

# Etude asymptotique d'algorithmes de poursuite

BERNARD DELYON and ANATOLI JUDITSKY  
IRISA, Campus de Beaulieu, 35042 Rennes France

## RÉSUMÉ

Cet article discute du problème de la poursuite de paramètres de régression animés d'un mouvement aléatoire. Nous étudions les propriétés asymptotiques de certains algorithmes en présence de petit bruit. Toute l'étude est basée sur un théorème-limite central pour un type assez général d'équation aux différences.

## 1 Introduction

Nous considérons ici les algorithmes de la forme

$$y_t = \theta_t^T \varphi_t + e_t.$$

où  $e_t$  est un bruit aléatoire,  $\varphi_t \in \mathbf{R}^N$ ,  $y_t \in \mathbf{R}$  sont les entrées et sorties observées et  $\theta_t$  est un vecteur de paramètres inconnu, variable dans le temps. On suppose que  $\theta_t$  est aléatoire et varie lentement, i.e.

$$\theta_t = \theta_{t-1} + \gamma w_t \quad (1)$$

où  $\gamma$  est un petit paramètre.

L'identification du système conduit généralement à un algorithme de la forme suivante (cf [6]):

$$\hat{\theta}_t = \hat{\theta}_{t-1} + \mu L_t (y_t - \varphi_t^T \hat{\theta}_{t-1}), \quad \hat{\theta}_t \in \mathbf{R}^N, \quad (2)$$

Chaque méthode se caractérise par la manière dont le gain vectoriel  $L_t$  est réestimé.  $\mu$  est un réel positif. L'article se consacre à l'étude asymptotique (quand  $\mu \rightarrow 0$  et  $\gamma \rightarrow 0$ ) de la distribution stationnaire de l'erreur d'estimation  $\hat{\theta}_t - \theta_t$ . Plus précisément, notre objectif est de montrer que pour diverses méthodes, que la distribution de l'erreur converge vers une loi normale de variance calculable.

Soit  $\Gamma = \Gamma^T > 0$ . On considérera les méthodes de réestimation suivantes:

- Moindres carrés de Widrow (LMS):

$$L_t = \Gamma \varphi_t \quad \text{ou} \quad L_t = \Gamma \varphi_t / (1 + \mu \varphi_t^T \Gamma \varphi_t)$$

- Moindres carrés normalisés (LMS):

$$L_t = \Gamma \varphi_t / (1 + |\varphi_t|^2)$$

- Moindres carrés récursifs avec facteur d'oubli (RLS):

$$\begin{aligned} R_t &= (1 - \mu)R_{t-1} + \mu \varphi_t \varphi_t^T, \quad R_0 = \varrho I, \quad \varrho > 0 \\ L_t &= R_t^{-1} \varphi_t \end{aligned}$$

- Moindres carrés stabilisés ( $0 < \rho < 1$ )

$$\begin{aligned} L_t &= \Gamma_t \varphi_t \\ \Gamma_t &= (\mu \rho^{-1} R_t + \Gamma^{-1})^{-1} \\ R_t &= (1 - \rho)R_{t-1} + \rho \varphi_t \varphi_t^T, \quad R_0 = 0 \end{aligned}$$

## ABSTRACT

The paper addresses the problem of tracking random drifting parameters of linear regression system. We study the asymptotic properties of several estimation algorithms in the limit of slow drift. The basic tool is the central limit theorem for a class of stochastic difference equations established under weak conditions on disturbances and observations. The estimates of the rate of convergence obtained in the paper allow us to develop the asymptotically optimal algorithms.

**Remarques:** Ces algorithmes sont bien connus (cf. [6]) à l'exception des moindres carrés stabilisés. Ce dernier a été conçu comme une version régularisée de MS et RLS à la fois (cf [4]).

Le point théorique principal de l'article est le théorème-limite central pour les équations aux différences développé en section 2. Il donne une approximation en *horizon infini* pour la distribution asymptotique de l'erreur  $\hat{\theta}_t - \theta_t$  de l'équation (2). Nous donnons ensuite un guide pour l'application de ce résultat aux algorithmes d'estimation. En section 3 nous considérons les algorithmes décrits ci-dessus et on donne des conditions d'obtention du théorème-limite central ainsi que les expressions de la covariance asymptotique de l'erreur.

## 2 Resultat fondamental

### 2.1 Théorème-limite central

On se donne un espace de probabilité  $\{\Omega, \mathcal{F}, P\}$ . Considérons le processus  $(\Delta_t)$ ,  $\Delta_t \in \mathbf{R}^N$  satisfaisant l'équation:

$$\Delta_t = (I - \mu P_t) \Delta_{t-1} + \mu \zeta_t \quad \Delta_0 \in \mathbf{R}^N \quad (3)$$

où  $\mu \leq \mu_0$  est un réel positif,  $(P_t)$  et  $(\zeta_t)$  sont des processus aléatoires, à valeurs dans  $\mathbf{R}^{N \times N}$  et  $\mathbf{R}^N$  respectivement. Nous allons énoncer (sans preuve, faute de place) le théorème-limite pour la solution  $\Delta_t$  de (3). On autorise les processus  $P_t$  et  $\zeta_t$  à dépendre de  $\mu$ , mais on suppose qu'on peut les décomposer de la façon suivante:

$$P_t = P_t^0 + P_t' \quad (4)$$

$$\zeta_t = \zeta_t^0 + \zeta_t' \quad (5)$$

$P_t^0$  and  $\zeta_t^0$  ne dépendent pas de  $\mu$  et  $P_t'$  et  $\zeta_t'$  satisfont des hypothèses particulières. Supposons qu'existe un processus strictement stationnaire  $(P_t^0, \zeta_t^0, X_t)$  and  $\mathcal{F}_t = \sigma\{\dots, P_t^0, \zeta_t^0, X_t\}$ , tels que  $P_t^0, \zeta_t^0 \in \mathcal{F}_t$ . Les hypothèses sont:

[A1]  $P_t^0 = (P_t^0)^T \geq 0, EP_1^0 > 0, E|P_1^0|^2 < \infty.$

[A2]  $(P_t^0)$  and  $(\zeta_t^0)$  sont des processus strictement stationnaires ergodiques.

[A3]  $\sum_{s=0}^{\infty} (E|E(\zeta_s^0 | \mathcal{F}_0)|^2)^{1/2} < \infty$



$$[\mathbf{A4}] \quad \lim_{\mu \rightarrow 0} \mu^{-1/2} \sup_t E(|\zeta'_t|) = 0$$

[\mathbf{A5}] Il existe un processus stationnaire ergodique  $p'_t$  satisfaisant :

$$\begin{aligned} |P'_t| &\leq p'_t, \quad \lim_{\mu_0 \rightarrow 0} E(\sup_{\mu \leq \mu_0} [p'_t]^2) = 0 \\ \sup_t E([p'_t]^2) &< \infty \end{aligned}$$

**Théorème 1** Sous les hypothèses A1-A5, le système (3) avec toute condition initiale déterministe  $\Delta_0$  satisfait

$$\lim_{\mu \rightarrow 0} \lim_{t \rightarrow \infty} \mu^{-1/2} \Delta_t = \mathcal{N}(0, V) \quad \text{en loi} \quad (6)$$

i.e.  $\mu^{-1/2} \Delta_t$  converge en loi vers la variable Gaussienne de moyenne nulle et de covariance  $V$ , où  $V$  est la solution de l'équation de Liapounov

$$BV + VB = S_0 \quad (7)$$

$$\text{avec } B = EP_1^0 \text{ et } S_0 = E\zeta_0^0 \zeta_0^{0T} + \sum_{i=1}^{\infty} E\zeta_0^0 \zeta_i^{0T} + E\zeta_i^0 \zeta_0^{0T}$$

Notons que les hypothèses A2, A3 garantissent l'existence de  $S_0 < \infty$ .

Le sens précis de la limite ci-dessus est

$$\lim_{\mu \rightarrow 0} \limsup_{t \rightarrow \infty} |E[f(\mu^{-1/2} \Delta_t)] - E[f(\mathcal{N}(0, V))]| = 0$$

pour toute fonction  $f$  continue bornée.

**Remarques:** Ce résultat sera appliqué à  $\Delta_t = \hat{\theta}_t - \theta_t$ . Notons que les hypothèses du théorème donnent une approximation en horizon infini. Ceci constitue une différence majeure avec les résultats habituels d'approximation, où l'on prouve la convergence faible sur un interval fini d'ordre  $\gamma^{-1}$ . Comparons le théorème 1 avec des résultats analogues comme le théorème 4.15, partie 2 de [1] ou le résultat correspondant de [5]. En fait ces résultats demandent implicitement que les trajectoires ( $\hat{\theta}_t$ ) de l'équation (3) soient bornées. Par ailleurs, la condition sur la dépendance de la suite ( $P_t$ ) dans le théorème 1 est plus explicite et moins restrictive que celle, par exemple, du théorème 4.15 de [1] puisque l'ergodicité seule est réclamée.

Comparé avec les résultats obtenus dans [3], [13], [8]-[10] cet article ne considère pas les moments de  $\hat{\theta}_t - \theta_t$  (qui peuvent très bien être infinis) mais s'intéresse à la limite en loi de ces processus. L'avantage notable de cette approche est la faiblesse des hypothèses imposées dans le théorème. Remarquons que les conclusions du théorème n'impliquent pas la convergence en loi de  $\mu^{-1/2} \Delta_t$  pour  $\mu$  fixé; il est simplement dit que la distance entre la distribution de  $\mu^{-1/2} \Delta_t$  et la Gaussienne tend vers zéro.

## 2.2 Utilisation du théorème 1

L'équation (2) conduit à la récursion suivante pour l'erreur d'estimation  $\delta_t = \theta_t - \hat{\theta}_t$

$$\delta_t = (I - \mu L_t \varphi_t^T) \delta_{t-1} + \mu L_t e_t - \gamma w_t \quad (8)$$

et si l'on pose

$$\begin{aligned} \delta_t^{(1)} &= (I - \mu L_t \varphi_t^T) \delta_{t-1}^{(1)} + \sqrt{\mu} L_t e_t, \quad \delta_0^{(1)} = \delta_0 \\ \delta_t^{(2)} &= (I - \mu L_t \varphi_t^T) \delta_{t-1}^{(2)} - \sqrt{\mu} w_t, \quad \delta_0^{(2)} = 0 \\ \Delta_t^T &= \sqrt{\mu} (\delta_t^{(1)}, \delta_t^{(2)})^T \end{aligned}$$

alors

$$\delta_t = \sqrt{\mu} \delta_t^{(1)} + \frac{\gamma}{\sqrt{\mu}} \delta_t^{(2)} \quad (9)$$

et l'équation (3) equivaut à (8) avec

$$P_t = \begin{pmatrix} L_t \varphi_t^T & 0 \\ 0 & L_t \varphi_t^T \end{pmatrix}, \quad \zeta_t = \begin{pmatrix} L_t e_t \\ w_t \end{pmatrix} \quad (10)$$

Donc, quand  $\mu$  tend vers zéro,  $\delta$  est donné par l'équation (9) où le vecteur  $(\delta^{(1)}, \delta^{(2)})$  is approximé (indépendamment de  $\gamma$ ) par un vecteur Gaussien de matrice de covariance d'ordre 1. Notons que le choix optimal du gain est  $\mu \simeq \gamma$ . Les cas  $\mu = o(\gamma)$  ou  $\gamma = o(\mu)$  ne sont pas dénués d'intérêt car, en pratique, le paramètre  $\gamma$  est assez difficile à estimer. Introduisons la notation suivante

**Definition 1:** Soit

$$\delta_t = \sqrt{\mu} \delta_t^{(1)} + \frac{\gamma}{\sqrt{\mu}} \delta_t^{(2)}$$

où  $\delta_t^{(1)}$  et  $\delta_t^{(2)}$  sont deux processus aléatoires dépendant du paramètre  $\mu$  seulement. Si  $(\delta_t^{(1)}, \delta_t^{(2)})$  converge en loi vers la variable Gaussienne  $N(0, V)$ , avec

$$V = \begin{pmatrix} V_1 & 0 \\ 0 & V_2 \end{pmatrix}$$

alors, on notera  $\delta_t \simeq N(0, \mu V_1 + \frac{\gamma^2}{\mu} V_2)$ .

## 3 Etude des algorithmes

Afin de simplifier la présentation on supposera que  $e_t$  et  $w_t$  sont des accroissements de martingale.

On note  $\mathcal{F}_t = \sigma\{\dots, \varphi_{t+1}, e_t, w_t\}$  et  $\mathcal{G}'$  la tribu invariante de la filtration  $(\varphi_t, e_t, w_t)$ . On considérera les hypothèses:

[B1]  $(\varphi_t, e_t, w_t)$  est une suite strictement stationnaire ergodique;  $E(e_t | \mathcal{F}'_{t-1}) = 0$ ,  $E(w_t | \mathcal{F}'_{t-1}) = 0$ ,  $Ee_t^4 < \infty$ ,  $E(e^2 | \mathcal{F}'_{t-1}) = \sigma_e^2$ ,  $E(w_t w_t^T | \mathcal{F}'_{t-1}) = R_w$ , et  $E(w_t e_t | \mathcal{F}'_{t-1}) = 0$ .

[B2]  $E|\varphi_t|^4 < \infty$  et  $E\varphi_t \varphi_t^T > 0$ .

[B3]  $\Gamma = \Gamma^T > 0$ .

### 3.1 Algorithme de Widrow (LMS)

On considère l'algorithme [14]

$$\hat{\theta}_t = \hat{\theta}_{t-1} + \mu \Gamma \varphi_t (y_t - \varphi_t^T \hat{\theta}_{t-1}) \quad (11)$$

ainsi qu'une version modifiée

$$\hat{\theta}_t = \hat{\theta}_{t-1} + \mu \Gamma \frac{\varphi_t}{1 + \mu \varphi_t^T \Gamma \varphi_t} (y_t - \varphi_t^T \hat{\theta}_{t-1}) \quad (12)$$

Posons  $D = E\varphi_1 \varphi_1^T$  et définissons les matrices  $V_i$  à l'aide des équations de Liapounov

$$\Gamma D V_1 + V_1 D \Gamma = \sigma_e^2 \Gamma D \Gamma \quad (13)$$

$$\Gamma D V_2 + V_2 D \Gamma = R_w \quad (14)$$

**théorème 2** *Sous les hypothèses B1-B3, l'algorithme (11) (12) (pour ce dernier on exige aussi  $E|\varphi_t|^8 < \infty$ ) satisfait*

$$\hat{\theta}_t - \theta_t \asymp \mathcal{N}(0, \mu V_1 + V_2 \gamma^2 / \mu)$$

**démonstration:** Posons

$$\delta_t = \Gamma^{-1/2}(\hat{\theta}_t - \theta_t), \quad \bar{\varphi}_t = \Gamma^{1/2} \varphi_t, \quad \bar{w}_t = \Gamma^{-1/2} w_t$$

$$\begin{aligned} \bar{P}_t^0 &= \bar{\varphi}_t \bar{\varphi}_t^T & \zeta_t^0 &= \begin{pmatrix} \bar{\varphi}_t e_t \\ \bar{w}_t \end{pmatrix} \\ \bar{P}_t^1 &= \frac{\bar{\varphi}_t \bar{\varphi}_t^T}{1 + \mu |\bar{\varphi}_t|^2} & \zeta_t^1 &= \begin{pmatrix} \frac{\bar{\varphi}_t e_t}{1 + \mu |\bar{\varphi}_t|^2} \\ \bar{w}_t \end{pmatrix} \end{aligned}$$

avec ces notations, il vient

$$\delta_t = \sqrt{\mu} \delta_t^{(1)} + \delta_t^{(2)} \gamma / \sqrt{\mu}$$

$$\Delta_t = \sqrt{\mu} (\delta_t^{(1)}, \delta_t^{(2)}) \text{ satisfait}$$

$$\Delta_t = (I - \mu \bar{P}_t) \Delta_{t-1} + \mu \zeta_t \tag{15}$$

$$\bar{P}_t = \begin{pmatrix} \bar{P}_t^i & 0 \\ 0 & \bar{P}_t^i \end{pmatrix}, \quad \zeta_t = \zeta_t^i.$$

On choisit  $i=0$  ou  $i=1$  pour l'algorithme (11) ou (12) respectivement. Les processus  $P_t^0, \zeta_t^0$  vérifient A1-A5 du théorème et donc le théorème est immédiat pour l'algorithme (11). Notons que  $P_t^1$  se décompose en  $P_t^1 = P_t^0 + P_t'$  où

$$P_t' = -\mu \frac{|\bar{\varphi}_t|^2 \bar{\varphi}_t \bar{\varphi}_t^T}{1 + \mu |\bar{\varphi}_t|^2}$$

On vérifie sans peine que l'hypothèse A5 est vérifiée. De plus,

$$E|\zeta_t^1 - \zeta_t^0| \leq \mu E(|\bar{\varphi}_t|^3) \sigma_e$$

ce qui implique A4. On peut donc appliquer le théorème 1.  $\blacksquare$

Pour terminer l'étude asymptotique de l'algorithme de Wiener, développons sa version optimale. Soit  $\mu = \gamma$ . Alors

$$\gamma^{-1/2}(\hat{\theta}_t - \theta_t) \xrightarrow{D} \mathcal{N}(0, V_3)$$

où  $V_3 = V_1 + V_2$  est la solution de l'équation:

$$\Gamma D V_3 + V_3 D \Gamma = \sigma_e^2 \Gamma D \Gamma + R_w \tag{16}$$

On a alors le corollaire suivant:

**Corollaire 1** *Considérons une matrice de gain  $\Gamma^*$  satisfaisant*

$$\Gamma^* D \Gamma^* = \frac{R_w}{\sigma_e^2}.$$

Alors pour tout choix de  $\Gamma$  satisfaisant B3

$$V(\Gamma) \geq V(\Gamma^*) = \sigma_e^2 \Gamma^*.$$

La démonstration de ce résultat se trouve dans [11]. Notons que  $V(\Gamma^*)$  vaut

$$V(\Gamma^*) = \sigma_e D^{-1/2} (D^{1/2} R_w D^{1/2})^{1/2} D^{-1/2} \tag{17}$$

si les bruits  $e_t$  et  $w_t$  ont une distribution Gaussienne, cette valeur est la plus petite possible qu'un algorithme d'estimation puisse atteindre (cf [11]).

### 3.2 Algorithme LMS normalisé

On considère l'algorithme

$$\hat{\theta}_t = \hat{\theta}_{t-1} + \mu \Gamma \frac{\varphi_t}{1 + |\varphi_t|^2} (y_t - \varphi_t^T \hat{\theta}_{t-1}). \tag{18}$$

Il fut introduit dans la littérature (cf [9]) comme une modification du LMS habituel. La stabilité dans  $L_p$  de cette méthode a été prouvée dans [9] et des estimées de la vitesse de convergence y sont données.

On note  $D = E \varphi_t \varphi_t^T (1 + |\varphi_t|^2)^{-1}$  et  $G = E \varphi_t \varphi_t^T (1 + |\varphi_t|^2)^{-2}$ . Remarquons que si B2 est satisfaite alors  $D > 0$  et  $G > 0$ . Définissons les matrices  $V_i$  par les équations de Liapounov

$$\begin{aligned} \Gamma D V_1 + V_1 D \Gamma &= \sigma_e^2 \Gamma G \Gamma \\ \Gamma D V_2 + V_2 D \Gamma &= R_w \end{aligned}$$

**Théorème 3** *Sous B1-B3, l'algorithme (18) satisfait*

$$\hat{\theta}_t - \theta_t \asymp \mathcal{N}(0, \mu V_1 + V_2 \gamma^2 / \mu)$$

La démonstration est analogue à celle du théorème 2.

### 3.3 Algorithme avec facteur d'oubli

$\hat{\theta}_t$  satisfait ici l'équation

$$\begin{aligned} \hat{\theta}_t &= \hat{\theta}_{t-1} - \mu R_t^{-1} \varphi_t (y_t - \hat{\theta}_{t-1}^T \varphi_t) \\ R_t &= (1 - \mu) R_{t-1} + \mu \varphi_t \varphi_t^T, \quad R_0 = \rho I \end{aligned} \tag{19}$$

avec  $\rho > 0$ . Posons  $D = E \varphi_t \varphi_t^T$ ,  $V_1 = \sigma_e^2 D^{-1} / 2$  et  $V_2 = R_w / 2$

**Théorème 4** *Sous B1 et B2, l'algorithme (19)*

$$\hat{\theta}_t - \theta_t \asymp \mathcal{N}(0, \mu V_1 + V_2 \gamma^2 / \mu)$$

Des conditions suffisantes pour la stabilité dans  $L_p$  ainsi que des estimées de la vitesse de convergence se trouvent dans [3] et [13].

On aura besoin du lemme suivant (admis):

**Lemme 1** *Soit  $(\varphi_t)$  un processus stationnaire ergodique à valeurs dans  $\mathbf{R}^N$ ,  $E \varphi_t \varphi_t^T = D$  and  $E|\varphi_t|^4 < \infty$ . Définissons  $R_t$  par*

$$R_t = (1 - \mu) R_{t-1} + \mu \varphi_t \varphi_t^T, \quad R_0 = \rho I > 0$$

Alors  $\sup_{0 < \mu < 1} \sup_t E |R_t - D|^2 < \infty$ , et  $\lim_{\mu \rightarrow 0} \lim_{t \rightarrow \infty} E |R_t - D|^2 = 0$ .

**Démonstration du théorème 4:** On ne considérera que le cas  $\mu = \gamma$ . Le processus  $x_t = R_t(\hat{\theta}_t - \theta_t)$  satisfait l'équation (cf. [2])

$$x_t = (1 - \gamma) x_{t-1} + \gamma \varphi_t e_t + \gamma R_t w_t.$$

On peut alors faire la décomposition

$$x_t = \bar{x}_t + \bar{\delta}_t$$

où

$$\bar{\delta}_t = (1 - \gamma) \bar{\delta}_{t-1} + \gamma (R_t - D) w_t, \quad \bar{\delta}_0 = 0$$

$$\bar{x}_t = (1 - \gamma) \bar{x}_{t-1} + \gamma \varphi_t e_t + \gamma D w_t, \quad \bar{x}_0 = x_0.$$



On déduit du lemme 1 que les conditions du théorème 1 sont satisfaites par le processus  $(\bar{x}_t)$ ; par conséquent

$$\gamma^{-1/2} \bar{x}_t \xrightarrow{D} \mathcal{N}(0, \bar{V})$$

avec  $\bar{V} = \sigma_e^2 D + DR_w D$ . Puisque  $(R_t - D)w_t$  est un accroissement de martingale, on a

$$E|\bar{\delta}_t|^2 \leq (1 - \gamma)^2 E|\bar{\delta}_{t-1}|^2 + \gamma^2 |R_w| E|R_t - D|^2 = o(\gamma)$$

Donc  $\gamma^{-1/2} \bar{\delta}_t \xrightarrow{P} 0$ . Le lemme 1 permet de conclure que pour tout  $0 < \varepsilon \leq 1/2$  il existe  $\mu(\varepsilon)$  tel que  $P(|R_t - D| > \varepsilon) < \varepsilon$  dès que  $\mu \leq \mu(\varepsilon)$ . Et donc  $P(|R_t^{-1} - D^{-1}| > 2\lambda_{\min}^{-1}(D)\varepsilon) < \varepsilon$ . Ceci entraîne que  $\gamma^{-1/2}(R_t^{-1}x_t - D^{-1}x_t) \xrightarrow{P} 0$  et  $\gamma^{-1/2}(\hat{\theta}_t - \theta_t) \sim D^{-1}x_t$ . ■

Notons que si  $\mu = \gamma$ , la matrice de covariance de l'erreur normalisée  $V = (\sigma_e^2 D^{-1} + R_w)/2$  diffère de la valeur optimale (17). Cette méthode n'est donc pas optimale.

### 3.4 LMS stabilisé

$\hat{\theta}_t$  satisfait l'équation

$$\hat{\theta}_t = \hat{\theta}_{t-1} + \mu \Gamma_t \varphi_t (y_t - \varphi_t^T \hat{\theta}_{t-1}) \quad (20)$$

$$\Gamma_t = (\mu \rho^{-1} R_t + \Gamma^{-1})^{-1}, \quad \Gamma = \Gamma^T > 0 \quad (21)$$

$$R_t = (1 - \rho) R_{t-1} + \rho \varphi_t \varphi_t^T, \quad R_0 = 0. \quad (22)$$

Ici  $0 < \rho < 1$  et  $\mu > 0$  sont les paramètres de l'algorithme. Quand  $\mu \rightarrow 0$  les équations (20) - (22) peuvent être vues comme une version régularisée du LMS (11) avec le gain constant  $\Gamma$  et également, comme une version régularisée de l'algorithme avec facteur d'oubli. L'avantage de cette méthode est la stabilité dans  $L_p$  pour toutes valeurs de  $\mu$  et  $\rho$  sous certaines conditions d'excitation (cf. [4]).

**Théorème 5** Sous B1-B3, l'algorithme (20) - (22) satisfait

$$\hat{\theta}_t - \theta_t \asymp \mathcal{N}(0, \mu V_1 + V_2 \gamma^2 / \mu)$$

où  $V_1$  et  $V_2$  sont définies par (13) et (14).

**Démonstration:** Posons  $P_t^0 = \Gamma$ ; alors  $\Gamma_t = P_t^0 + P_t'$  où

$$P_t' = -\Gamma(\Gamma + \mu^{-1} \rho R_t^{-1})^{-1} \Gamma,$$

et

$$|P_t'| \leq |\Gamma|^2 |(\Gamma + \mu^{-1} \rho R_t^{-1})^{-1}| \leq |\Gamma|^2 \mu \rho^{-1} |R_t|.$$

Introduisons la version stationnaire de la suite  $(R_t)$ :

$$S_0 = \rho \sum_{j=-\infty}^0 (1 - \rho)^{-j} \varphi_j \varphi_j^T$$

$$S_t = (1 - \rho) S_{t-1} + \rho \varphi_t \varphi_t^T$$

Remarquons que

$$S_t - R_t = (1 - \rho)(S_{t-1} - R_{t-1})$$

et  $R_0 = 0$  impliquent  $R_t \leq S_t$ ; donc le choix

$$p_t' = |\Gamma|^2 \mu \rho^{-1} |S_t|$$

satisfait [A5]. La démonstration se termine comme pour le théorème 2. ■

Puisque l'expression de la covariance asymptotique de l'erreur est la même que dans le théorème 2, le corollaire 1 reste vrai pour l'algorithme (20) - (22).

## References

- [1] A. BENVENISTE, M. METIVIER and P. PRIOURET *Adaptive Algorithms and Stochastic Approximations* Springer-Verlag, Berlin, 1990.
- [2] S. BITTANTI and M. CAMPI Adaptive RLS algorithms under stochastic excitation -  $L^2$  convergence analysis. *IEEE Trans. Automatic Control*, AC-36, N. 8, 963-967, 1991.
- [3] L.GUO, L. LJUNG and P. PRIOURET Performance Analysis of Forgetting factor RLS, *Proceedings of CDC'91*, Tucson, Arizona, December 1992.
- [4] A. JUDITSKY and P. PRIOURET A robust algorithm for random parameter tracking. Submitted for publication.
- [5] H. KUSHNER, H. HUANG, Asymptotic properties of stochastic approximations with constant coefficients, *SIAM J. Control, Optim*, 19, 87-105, 1981.
- [6] L.LJUNG, S.GUNNARSON *Adaptation and Tracking in System Identification-A Survey*, Automatica, Vol.26, No. 1, pp. 7-21,1990.
- [7] L.LJUNG *Optimal and ad-hoc adaptation mechanisms*, Linkoping University Internal Report No.LITH-ISY-I-1181.
- [8] L.LJUNG *An Exact Formula for the Tracking Ability of Adaptive Algorithms* Linkoping University Internal Report No.LITH-ISY-I-1189.
- [9] L.LJUNG, P.PRIOURET *A Result on the Mean Square Error Obtained Using General Tracking Algorithm*, Int.J. of Adaptive Control and Signal Processing, Vol. 5, pp.231-250, 1992.
- [10] L.LJUNG, P.PRIOURET *Remarks on the Mean Square Tracking Error*, Int.J. of Adaptive Control and Signal Processing, Vol. 6,1992.
- [11] A. JUDITSKY, A. NAZIN, Optimal and robust estimation of slowly drifting parameters of linear regression, *Avtomatika i Telemekhanika*, N 6, 66-75, 1991 (in Russian). To be translated as *Automation & Remote Control*.
- [12] O. MACCHI and E. EWEDA Second order convergence analysis of stochastic adaptive linear filtering *IEEE Trans. Automatic Control*, AC-28, 76-85, 1983.
- [13] M. NIEDŹMIEWCKI and L. GUO Nonasymptotic results for finite-memory WLS filters.
- [14] B. WIDROW, J. Mc COOL, M.G. LARIMORE, C.R. JOHNSON Stationary and nonstationary learning characteristics of the LMS adaptive filter, *Proc. of the IEEE*, 64, N. 8, 1151-1161, 1976.