



---

# Seminar Nachrichtentechnik

## Adaptive Entzerrer

### WS 2005/2006

*ZEMMARI REDA*

- 1 Einleitung (MMSE-Lösung)**
- 2 Das Gradientenverfahren**
- 3 Least-Mean-Squares-Algorithmus**
- 4 Recursive-Least-Squares- Algorithmus**
- 5 Zusammenfassung**

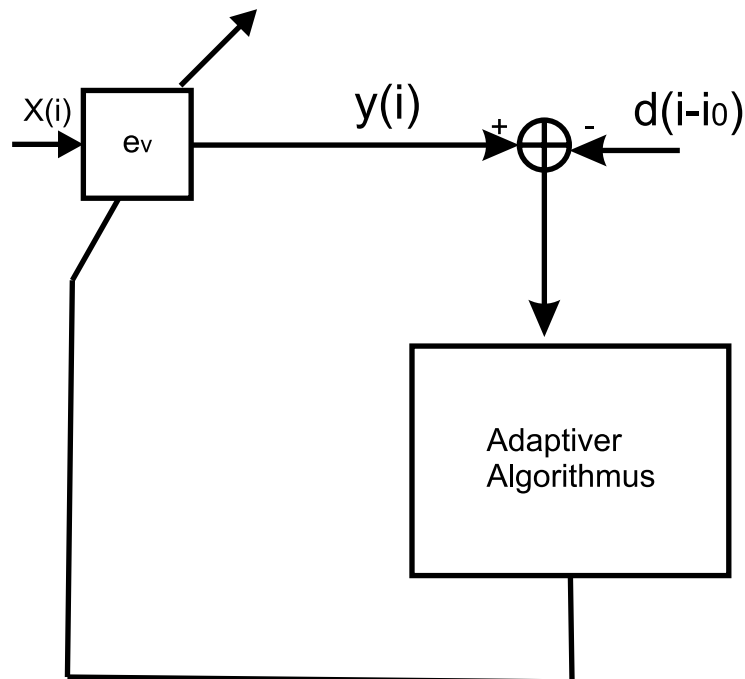


# Einleitung (MMSE-Lösung)



## Aufgabe des adaptiven Entzerrers

- Empfängerseitige Schaltung :



Transversaler Entzerrer :

$$e(k) = \sum_{i=0}^n e_i \delta_{k-i}$$

- Problem : Unbekannte Eigenschaften des Kanals und des entsprechenden Entzerrers
- Lösung : Schätzung der Parameter des Entzerrers



# Einleitung (MMSE-Lösung)



- MMSE-Lösung:

$$\mathbf{F} = E\|Y(i) - D(i - i_0)\|^2 \implies \min$$

wobei

$$Y(i) = X^T(i)e$$
$$e = \begin{pmatrix} e_0 \\ \vdots \\ e_n \end{pmatrix}, \quad X(i) = \begin{pmatrix} X(iT) \\ \vdots \\ X(iT - nT) \end{pmatrix}$$

und  $d(i - i_0)$  eine zwischen Sender und Empfänger vereinbarte Trainingssymbolen Sequenz ist.

## Verfahren

- Least-Mean-Squares-Algorithmus
- Recursive-Least-Squares-Algorithmus






## Definition

- Iteratives , numerisches Verfahren
- Beginnend von einem Startpunkt ( möglichst nah genug)
- Schrittweise in Richtung des steilsten Abfalls
- Das Minimum einer Funktion annähern

$$X_{i+1} = X_i - \mu \frac{\partial f(X_i)}{\partial X_i}$$



# Das Gradientenverfahren



# Least-Mean-Squares-Algorithmus



## LMS-Algorithmus

- Iteratives Verfahren
- Beruht auf dem Gradientenverfahren
- Optimale Lösung des MMSE Problems

$$e(0) : \textit{Startvektor} \quad e(i+1) = e(i) - \mu \frac{\partial \mathbf{F}}{\partial e^H(i)}$$
$$\mu : \textit{positive Schrittweite}$$

## Konvergenz des GV

- $F$  ist in quadratischer Form
- $F$  stellt ein Leistung dar  $\implies$  immer nicht negativ
- Es existiert immer ein Minimum

$$e_{opt} = \min \mathbf{F} \quad \textit{ist eindeutig bestimmt}$$



# Least-Mean-Squares-Algorithmus



## Der stochastische Gradientenalgorithmus

- In der Praxis ist der Erwartungswert unbekannt
- Schätzung des Fehlers durch:

$$\hat{\mathbf{F}} = |y(i) - d(i - i_0)|^2$$

- der stochastische Gradientenalgorithmus :

$$e(i + 1) = e(i) - \mu \frac{\partial \hat{\mathbf{F}}}{\partial e^H(i)}$$

Die Ableitung ist im  
Sinne von Wirtinger

es gilt dann:

$$\begin{aligned} \frac{\partial \hat{\mathbf{F}}}{\partial e^H(i)} &= \frac{\partial [y(i) - d(i - i_0)]^* [y(i) - d(i - i_0)]}{\partial e^H(i)} \\ &= \frac{\partial [e^H(i)x^*(i) - d^*(i - i_0)][e^T(i)x(i) - d(i - i_0)]}{\partial e^H(i)} \end{aligned}$$



# Least-Mean-Squares-Algorithmus



Wirtinger Ableitung :

$$\frac{\partial y(i)}{\partial e^H} = \frac{\partial e^T x(i)}{\partial e^H} = 0$$
$$\frac{\partial y^*(i)}{\partial e^H} = \frac{\partial e^H x^*(i)}{\partial e^H} = x^*(i)$$

$$\implies \frac{\partial \hat{\mathbf{F}}}{\partial e^H(i)} = x^*(i)[y(i) - d(i - i_0)]$$

LMS-Algorithmus aus dem stochastischen Gradientenalgorithmus

$$e(i+1) = e(i) - \mu x^*(i)[y(i) - d(i - i_0)]$$
$$= e(i) - \mu \varepsilon(i) x^*(i)$$

*LMS Algorithmus*

Iterationsschritte wiederholen bis:  $\|e(i+1) - e(i)\| < \delta$

- Die Schrittweite  $\mu$  muss auf dem Intervall  $(0, \frac{2}{\lambda_{max}})$  beschränkt sein, wobei  $\lambda_{max}$  der größte Eigenwert von der Autokorrelationsfunktion  $R_{XX}$  ist







## RLS

Korrelationsfunktionen:

$$E\{X^*(i)X(i)\} = R_{XX} \quad , \quad E\{D^*(k)D(k)\} = \sigma_D^2$$
$$E\{X^*(i)D(i)\} = r_{XD}$$

Squared Error :

$$\begin{aligned} \mathbf{F}(i) &= e^H(i)E\{X^*(i)X^T(i)\}e(i) - e^H(i)E\{X^*(i)D(i - i_0)\} \\ &\quad - E\{D^*(i - i_0)X^T(i)\}e(i) + E\{D^*(i - i_0)D^T(i - i_0)\} \\ &= e^H(i)R_{XX}e(i) - e^H(i)r_{XD} - r_{DX}e(i) + \sigma_D^2 \end{aligned}$$

notwendige Bedingung:

$$\frac{\partial \mathbf{F}}{\partial e^H} = R_{XX}e - r_{XD} \doteq 0$$

RLS-Algorithmus:

$$e(i + 1) = R_{XX}^{-1}(i)r_{XD}(i)$$

- **Nachteil:** Kenntniss der Autokorrelationsfunktion  $R_{XX}(i)$  und Kreuzkorrelationsfunktion  $r_{XD}(i)$  erforderlich





- In der Praxis sind AKF und KKF unbekannt
- Schätzung durch zeitliche Mittelung :

$$\hat{R}_{XX}(i) = \sum_{k=0}^i w^{i-k} x^*(k) x^T(k)$$

$0 < w < 1$  : ' Vergessensfaktor' [Forgetting factor ] (zeitlich zurückliegende Mittelungsergebnisse werden geschwächt. Sehr üblich bei zeitvarianten Kanälen . )

- rekursiv gilt dann:

$$\begin{aligned}\hat{R}_{XX}(i) &= w\hat{R}_{XX}(i-1) + x^*(i)x^T(i) \\ \hat{r}_{XD}(i) &= w\hat{r}_{XD}(i-1) + x^*(i)d(i-i_0)\end{aligned}$$

- Modifizierter RLS-Algorithmus :

$$e(i+1) = \hat{R}_{XX}^{-1}(i)\hat{r}_{XD}(i)$$

**Nachteil** : die inverse Matrix muss in jedem Iterationsschritt neu ausgerechnet werden





## Matrix-Inversionslemma

$$\hat{R}_{XX}^{-1}(i) = \frac{1}{w} [\hat{R}_{XX}^{-1}(i-1) - k(i)x^T \hat{R}_{XX}^{-1}(i-1)]$$
$$k(i) = \frac{1}{w + L(i)} \hat{R}_{XX}^{-1}(i-1)x^*(i)$$

wobei  $L(i) = x^T \hat{R}_{XX}^{-1}(i-1)x^*(i)$

- aus dem modifizierten RLS- Algorithmus :

$$e(i+1) = \frac{1}{w} [\hat{R}_{XX}^{-1}(i-1) - k(i)x^T \hat{R}_{XX}^{-1}(i-1)] [w\hat{r}_{XD}(i-1) + x^*(i)d(i-i_0)]$$
$$= \hat{R}_{XX}^{-1}(i-1)\hat{r}_{XD}(i-1) + \frac{1}{w} \hat{R}_{XX}^{-1}(i-1)x^*(i)d(i-i_0)$$
$$- k(i)x^T \hat{R}_{XX}^{-1}(i-1)\hat{r}_{XD}(i-1) - \frac{1}{w} k(i)x^T \hat{R}_{XX}^{-1}(i-1)x^*(i)d(i-i_0)$$
$$e(i+1) = e(i) + \frac{1}{w} d(i-i_0) \hat{R}_{XX}^{-1}(i-1)x^*(i) - k(i)x^T e(i) - \frac{L(i)}{w} d(i-i_0)k(i)$$



# Recursive-Least-Squares- Algorithmus



aus:

$$\begin{aligned} & x^T e(i) = y(i) \quad (\text{Ausgangswert des Entzerrers}) \\ \text{und} \quad & \hat{R}_{XX}^{-1}(i-1)x^*(i) = [w + L(i)]k(i) \end{aligned}$$

folgt:

$$e(i+1) = e(i) - k(i) \underbrace{[y(i) - d(i - i_0)]}_{\varepsilon(i)}$$

RLS-Algorithmus:

$$e(i+1) = e(i) - k(i)\varepsilon(i)$$





## RLS-Schritte

- Ausgang ausrechnen

$$y(i) = x^T e(i)$$

- Vergleich mit Trainingsdaten

$$\varepsilon(i) = y(i) - d(i - i_0)$$

- Kalman Verstärkung :

$$k(i) = \frac{1}{w + L(i)} \hat{R}_{XX}^{-1}(i-1) x^*(i)$$
$$L(i) = x^T \hat{R}_{XX}^{-1}(i-1) x^*(i)$$

- Aktualisierung der inversen Autokorrelationsmatrix

$$\hat{R}_{XX}^{-1}(i) = \frac{1}{w} [\hat{R}_{XX}^{-1}(i-1) - k(i) x^T \hat{R}_{XX}^{-1}(i-1)]$$

- Aktualisierung des Koeffizientenvektors

$$e(i+1) = e(i) - k(i) \varepsilon(i)$$

bis  $\|e(i+1) - e(i)\| < \delta$





## vorgestellte Verfahren

- LMS-Algorithmus basiert auf dem Gradientenverfahren
- RLS-Algorithmus mit Hilfe der Kalman Verstärkung

## Vor- und Nachteile

- Konvergenzgeschwindigkeit des LMS-Algorithmus hängt von dem Verhältnis zwischen maximalem und minimalem Eigenwert der AKF ab
- Adaptionsgeschwindigkeit wird durch den RLS-Algorithmus gesteigert
- Aktualisierung der inversen Matrix erhöht den Rechenaufwand
- Aufwand in jedem Iterationsschritt :  $n + 1$  beim LMS und  $(n + 1)^2$  beim RLS

## Lösung

- Lattice-Entzerrer : gutes Konvergenzverhalten mit kleinem Rechenaufwand verbinden.





## Literatur

- Karl-Dirk Kammeyer Nachrichtenübertragung 3.Auflage

