






Caractérisation des signaux physiologiques

5. Filtrage adaptatif




Plan



- Introduction


Introduction



■ Contexte

- Les signaux physiologiques sont des signaux à composante aléatoire, l'acquisition étant perturbée par différents types de bruit


■ Exemples :



Bruit
d'acquisition

Le bruit à 50Hz sur un ECG


Introduction



■ Contexte


- Les signaux physiologiques sont des signaux à composante aléatoire, l'acquisition étant perturbée par différents types de bruit

■ Exemples :



ECG foetal perturbé par celui de la maman


Introduction



■ Contexte

- Le filtrage classique atteint ses limites pour ce type de signaux (superposition des spectres)
- L'idée est alors de définir des filtres dont **la réponse impulsionnelle peut s'adapter aux évolutions des caractéristiques statistiques du signal étudié** (moyenne, variance, corrélation etc.) au cours du temps afin d'extraire la composante d'intérêt


Introduction



■ Filtrage adaptatif ?


- Le filtrage adaptatif est basé sur la recherche de **paramètres optimaux** par **minimisation d'un critère de performance**.
- Les signaux étudiés ici étant à composante aléatoire, il est nécessaire d'avoir en tête les estimateurs associés
- Ce type de filtrage faisant appel à une problématique de minimisation d'un critère par rapport à un ensemble d'observation, le principe de régression linéaire sera également revu...

Introduction




- **Filtrage adaptatif ?**
 - ...pour enfin s'attaquer au filtre de Wiener...
 - ... et à la notion de filtrage adaptatif.

Plan



- Introduction
- Rappels sur l'estimation statistique

Estimation statistique



■ Rappels

- La moyenne d'une variable aléatoire X caractérisée par une ddp $p(x)$:


$$\mu_X = E[X] = \int_{-\infty}^{+\infty} xp(x) dx$$

- La variance de cette même variable aléatoire

$$\sigma_X^2 = E[(X - \mu_X)^2] = \int_{-\infty}^{+\infty} (x - \mu_X)^2 p(x) dx$$

$$\sigma_X^2 = E[X^2] - E[X]^2$$

Estimation statistique



■ Rappels

- Corrélation de deux variables aléatoires X et Y de lois de densité de probabilité conjointe $p(x,y)$:


$$R_{XY} = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} xyp(x,y) dx dy$$

- La covariance associée

$$C_{XY} = \sigma_{XY} = E[(X - \mu_X)(Y - \mu_Y)]$$

$$C_{XY} = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (x - \mu_X)(y - \mu_Y) p(x,y) dx dy$$

Estimation statistique




■ Rappels

- Coefficient de **corrélation linéaire**

$$r_{XY} = \frac{C_{XY}}{\sigma_X \sigma_Y} \in [-1, 1]$$


Il s'agit d'une « quantification » de l'interdépendance de 2 *v.a*

Estimation statistique




■ Rappels

■ Coefficient de **corrélation linéaire**




Plan



- Introduction
- Rappels sur l'estimation statistique
- Régression linéaire

Régression linéaire




■ Principe de la régression

- On souhaite expliquer les variations d'une variable Y à partir des valeurs observées pour la variable x .
- Le problème n'est pas symétrique : les 2 variables n'ont pas le même statut :

Y	variable à expliquer ou réponse, supposée aléatoire
x	variable explicative ou covariable ou régresseur, supposée fixe

Régression linéaire




- Principe de la régression
 - Modèle général

$$Y = f(x) + E$$

Fonction associée à
la régression

Terme résiduel
aléatoire, ou erreur


Régression linéaire





■ Principe

- La régression **linéaire** consiste en la recherche de **la droite** passant **au mieux** parmi **un ensemble de points mesurés**
- Le critère conduisant à cet optimum est la **minimisation des distances quadratiques** entre **les points mesurés et la droite optimum**.
- Il s'agit donc d'un problème **d'optimisation**

Régression linéaire




■ Principe



Optimisation de la fonctionnelle $J(a,b)$ représentant l'ensemble des droites possibles

Régression linéaire



■ Principe


■ Autrement dit :

- On observe N individus ($i = 1, \dots, N$).
- Et on suppose que pour tout i :

$$Y_i = ax_i + b + E_i$$

- Et on cherche à estimer a, b et la variance associée aux Y_i (qui est aussi la variance de la variable aléatoire E)


Régression linéaire




■ Remarques

- Le principe de régression linéaire s'applique à des grandeurs statiques (qui n'évoluent pas dans le temps)
- Le filtre de Wiener est une évolution de ce principe mais à des phénomènes évoluant dans le temps
- Du point de vue optimisation il s'agit d'un problème quadratique convexe, il y a donc nécessairement un minimum et il est unique !


Régression linéaire



■ Exemple sur l'estimation des intervalles ECG



Régression linéaire




■ 2 approches possibles pour l'estimation

■ 1. Approche des moindres carrés

- On cherche les valeurs de a et b qui minimisent la **somme des carrés des résidus**, *i.e.* les écarts entre les observations (Y_i) et les prédictions ($ax_i + b$) du modèle.

$$MSE(a, b) = \frac{1}{N} \sum_{i=1}^N (Y_i - (ax_i + b))^2$$

Régression linéaire



■ 2 approches possibles pour l'estimation


■ 2. Approche du Maximum de Vraisemblance (MLE)

- Ce critère utilise l'hypothèse de distribution gaussienne des erreurs E_i .

$$MLE(y_i; a, b, \sigma^2) = \frac{1}{\sigma \sqrt{2\pi}} \exp \left[-\frac{(y_i - (ax_i + b))^2}{2\sigma^2} \right]$$

On retrouve le critère
des moindres carrés

Régression linéaire



■ 2 approches possibles pour l'estimation


- Dans les deux cas, pour l'échantillon i pris parmi les N disponibles :

- $E_i = y_i - (ax_i + b)$

- *La moyenne de E tend vers zéro si le modèle n'est pas biaisé*


- *La variance de E doit diminuer lorsque les valeurs estimées de a et de b se rapprochent des valeurs exactes*

Régression linéaire



- **2 approches possibles pour l'estimation**
 - Remarques
 - *Les estimateurs de a , b et σ^2 sont des variables aléatoires*
 - *L'approche MLE par l'hypothèse de gaussiannité sur E , permet de caractériser les lois des estimateurs précédents*
 - *On peut alors comparer les estimateurs, définir des intervalles de confiance, etc.*

Régression linéaire




■ Exercice 1

- *On se place dans le cadre de l'approche RMS*
- *Déterminer l'expression analytique de a et de b permettant de minimiser le problème d'estimation considéré entre la variable aléatoire Y et la variable x*
- *Point de départ : on minimise la fonctionnelle suivante :*

$$MSE(a, b) = \frac{1}{N} \sum_{i=1}^N (y_i - (ax_i + b))^2$$


Régression linéaire




■ Exercice 1

- *Déterminer l'expression analytique de a et de b permettant de minimiser le problème d'estimation considéré entre la variable aléatoire Y et la variable x*

$$MSE(a,b) = \frac{1}{N} \sum_{i=1}^N (y_i - (ax_i + b))^2$$



Régression linéaire



■ Exercice 1

■ *Résolution*


On minimise

$$J(a, b) = \frac{1}{N} \sum_{n=0}^{N-1} e^2(n) = \frac{1}{N} \sum_{n=0}^{N-1} (y(n) - (ax(n) + b))^2$$

Lorsque l'écart quadratique moyen est minimum

$$\frac{\partial J(a, b)}{\partial a} = 0 \qquad \frac{\partial J(a, b)}{\partial b} = 0$$

Régression linéaire




■ Exercice 1

■ *Résolution*

Or

$$\begin{aligned}\frac{\partial J(a,b)}{\partial a} &= \frac{1}{N} \sum_{n=0}^{N-1} 2 (y(n) - (ax(n) + b)) (0 - x(n) - 0) \\ &= \frac{2}{N} \sum_{n=0}^{N-1} (-x(n)y(n) + ax^2(n) + bx(n)) \\ &= \frac{2}{N} \left(- \sum_{n=0}^{N-1} x(n)y(n) + a \sum_{n=0}^{N-1} x^2(n) + b \sum_{n=0}^{N-1} x(n) \right)\end{aligned}$$

Régression linéaire




■ Exercice 1

■ *Résolution*

Et

$$\begin{aligned}\frac{\partial J(a,b)}{\partial b} &= \frac{1}{N} \sum_{n=0}^{N-1} 2 (y(n) - (ax(n) + b)) (0 - 0 - 1) \\ &= \frac{2}{N} \sum_{n=0}^{N-1} (-y(n) + ax(n) + b) \\ &= \frac{2}{N} \left(- \sum_{n=0}^{N-1} y(n) + a \sum_{n=0}^{N-1} x(n) + \sum_{n=0}^{N-1} b \right)\end{aligned}$$

Régression linéaire



■ Exercice 1


■ *Résolution*

On obtient donc deux équations :

$$a \frac{1}{N} \sum_{n=0}^{N-1} x^2(n) + b \frac{1}{N} \sum_{n=0}^{N-1} x(n) = \frac{1}{N} \sum_{n=0}^{N-1} x(n)y(n)$$

$$a \frac{1}{N} \sum_{n=0}^{N-1} x(n) + \frac{1}{N} \sum_{n=0}^{N-1} b = \frac{1}{N} \sum_{n=0}^{N-1} y(n)$$

Régression linéaire



■ Exercice 1

■ *Résolution*

En plus compact


$$a\mu_x + b = \mu_y$$

$$a\mu_x^2 + b\mu_x = \mu_{xy}$$

Ou encore

$$\begin{pmatrix} \mu_x & 1 \\ \mu_x^2 & \mu_x \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} \mu_y \\ \mu_{xy} \end{pmatrix}$$

Régression linéaire



■ Exercice 1

■ *Résolution*


Et la solution est donc

$$\begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} \mu_x & 1 \\ \mu_x^2 & \mu_x \end{pmatrix}^{-1} \begin{pmatrix} \mu_y \\ \mu_{xy} \end{pmatrix}$$

Analytiquement :

$$a = \frac{\mu_x \mu_y - \mu_{xy}}{\mu_x^2 - \mu_x^2}$$
$$b = \frac{\mu_x \mu_{xy} - \mu_y \mu_x^2}{\mu_x^2 - \mu_x^2}$$

Régression linéaire



■ Exercice 1

■ *Résolution*

$$a = \frac{\mu_x \mu_y - \mu_{xy}}{\mu_x^2 - \mu_x^2}$$

$$b = \frac{\mu_x \mu_{xy} - \mu_y \mu_x^2}{\mu_x^2 - \mu_x^2}$$


Ou de manière plus classique

$$\hat{a} = \frac{C_{xy}}{\sigma_x^2}$$

et

$$\hat{b} = \mu_y - \hat{a}\mu_x$$

Régression linéaire




■ Exercice 2


■ Exemple

Temp.	23.8	16.3	27.2	7.1	25.1	27.5	19.4	19.8	32.2	20.7
O3	115.4	76.8	113.8	81.6	115.4	125.0	83.6	75.2	136.8	102.8

Déterminer les coefficients a et b associés à ce problème de régression linéaire



Régression linéaire



■ Exercice 2

■ Résolution


Temp.	23.8	16.3	27.2	7.1	25.1	27.5	19.4	19.8	32.2	20.7
O3	115.4	76.8	113.8	81.6	115.4	125.0	83.6	75.2	136.8	102.8

On utilise les résultats de l'exercice précédent

$$\hat{a} = \frac{C_{xy}}{\sigma_x^2}$$

$$\hat{b} = \mu_y - \hat{a}\mu_x$$

Régression linéaire



■ Exercice 2


■ Résolution

$$\hat{a} = \frac{C_{xy}}{\sigma_x^2}$$


$$\hat{b} = \mu_y - \hat{a}\mu_x$$

Temp.	23.8	16.3	27.2	7.1	25.1	27.5	19.4	19.8	32.2	20.7
O3	115.4	76.8	113.8	81.6	115.4	125.0	83.6	75.2	136.8	102.8

T	23,8
O3	115,4
T*T	566,44
T*O3	2746,52
moy_T	21,91
moy_O3	102,64
moy_T_O3	2365,084
moy_T_T	524,237
CovT_O3	129,1573333
std_T	49,09877778
a	2,630561069
b	45,00440699




Plan



- Introduction
- Rappels sur l'estimation statistique
- Régression linéaire
- Filtrage de Wiener


Filtrage de Wiener




■ Contexte

- On cherche à supprimer l'influence d'un bruit dont le spectre se superpose à celui du signal d'intérêt
- Le filtre de Wiener utilise la propriété de stationnarité des signaux aléatoires
- **Hypothèse** : le signal recherché peut se modéliser à l'aide d'un modèle MA (*Moving Average*)


Filtrage de Wiener



■ Illustration et notations



Filtrage de Wiener




■ Rappels : Modèle MA, AR

- La nature du modèle du signal de sortie dépend du type de la fonction de transfert en z associé au système considéré
- Plus précisément les modèles MA (moyenne glissante) correspondent aux sorties des filtres de type FIR

$$H(Z) = \frac{Y(Z)}{X(Z)} = \sum_{i=0}^{N-1} b_i \cdot Z^{-i}$$

Filtrage de Wiener




■ Rappels : Modèle MA, AR

- La nature du modèle du signal de sortie dépend du type de la fonction de transfert en z associé au système considéré
- Plus précisément les modèles AR (autorégressif) correspondent aux sorties des filtres de type RII tel que

$$H(Z) = \frac{Y(Z)}{X(Z)} = \frac{1}{\sum_{k=0}^{M-1} a_k \cdot Z^{-k}}$$

Filtrage de Wiener




■ Rappels : Modèle MA, AR

- La nature du modèle du signal de sortie dépend du type de la fonction de transfert en z associé au système considéré
- On parle de modèle ARMA lorsque

$$H(Z) = \frac{Y(Z)}{X(Z)} = \frac{\sum_{i=0}^{N-1} b_i \cdot Z^{-i}}{\sum_{k=0}^{M-1} a_k \cdot Z^{-k}}$$

Filtrage de Wiener




■ Problématique

- Le signal $y_p(n)$ est de type MA d'ordre p

$$y_p(n) = \sum_{k=0}^{p-1} w_k \cdot x(n-k)$$

- Le but poursuivi est de trouver les coefficients w_k du modèle MA à partir de la mesure des signaux d'entrée $x(n)$ et de sortie $y(n)$.


Filtrage de Wiener



■ Problématique

- La recherche d'une solution consiste à rendre $y_w(n)$ aussi proche que possible du signal $y_p(n)$...
- ... en minimisant **l'erreur quadratique moyenne** par ajustement des coefficients w_k .
- On revient donc à un problème proche de la régression linéaire.


Filtrage de Wiener



■ Remarque importante

Si la solution exacte est trouvée, le signal d'écart $\varepsilon(n)$ n'est pas nul, **mais égal au bruit de la mesure $e(n)$.**

Filtrage de Wiener




■ Résolution

- *Pour simplifier les calculs, on considèrera un processus MA d'ordre 3*
- *On notera **W** le vecteur associé aux 3 paramètres recherchés*

$$W = \begin{pmatrix} w_0 \\ w_1 \\ w_2 \end{pmatrix}$$

Filtrage de Wiener



■ Résolution


- *Le signal estimé $y_w(n)$ peut alors s'écrire*

$$y_w(n) = w_0 x(n) + w_1 x(n-1) + w_2 x(n-2)$$

- *On cherche à minimiser la fonctionnelle suivante*

$$J = \frac{1}{N} \sum_{n=0}^{N-1} (y(n) - y_w(n))^2$$

Filtrage de Wiener



■ Exercice 😊

- **Montrer que la solution de ce problème d'optimisation est en se limitant à 3 coefficients :**


$$W = R_{XX}^{-1} r_{xy}$$

Avec R_{XX} la matrice d'autocorrélation associée à la variable x et

$$r_{xy}(k) = \frac{1}{N} \sum_{n=0}^{N-1} x(n) y(n+k) = \frac{1}{N} \sum_{n=0}^{N-1} x(n-k) y(n) = r_{yx}(-k)$$

la corrélation associée aux variables x et y

Filtrage de Wiener




■ Résolution

- De la même manière que pour la régression linéaire, J est minimale lorsque les 3 dérivées par rapport aux w_i s'annulent
- Soit

$$\begin{aligned}\frac{\partial J}{\partial w_0} &= \frac{2}{N} \sum_{n=0}^{N-1} (y(n) - w_0 x(n) - w_1 x(n-1) - w_2 x(n-2)) (-x(n)) \\ &= -\frac{2}{N} \sum_{n=0}^{N-1} (x(n)y(n) - w_0 x(n)x(n) - w_1 x(n)x(n-1) - w_2 x(n)x(n-2))\end{aligned}$$

Filtrage de Wiener




■ Résolution

- 3 équations :

$$\begin{aligned}\frac{\partial J}{\partial w_0} &= \frac{2}{N} \sum_{n=0}^{N-1} (y(n) - w_0 x(n) - w_1 x(n-1) - w_2 x(n-2)) (-x(n)) \\ &= -\frac{2}{N} \sum_{n=0}^{N-1} (x(n)y(n) - w_0 x(n)x(n) - w_1 x(n)x(n-1) - w_2 x(n)x(n-2))\end{aligned}$$

$$\begin{aligned}\frac{\partial J}{\partial w_1} &= \frac{2}{N} \sum_{n=0}^{N-1} (y(n) - w_0 x(n) - w_1 x(n-1) - w_2 x(n-2)) (-x(n-1)) \\ &= -\frac{2}{N} \sum_{n=0}^{N-1} (x(n-1)y(n) - w_0 x(n-1)x(n) - w_1 x(n-1)x(n-1) - w_2 x(n-1)x(n-2))\end{aligned}$$

Filtrage de Wiener




■ Résolution

■ et

$$\begin{aligned}\frac{\partial J}{\partial w_2} &= \frac{2}{N} \sum_{n=0}^{N-1} (y(n) - w_0 x(n) - w_1 x(n-1) - w_2 x(n-2)) (-x(n-2)) \\ &= -\frac{2}{N} \sum_{n=0}^{N-1} (x(n-2)y(n) - w_0 x(n-2)x(n) - w_1 x(n-2)x(n-1) - w_2 x(n-2)x(n-2))\end{aligned}$$

Filtrage de Wiener



■ Résolution


- En utilisant l'intercorrélation, il vient que

$$\frac{\partial J}{\partial w_0} = -2 (r_{xy}(0) - w_0 r_{xx}(0) - w_1 r_{xx}(-1) - w_2 r_{xx}(-2))$$

$$\frac{\partial J}{\partial w_1} = -2 (r_{xy}(+1) - w_0 r_{xx}(+1) - w_1 r_{xx}(0) - w_2 r_{xx}(-1))$$

$$\frac{\partial J}{\partial w_2} = -2 (r_{xy}(+2) - w_0 r_{xx}(+2) - w_1 r_{xx}(+1) - w_2 r_{xx}(0))$$

Filtrage de Wiener



■ Résolution


- On obtient donc un système de 3 équations à 3 inconnues

$$w_0 r_{xx}(0) + w_1 r_{xx}(-1) + w_2 r_{xx}(-2) = r_{xy}(0)$$

$$w_0 r_{xx}(+1) + w_1 r_{xx}(0) + w_2 r_{xx}(-1) = r_{xy}(+1)$$

$$w_0 r_{xx}(+2) + w_1 r_{xx}(+1) + w_2 r_{xx}(0) = r_{xy}(+2)$$

Filtrage de Wiener



■ Résolution

- Soit sous forme matricelle

$$\begin{pmatrix} r_{xx}(0) & r_{xx}(-1) & r_{xx}(-2) \\ r_{xx}(+1) & r_{xx}(0) & r_{xx}(-1) \\ r_{xx}(+2) & r_{xx}(+1) & r_{xx}(0) \end{pmatrix} \begin{pmatrix} w_0 \\ w_1 \\ w_2 \end{pmatrix} = \begin{pmatrix} r_{xy}(0) \\ r_{xy}(1) \\ r_{xy}(2) \end{pmatrix}$$




Matrice d'autocorrélation

Et donc

$$R_{XX} W = r_{xy}$$

Filtrage de Wiener




■ Résolution

- Et finalement (CQFD)

$$W = R_{XX}^{-1} r_{xy}$$

Il s'agit de l'équation de Wiener-Hopf

Filtrage de Wiener



■ Généralisation


- Ce résultat se généralise à tout ordre p associé au vecteur W

$$W = \begin{pmatrix} w_0 \\ w_1 \\ \vdots \\ w_{p-1} \end{pmatrix}$$

auquel on associe le vecteur $X(n)$ tel que

$$X(n) = \begin{pmatrix} x(n) \\ x(n-1) \\ \vdots \\ x(n-p+1) \end{pmatrix}$$

Filtrage de Wiener



■ Généralisation


- On obtient alors

$$y_w(n) = \sum_{i=0}^{p-1} w_i \cdot x(n-i) = W^T X(n) = X(n)^T W$$

- L'erreur quadratique est donnée par

$$\varepsilon(n)^2 = \left(y(n) - X(n)^T W \right)^2$$

Filtrage de Wiener



■ Généralisation


- On minimise alors l'espérance de l'erreur quadratique moyenne

$$J(W) = E[\varepsilon(n)^2] = E\left[\left(y(n) - X(n)^T W\right)^2\right]$$

- Ce que l'on peut encore écrire

$$J(W) = E\left[y(n)^2\right] - 2E\left[y(n)X(n)^T W\right] + E\left[W^T X(n)X(n)^T W\right]$$

Filtrage de Wiener



■ Généralisation


- Ce que l'on peut écrire

$$J(W) = E[y(n)^2] - 2E[y(n)X(n)^T W] + E[W^T X(n)X(n)^T W]$$

- Ou encore

$$J(W) = r_{yy}(0) - 2r_{xy}^T W + W^T R_{XX} W$$

Filtrage de Wiener



■ Généralisation

$$J(W) = r_{yy}(0) - 2r_{xy}^T W + W^T R_{XX} W$$


- On minimise donc J dans la direction W , ce qui revient à annuler le gradient de J dans cette direction.
- On résout donc

$$\frac{\partial J(W)}{\partial W} = -2r_{xy} + 2R_{XX} W = 0$$

- Soit

$$W = R_{XX}^{-1} r_{xy}$$


Filtrage de Wiener



■ Quelques applications

- Identification de processus (on cherche les w qui modélisent au mieux le processus inconnu)
- La prédiction linéaire (on estime une valeur à venir en prenant en compte les valeurs précédentes)
- **La suppression d'un signal perturbateur**


Filtrage de Wiener




■ Exemple



- Extraction de l'ECG d'un foetus superposé à celui de la maman (mesure au moyen d'une sonde Doppler)
- Dans ce contexte, le signal d'entrée est l'ECG de la maman (facilement mesurable au moyen d'un système d'acquisition classique)
- Le signal recherché est donc paradoxalement l'erreur $e(n)$

Filtrage de Wiener




■ Illustration et notations






ECG
maman




Signaux
superposés
(Doppler)



*Estimation
de l'ECG
du bébé*


Filtrage de Wiener



■ Limites


- Le calcul de la matrice d'autocorrélation et de la corrélation est gourmand en calcul
- L'inversion de la matrice d'autocorrélation est également gourmande
- Si l'hypothèse de stationnarité n'est pas respectée (ce qui est assez souvent le cas), la matrice d'autocorrélation et la corrélation évoluent dans le temps ; il faut donc à chaque itération les recalculer
- **Solution** : le filtrage adaptatif

Plan



- Introduction
- Rappels sur l'estimation statistique
- Régression linéaire
- Filtrage de Wiener
- Filtrage adaptatif


Filtrage adaptatif



■ Définition

- Un filtre adaptatif est un système numérique dont les coefficients se modifient eux mêmes en fonction des signaux extérieurs.
- Il est utilisé chaque fois qu'un environnement est mal connu ou changeant ou pour supprimer des perturbations situées dans le domaine de fréquences du signal utile...
- **...ce que les filtres classiques ne peuvent pas faire.**


Filtrage adaptatif




■ Principe

- Un filtre adaptatif est constitué de deux parties distinctes :
 - un filtre numérique à coefficients ajustables ;
 - un algorithme de modification des coefficients basé sur un critère d'optimisation.
 - **Exemples** : Algorithme récursif des moindres carrés, Algorithme récursif normalisé

Filtrage adaptatif




- **Algorithme récursif des moindres carrés (RLMS)**
 - **Principe** : Nous avons vu précédemment que le filtrage de Wiener peut se voir comme un problème d'optimisation avec une fonction « coût » de type parabololoïde



Avec J l'erreur quadratique moyenne associée au problème

Filtrage adaptatif



- **Algorithme récursif des moindres carrés (RLMS)**


- Le minimum s'obtient en descendant le long de la pente de la paraboloïde jusqu'à annulation de la dérivée de la fonction de coût dans la direction W (*les coefficients optimaux du filtre*)

$$\frac{\partial J(W)}{\partial W} = -2r_{xy} + 2R_{XX}W$$

Et lorsque la dérivée s'annule


$$W = R_{XX}^{-1} r_{xy}$$

Filtrage adaptatif




- **Algorithme récursif des moindres carrés (RLMS)**
 - De manière heuristique, on imagine bien que cette solution peut être atteinte récursivement...
 - ...en corrigeant les valeurs des coefficients w_k en chaque instant n dans le sens opposé à l'évolution de l'erreur quadratique par rapport au vecteur des coefficients \mathbf{W}

Filtrage adaptatif



- **Algorithme récursif des moindres carrés (RLMS)**

- ***Illustration graphique :***




Soit

$$W(n) = W(n-1) - \frac{\gamma}{2} \left(\frac{\partial \varepsilon^2(n)}{\partial W} \right)$$

On parle de descente de gradient

Rq : γ est la facteur de pondération du gradient

Filtrage adaptatif




- **Algorithme récursif des moindres carrés (RLMS)**

- **Exercice :**

- *Montrer que l'expression de la fonction de mise à jour des coefficients w peut s'écrire*

$$W(n) = W(n-1) + \gamma \varepsilon(n) X(n)$$

Filtrage adaptatif



- **Algorithme récursif des moindres carrés (RLMS)**


- ***Exercice (Solution):***

$$\varepsilon^2(n) = \left(y(n) - \sum_{i=0}^{p-1} w_i x(n-i) \right)^2 = (y(n) - X(n)^T W)^2$$

Et donc

$$\frac{\partial \varepsilon^2(n)}{\partial W} = 2\varepsilon(n) \frac{\partial \varepsilon(n)}{\partial W} = -2\varepsilon(n) X(n)$$

Filtrage adaptatif




- **Algorithme récursif des moindres carrés (RLMS)**
 - ***Exercice (Solution):***

Finalemment, en remplaçant

$$W(n) = W(n-1) + \gamma \varepsilon(n) X(n)$$

Il s'agit de l'algorithme *Recursive Least Mean Square (RLMS)*


Filtrage adaptatif



- **Algorithme récursif des moindres carrés (RLMS)**
 - ***Ce dont on a besoin***
 - *Le vecteur des p coefficients du filtre à l'instant $n-1$*

$$W(n-1) = \left[w_0(n-1), w_1(n-1), \dots, w_{p-1}(n-1) \right]^T$$


Filtrage adaptatif



- **Algorithme récursif des moindres carrés (RLMS)**
 - ***Ce dont on a besoin***
 - *Les p dernières valeurs du signal d'entrée*


$$X(n) = [x(n), x(n-1), \dots, x(n-p+1)]^T$$

Filtrage adaptatif




- **Algorithme récursif des moindres carrés (RLMS)**
 - ***Ce dont on a besoin***
 - *La valeur du signal de sortie à l'instant n , $y(n)$*
 - *Le gain d'adaptation γ de l'algorithme récursif ($\ll 1$)*

Filtrage adaptatif



- **Algorithme récursif des moindres carrés (RLMS)**
 - **Remarque sur le gain**
 - *Son choix est empirique et pas toujours évident*
 - *Trop petit, la vitesse de convergence est très lente*
 - *Trop grand, l'algorithme peut osciller longtemps autour de la valeur optimale...*
 - *... et même entraîner une divergence de l'algorithme*


Filtrage adaptatif



- **Algorithme récursif des moindres carrés (RLMS)**
 - ***Avantages/Inconvénients***
 - + *Rapide à mettre en œuvre*
 - + *Peu de calcul*
 - - *Lente convergence*
 - - *Instabilité (oscillation, divergence) si le gain est trop grand*

Nécessité de proposer une solution d'adaptation automatique du gain

Filtrage adaptatif




- **Algorithme récursif normalisé (NLMS)**

- ***Principe***

- **1975** : *Widrow et al* montre qu'on peut adapter le gain de manière stable entre 0 et 1 en le normalisant :

- *Par le nombre p de paramètres du vecteur W*
- **Et** *par la puissance ou par la variance du signal d'entrée*

Filtrage adaptatif




- **Algorithme récursif normalisé (NLMS)**
 - **Cas d'un signal stationnaire**
 - *En prenant stricto sensu la normalisation proposée par Widrow et al :*

$$\gamma = \frac{\gamma_0}{p \cdot \sigma_x^2}$$

La valeur initiale est généralement choisie à 0.1, et la valeur s'adapte à la puissance du signal (via la variance)

Filtrage adaptatif




- **Algorithme récursif normalisé (NLMS)**

- ***Cas d'un signal stationnaire***

- *Cette solution directe présente l'inconvénient d'avoir un gain qui peut augmenter de manière non maîtrisé*

$$\lim_{\sigma_x \rightarrow 0} \gamma = \lim_{\sigma_x \rightarrow 0} \frac{\gamma_0}{p \cdot \sigma_x^2} = +\infty$$

Filtrage adaptatif




- **Algorithme récursif normalisé (NLMS)**
 - **Cas d'un signal stationnaire**
 - *On ajoutera alors un terme constant au dénominateur telle que*

$$\gamma = \frac{\gamma_0}{a + p \cdot \sigma_x^2}$$

$$a \ll 1$$

Filtrage adaptatif




- **Algorithme récursif normalisé (NLMS)**
 - **Cas d'un signal stationnaire**
 - *L'algorithme s'écrit alors*

$$W(n) = W(n-1) + \frac{\gamma_0}{a + p \cdot \sigma_x^2} \varepsilon(n) X(n)$$

Normalisation, d'où le nom
NLMS (Normalized LMS)

Filtrage adaptatif




- **Algorithme récursif normalisé (NLMS)**

- ***Cas d'un signal non stationnaire***

- *Dans ce cas, il n'est plus possible d'estimer la puissance du signal sans prendre en compte le temps*
- *Il faut donc l'estimer en tout instant*

$$P_x(n) = \frac{1}{n+1} \sum_{k=0}^n x^2(k)$$


Filtrage adaptatif



- **Algorithme récursif normalisé (NLMS)**
 - **Cas d'un signal non stationnaire**
 - *En pratique on utilisera un filtre passe bas d'ordre 1 à mémoire « courte »*
 - *Exemple de fonction de transfert*

$$H(z) = \frac{1 - \lambda}{1 - \lambda \cdot z^{-1}} \quad 0 < \lambda < 1$$

Filtrage adaptatif



- **Algorithme récursif normalisé (NLMS)**


- ***Cas d'un signal non stationnaire***

- *En pratique on utilisera un filtre passe bas d'ordre 1 à mémoire « courte »*

- *Equation de récurrence associée*

$$s(n) = (1 - \lambda)e(n) + \lambda s(n - 1) \quad 0 < \lambda < 1$$

Filtrage adaptatif




- **Algorithme récursif normalisé (NLMS)**

- ***Cas d'un signal non stationnaire***

- *En pratique on utilisera un filtre passe bas d'ordre 1 à mémoire « courte »*
- *Calcul de la puissance de manière récursive*

$$P_x(n) = (1 - \lambda)x^2(n) + \lambda P_x(n-1) \quad 0 < \lambda < 1$$

Filtrage adaptatif




- **Algorithme récursif normalisé (NLMS)**
 - ***Cas d'un signal non stationnaire***
 - *En pratique on utilisera un filtre passe bas d'ordre 1 à mémoire « courte »*
 - *Le paramètre λ fixe l'horizon de mémoire N souhaité*

$$N = \frac{3}{|\ln \lambda|}$$


Exemple : $N=30$ pour $\lambda=0,9$; $N=150$ pour $\lambda=0,98$

Filtrage adaptatif




■ Résultats

■ *ECG maman/foetus : données*




Filtrage adaptatif




■ Résultats

■ *ECG* maman/foetus :


Wiener



RLMS,
 $\gamma=0.1$




Filtrage adaptatif




■ Résultats

■ *ECG* maman/fœtus :


Wiener



NLMS,
 $\gamma_0=0.05$,
 $\lambda=0,95$




Filtrage adaptatif




■ Résultats

■ *ECG maman/foetus : comparaison RLMS, NLMS*


RLMS,
 $\gamma=0.1$



NLMS,
 $\gamma_0=0.05$
 $\lambda=0,95$




Filtrage adaptatif




■ Résultats

■ *ECG maman/foetus : comparaison RLMS, NLMS*



**Evolution du gain pour l'algo
NLMS, $\gamma_0=0.05$, $\lambda=0,95$**

Filtrage adaptatif




■ Résultats

■ *ECG maman/foetus : comparaison RLMS, NLMS*


- *L'algo NLMS est plus rapide en termes de convergence*
- *et plus stable également*
- *Le résultat obtenu est très proche de celui obtenu au moyen du filtre optimal de Wiener*

Plan




- Introduction
- Rappels sur l'estimation statistique
- Régression linéaire
- Filtrage de Wiener
- Filtrage adaptatif
- Exercice

Exercices




- **Contexte : Restauration d'images bruitées**
 - On considère ici la problématique de restauration d'images astronomiques acquises par un télescope type Hubble

Image bruitée



Galaxie spirale M100

Exercices




■ Problématique

- L'image reçue par le CCD est une collection de pixels que l'on rassemble sous la forme d'une matrice \mathbf{y}
- Cette matrice résulte de l'image initiale, \mathbf{x} , qui a été convoluée par la réponse impulsionnelle, \mathbf{h} , du télescope auquel s'ajoute un vecteur bruit noté \mathbf{n} (*blanc*)

$$y(i, j) = h(i, j) * x(i, j) + n(i, j)$$

Exercices




■ Espace des fréquences

- **Question 1** : Que devient cette relation dans l'espace de Fourier ?

$$Y(k, l) = H(k, l)X + N(k, l)$$

Rq : Dans cet espace, la matrice H est diagonale de valeur propre λ_k

Exercices



■ Espace des fréquences


- Le spectre de puissance de l'image suit souvent une loi de puissance,

$$\langle X^2 \rangle = C_0 k^{-\alpha}$$

- Le bruit est souvent un bruit blanc c'est à dire qu'il a la même intensité quel que soit la fréquence spatiale,

$$\langle N^2 \rangle = C$$


Exercices



- **Espace des fréquences**

- **Question 2 :** Montrer que l'inversion simple de la relation précédente (qui consiste à appliquer la matrice H^{-1} sur les données Y afin de retrouver X) conduit, au delà d'une certaine fréquence, à une amplification du bruit.

Exercices



■ Espace des fréquences

- **Solution** : En inversant simplement la relation précédente, on obtient

$$H^{-1}Y = H^{-1}HX + H^{-1}N = X + \frac{N}{\lambda_k}$$




- Comme le spectre de puissance de l'image décroît quand \mathbf{k} augmente et que celui du bruit reste constant, il existe une fréquence limite telle que

$$\frac{N}{\lambda_k} \gg X$$


Et donc le bruit est amplifié

Exercices

- **Espace des fréquences**
 - *Restauration par simple inversion*



Exercices




■ Filtre optimal

- On cherche donc maintenant à déconvoluer l'image mais aussi à filtrer le bruit.
- Pour cela, on va chercher le filtre R à appliquer sur les données Y qui va minimiser l'écart quadratique moyen entre la vraie image X et l'image filtrée définie par

$$\hat{X} = RY$$

Exercices




■ Filtre optimal

- **Question 3 :** En postulant que le bruit et le signal sont décorrélés et que le bruit est iid, montrer que

$$R = \left(H^T C_N^{-1} H + C_X^{-1} \right)^{-1} H^T C_N^{-1}$$

avec $C_X = \langle X^T X \rangle$ et $C_N = \langle N^T N \rangle$ les matrices de covariances du signal X et du bruit N

Exercices



■ Filtre optimal


■ *Solution :*

$$S = \langle \left(\tilde{X} - X \right)^2 \rangle = \langle \left(\tilde{X} - X \right)^T \left(\tilde{X} - X \right) \rangle = \langle (RY - X)^T (RY - X) \rangle = \langle (R(AX + N) - X)^T (R(AX + N) - X) \rangle$$

$$\frac{dS}{dR} = 0$$

$$R = \langle X^T X \rangle A^T \left(A \langle X^T X \rangle A^T + \langle N^T N \rangle \right)^{-1} = C_X A^T \left(A C_X A^T + C_N \right)^{-1} = \left(A^T C_N^{-1} A + C_X^{-1} \right)^{-1} A^T C_N^{-1}$$


Exercices



- **Filtre optimal**

- **Question 4 :** Dans l'espace de Fourier, les matrices de variance-covariance sont diagonales également et se réduisent aux spectres de puissances. Montrer que le filtre de Wiener \mathbf{R} inverse les basses fréquences et coupe les plus grandes où le bruit domine.

Exercices



■ Filtre optimal

■ *Solution*

$$R_k = \left(\frac{\lambda_k^2}{C} + \frac{1}{C_0 k^{-\alpha}} \right)^{-1} \frac{\lambda_k}{C} = \frac{\lambda_k}{\lambda_k^2 + \frac{C}{C_0 k^{-\alpha}}}$$

Pour k petit donc $C_0 k^{-\alpha} \gg C$ et $R_k \rightarrow \lambda_k^{-1}$

Et pour k grand donc $C_0 k^{-\alpha} \ll C$ et $R_k \rightarrow 0$

Les très hautes fréquences dominées par le bruit sont coupées, l'image est donc filtrée.

Exercices

- **Filtre optimal**

