based on H-infinity theory" *IEEE Transactions on Biomedical Engineering*, Vol. 40, n°11, pp.1133-1137, 1993
- [KON 92] Konstantinov K., Yoshida T., « Real-time Qualitative Analysis of the Temporal Shapes of (bio) processes Variables », *AIChE Journal*, vol. 38 ,n°11), p. 1703-1715, 1992.
- [KOS 94] E.M.J. Koski, T. Sukuvaara, A. Makivirta, A. Kari, A knowledge-based alarm system for monitoring cardiac operated patients – assessment of clinical performance, *International Journal of Clinical Monitoring and Computing* vol.11, pp.79-83, 1994
- [LAM 05] Lamrini,-B.; Le-Lann,-M.--V.; Benhammou,-A.; Lakhel,-E.-K. »Detection of functional states by the 'LAMDA' classification technique: application to a coagulation process in drinking water treatment » *Comptes Rendus de Academie des Sciences en Physique*. vol. 6, n° 10, pp. 1161-8, 2005
- [LAW 94] Lawless S. , "Crying wolf: false alarms in a pediatric intensive care unit" *Critical Care Medicine* vol. 22 pp. 981-985, 1994
- [LES 03] Lesecq S. ; Barraud A. « Arcing fault detection using wavelet transform »5th IFAC Symposium on Fault Detection, Supervision and Safety of technical Processes, *IFAC Symposium Safeprocess 2003*, 9-11 june, Washington, USA, 2003
- [LES 05] Lesecq S; Gentil S; Taleb S; Fagarasan I "Diagnostic decision algorithm based on spectral analysis and model validity" *IEEE International Conference on Control Applications (CCA)*. Toronto, Ont., Canada. 28-31 Aug 2005.

- [LOW 99] A. Lowe, M. Harrison, R. Jones, « Diagnostic monitoring in anaesthesia using fuzzy trend templates for matching temporal patterns », *Artificial Intelligence in Medicine* vol. 16 pp. 183-199, 1999
- [LOW 01] A. Lowe, R. Jones, M. Harrison, “The graphical presentation of decision support information in an intelligent anesthesia monitor”, *Artificial Intelligence in medicine*, vol. 22, pp. 173-191, 2001
- [MAI 97] Maitelli, A.L.; Yoneyama, T. « Suboptimal dual adaptive control for blood pressure management” *IEEE Transactions on Biomedical Engineering*, Vol. 44, n° 6, pp. 486-492, 1997
- [MAK 89] Makivirta A., Koski E., Kari A., Sukuvaara T., « Robust signal-to-symbol transformation using median filters », *Proceedings of IFAC Workshop on Decision Support for patient Management: Measurement, Modelling and Control*, pp. 91-104, 1989.
- [MAK 91] Makivirta A., Koski E., Kari A., Sukuvaara T., « The median filter as a preprocessor for a patient monitor limit alarm system in intensive care », *Computer Methods and Programs in Biomedicine*, vol. 34, p. 139-144, 1991.
- [MAR 04] Martin N., Durnerin M. . « Détection de non-stationnarités . Décision temps-fréquence », *HERMES* . Traité IC2. Chapitre 2 , 2004
- [MAR 92] Martin, I.F.; Schneider, A.M.; Quinn, M.L.; Smith, N.T. “Improved safety and efficacy in adaptive control of arterial blood pressure through the use of a supervisor” *IEEE Transactions on Biomedical Engineering*, Vol. 39, n° 4, pp. 381-388, 1992
- [MEL 01a] Melendez J, Colomer J, de la Rosa JL “Expert supervision based on cases” *Proceedings of the 8th International Conference on Emerging Technologies and Factory Automation. Proceedings ETFA 2001*
- [MEL 01b] Melendez J. Colomer J. « Episodes representation for supervision. Application to diagnosis of a level control system » *Proceedings of the Workshop on Principles of Diagnosis, DX’01*, 2002, Sansicario (Italie)
- [MIK 96] S. Miksh, W. Horn, C. Popow, F. Paky, “Utilizing temporal data abstraction for data validation in therapy planning for artificially ventilated newborn infants”, *Artificial Intelligence in Medicine* vol. 8, pp. 543-576, 1996
- [MIK 97] S. Miksh, W. Horn, C. Popow, F. Paky, « Time-oriented analysis of high frequency data in ICU monitoring”, in *Intelligent data analysis in Medicine and pharmacology eds Lavrac N., Keravnou E, Zupan B.* (1997) 17-36, Kluwer Academic Publishers
- [NIL 06] Nilsson, M., Funk, P., Olsson, E. M. G., Von Scheele, B.; Ning Xiong “Clinical decision-support for diagnosing stress-related disorders by applying psychophysiological medical knowledge to an instance-based learning system” *Artificial Intelligence in Medicine*. Vol. 36, n°2, pp.159-76, 2006
- [O’CA 86] O’Carrol, T, « Survey of alarms in an intensive therapy unit », *Anaesthesia*, vol. 41, p. 742-744, 1986.
- [OKU 04] Okuno T; Tsunoyama M; Ogawa M; Sato T “A fuzzy expert system for facility diagnosis of rotating machines” *2nd IASTED International Conference on Neural Networks and Computational Intelligence, NCI 2004*. Grindelwald, Switzerland. 23-25 Feb. 2004
- [OLS 04] Olsson E; Funk P; Ning Xiong “Fault diagnosis in industry using sensor readings and case-based reasoning” *Journal of Intelligent and Fuzzy Systems*. Vol. 15, n°1, pp. 41-6, 2004
- [OZB 06] Ozbay, Y.; Ceylan, R.; Karlik, B. “A fuzzy clustering neural network architecture for classification of ECG arrhythmias” *Computers in Biology and Medicine*. Vol. 36 n°4 pp.376-88, 2006
- [PAI 87] Paiss O., Inbar F.G. “Auto regressive modelling of surface EMG and its spectrum with application to fatigue” *IEEE Trans. Biomed. Eng.*, vol. 34; n° 10, pp. 761-769, 1987

- [PAJ 90] Pajunen, G.A.; Steinmetz, M.; Shankar, R. "Model reference adaptive control with constraints for postoperative blood pressure management" *IEEE Transactions on Biomedical Engineering*, Vol. 37, n° 7, pp. 679-687, 1990
- [PEA 05] Pean D. « Détection des variations temporelles survenant sur des paramètres biologiques enregistrés sur des patients hospitalisés en réanimation à des fins de filtrage d'alarmes de Spo2 » *Rapport de DEA Automatique*, LAG, INPG, Grenoble, Juin 2005
- [PLA 94] Plaisance P., Payen D. « Le choc hémorragique » *Collection d'anesthésiologie et de réanimation*, Masson, Paris, chapitre Physiopathologie du choc hémorragique pp. 1-16, 1994
- [QUI 93] Quinlan J.R. « C4.5 : Programs for machine learning » *Morgan Kaufman Publishers*, San Mateo, California, USA, 93
- [RAJ 05] Rajagopalan, S.; Aller, J. M.; Restrepo, J. A.; Habetler, T. G.; Harley, R. G. "A novel analytic wavelet ridge detector for dynamic eccentricity detection in BLDC motors under dynamic operating conditions" *Proceedings of IECON 2005. Thirty-First Annual Conference of the IEEE Industrial Electronics Society*. 6-10 Nov. 2005 Raleigh, NC, USA, 2005
- [REN 01] Rengaswamy R., Hagglund T., Venkatasubramanian V., « A qualitative shape analysis formalism for monitoring control loop performance », *Eng. App. of Art. Intell.*, vol. 14, p. 23-33, 2001.
- [REN 95 a] Rengaswamy R., Ventaakasubramanian V., « A syntactic pattern recognition approach for process monitoring and fault diagnosis », *Engng. Applic. Artif. Intell.*, Vol. 8, p. 35-51, 1995.
- [REN 95 b] Rengaswamy R., A framework for integrating process monitoring, diagnosis and supervisory control, *Thèse de doctorat*, Purdue University, 1995.
- [SEU 05] Seung Hwan Seong; Seop Hur; Jung Soo Kim; Jung Tak Kim; Won Man Park; Un Chul Lee; Sang Kyung Lee "Development of diagnosis algorithm for the check valve with spectral estimations and neural network models using acoustic signals" *Annals of Nuclear Energy*. 32(5): 479-92, 2005
- [SHI 06] Shih Ming Wang; Ming Je Luo; Hsing Yung Shieh "An on-line failure identification method for rotor systems" *Proceedings of the 25th IASTED International Conference on Modelling, Identification, and Control*. 6-8 Feb. Lanzarote, Canary Island, Spain, 2006
- [SIN 01] Singhal A; Seborg DE "Matching patterns from historical data using PCA and distance similarity factors" *Proceedings of American Control Conference*. Arlington, VA, USA 25-27 June, 2001
- [SRI 05] Srinivasan, V.; Eswaran, C.; Sriraam, N. "Artificial neural network based epileptic detection using time-domain and frequency-domain features" *Journal of Medical Systems.*; vol. 29, n°6, pp.647-60, 2005
- [STE 96] F. Steimann, « The interpretation of time-varying data with DIAMON-1", *Artificial Intelligence in Medicine* vol. 8 pp.343-357, 1996
- [STE 97] Stephanopoulos G., Locher G., Duff M., Kamimura R., « Fermentation data base mining by pattern recognition », *Biotechnology and Bioengineering*, vol. 53-5, p 443-452, 1997
- [SUK 93] T. Sukuvaara, E. Koski, A. Makivirta, A. Kari, "A knowledge-based alarm system for monitoring cardiac operated patients – technical construction and evaluation », *International Journal of Clinical Monitoring and Computing*, vol.10, pp. 117-126,1993
- [THA 92] Thavathia S., Rangayyan R, Fank C., Bell G.D., Ladly K.O., Zhang Y.T." Analysis of knee vibration signals using linear prediction", *IEEE Trans. Biomed. Eng.* Vol. 39, n°9, Sept 1992.
- [THI 97] Thiria S., Lechevallier Y., Gascuel O., Canu S. "Statistiques et méthodes neuronales" *Dunod*, Paris, 1997

- [TRA 98] Trajanoski, Z.; Wach, P. "Neural predictive controller for insulin delivery using the subcutaneous route" *IEEE Transactions on Biomedical Engineering*, Vol. 45, n° 9, pp. 1122-1134, 1998
- [TSI 97] Tsien C., Fackler J. "Poor prognosis for existing monitors in the intensive care unit". *Critical Care medicine* vol. 25 n°, p. 614 – 619, 1997.
- [TSI 00] Tsien C., Kohane I., McIntosh N. « Multiple signal integration by decision tree induction to detect artifacts in the neonatal intensive care units » *Artificial Intelligence in Medicine*, vol. 19, pp. 189-202, 2000
- [VED 97 a] Vedam H., Venkatasubramanian V., Bhalodia R., « A B-Spline based method for data compression, process monitoring and diagnosis », *Comput. Chem. Engng* vol. 21, p. 655-660, 1997.
- [VED 97 b] Vedam H., Venkatasubramanian V., « A wavelet Theory-based Adaptive Trend Analysis System for Process monitoring and diagnosis », *Proceedings of the American Control Conference*, Piscataway (NJ, USA), p 309-313, 1997.
- [YAI 04] Yairi T; Ogasawara S; Hori K; Nakasuka S; Ishihama N "Summarization of spacecraft telemetry data by extracting significant temporal patterns" *Advances in Knowledge Discovery and Data Mining. 8th Pacific-Asia Conference, PAKDD 2004*. Proceedings. Sydney, Australia, 26-28 May, 2004.
- [Yan 05] Yang P., Dumont G., Lim J., Ansermino J. M. "Adaptive change point detection for respiratory variables" *Proceedings of the 27th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Shanghai (Chine), 2005
- [ZIK 06] Zikov, T. Bibian, S. Dumont, G.A. Huzmezan, M. Ries, C.R. "Quantifying cortical activity during general anesthesia using wavelet analysis" *IEEE Transactions on Biomedical Engineering*, Vol. 53, n° 4, pp. 617 – 632, 2006
- [ZIY 03] Ziyen Wen; Crossman J; Cardillo J; Murphey YL "Case-base reasoning in vehicle fault diagnostics" *International Joint Conference on Neural Networks*. Portland, OR, USA. 20-24 July, 2003.
- [ZOU 06] Zoubek L. , Charbonnier S., Lesecq S., Buguet A., Chapotot F. "Knowledge extraction about sleep/wake stages using data driven methods" , *6th IFAC Symposium on Modelling and Control in Biomedical Systems*, September 20-22, 2006, Reims, France
- [ZWI 95] Zwingelstein G. « Diagnostic des défaillances, théorie et pratique pour les systèmes industriels » série Diagnostic et Maintenance, *Hermès*, Paris, 1995