

Resumindo e concluindo...

TeleTextos de bolso e de trazer por casa, suavemente, suavemente

Os critérios de decisão MAP e ML

© Sílvio A. Abrantes

Departamento de Engenharia Electrotécnica e de Computadores
Faculdade de Engenharia, Universidade do Porto
Porto, Portugal
sam@fe.up.pt

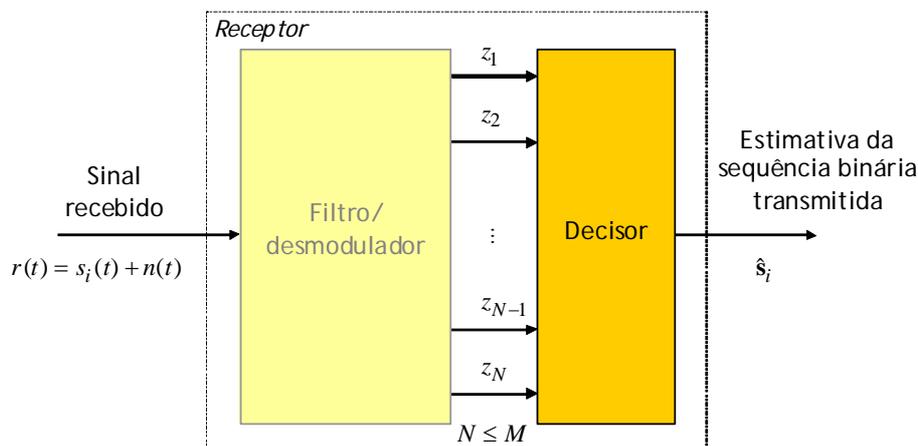
Janeiro de 2009

Conteúdo

1. Introdução	1
2. Os critérios de estimação MAP e ML	2
2.1. Critério ML ("maximum likelihood")	3
2.2. Critério MAP ("maximum a posteriori probability")	3
2.3. Decisões binárias com ruído gaussiano branco aditivo	6
2.4. Extensão à transmissão não-binária em espaço multidimensional	8
2.4.1. Decisões com ruído gaussiano branco aditivo	9
3. Minimização da probabilidade de erro	11

1. Introdução

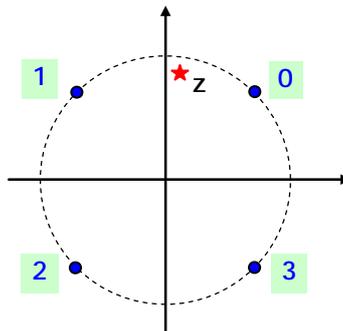
Uma sequência de M formas de onda $s_i(t)$, $0 \leq t \leq T$, representadas num espaço de sinal de $N \leq M$ dimensões atravessa um canal de comunicação ruidoso e chega ao receptor, que a tenta estimar através de uma escolha realizada num bloco decisor (ver figura seguinte). Admitamos que em cada instante de amostragem o decisor recebe um conjunto de N valores, que encararemos como um vector-coluna $\mathbf{z} = [z_1 \ \dots \ z_N]^T$ no referido espaço de sinal de N dimensões. A dimensão do espaço depende do sinal enviado. Por exemplo, um sinal modulado em 16-QAM necessita de duas dimensões, ao passo que um sinal de 8-FSK precisa de oito e um sinal antipodal em banda-base só precisa de uma.



Sem ru do o vector \mathbf{z} nos sucessivos instantes de amostragem apresenta-nos as coordenadas dos pontos da constela o. Com ru do j  n o obtemos esses pontos mas sim outros.

$$\text{Sem ru do: } \mathbf{z} = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_N \end{bmatrix} = \begin{bmatrix} s_{i1} \\ s_{i2} \\ \vdots \\ s_{iN} \end{bmatrix} = \mathbf{s}_i \qquad \text{Com ru do: } \mathbf{z} = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_N \end{bmatrix} = \begin{bmatrix} s_{i1} + n_1 \\ s_{i2} + n_2 \\ \vdots \\ s_{iN} + n_N \end{bmatrix} = \mathbf{s}_i + \mathbf{n}$$

No vector anterior o ru do   representado pelo vector de amostras $\mathbf{n} = [n_1 \dots n_N]$. A pergunta que fazemos  : como estimar o s mbolo s_i a partir do vector recebido \mathbf{z} ? Por exemplo, se na figura seguinte recebermos o vector \mathbf{z} assinalado que ponto da constela o devemos escolher? Deveremos escolher o s mbolo 0? E por que n o o s mbolo 1?



Para responder  s perguntas devemos ter em conta a estat stica do ru do e as probabilidades de ocorr ncia dos s mbolos, que no seu conjunto nos v o ajudar a estabelecer regi es de decis o, ou regi es de pertenc a: se o ponto recebido "cair" na regi o do sinal 2, por exemplo, o decisor escolhe esse s mbolo. Como estabelecer regi es de decis o e suas fronteiras? Vamos abordar dois m todos.

2. Os cr terios de estima o MAP e ML

Suponhamos que o ru do aditivo tem m dia nula e que a sua fun o densidade de probabilidade (fdp)   $p_n(\mathbf{n})$, uma fun o de N vari veis visto o vector \mathbf{n} ser composto de N elementos. Como estes s o independentes uns dos outros a fdp conjunta $p_n(\mathbf{n})$   igual ao produto das fdp de cada um:

$$p_n(\mathbf{n}) = p_n(n_1)p_n(n_2)\dots p_n(n_N) = \prod_{j=1}^N p_n(n_j).$$

Se transmitirmos o s mbolo correspondente a s_i o decisor recebe uma amostra $\mathbf{z} = \mathbf{s}_i + \mathbf{n}$ de uma vari vel aleat ria cuja fdp   $p(\mathbf{z}|\mathbf{s}_i) = p_n(\mathbf{z} - \mathbf{s}_i) = \prod_{j=1}^N p_n(z_j - s_{ij})$. A fun o densidade de probabilidade condicional $p(\mathbf{z}|\mathbf{s}_i)$ d -se o nome de *verossimilhan a* de s_i . As verossimilhan as s o conhecidas *a priori*, mesmo sem ainda termos recebido nada.

Se o ru do for gaussiano com m dia nula e vari ncia σ^2 - isto  ¹, $\mathcal{N}(0, \sigma^2)$ - a fdp da amostra de ru do n_j   dada por

$$p_n(n_j) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{\frac{-n_j^2}{2\sigma^2}} \tag{1}$$

¹ Para quem n o sabe: $\mathcal{N}(\bar{X}, \sigma^2)$ designa uma distribui o normal (gaussiana) de m dia \bar{X} e vari ncia σ^2 .

e a verosimilhança da componente s_{ij} é igual a

$$p_n(z_j - s_{ij}) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(z_j - s_{ij})^2}{2\sigma^2}\right)$$

de modo que globalmente temos

$$\begin{aligned} p(\mathbf{z}|\mathbf{s}_i) &= \prod_{j=1}^N \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(z_j - s_{ij})^2}{2\sigma^2}\right) = \\ &= \left(\frac{1}{2\pi\sigma^2}\right)^{N/2} \exp\left(-\frac{(z_1 - s_{i1})^2 + (z_2 - s_{i2})^2 + \dots + (z_N - s_{iN})^2}{2\sigma^2}\right) = \\ &= \left(\frac{1}{2\pi\sigma^2}\right)^{N/2} \exp\left(-\frac{\|\mathbf{z} - \mathbf{s}_i\|^2}{2\sigma^2}\right) \end{aligned} \quad (2)$$

Note-se que $\|\mathbf{z} - \mathbf{s}_i\| = d_i$ representa a distância do ponto recebido ao símbolo s_i pelo que poderíamos escrever também $p(\mathbf{z}|\mathbf{s}_i) = \left(\frac{1}{2\pi\sigma^2}\right)^{N/2} \exp\left(-\frac{d_i^2}{2\sigma^2}\right)$. Um caso muito frequente é o do espaço de sinal a duas dimensões. Aí é

$$p(\mathbf{z}|\mathbf{s}_i) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{\|\mathbf{z} - \mathbf{s}_i\|^2}{2\sigma^2}\right) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{d_i^2}{2\sigma^2}\right). \quad (3)$$

A estimativa do ponto enviado é feita de acordo com dois critérios de estimação de parâmetros: MAP e ML. Suponhamos, em primeiro lugar, que temos uma transmissão binária de pontos s_0 e s_1 . Depois generalizaremos a situação para a transmissão não-binária de símbolos num espaço de sinal multidimensional.

2.1. Critério ML (“maximum likelihood”)

Imagine-se que a probabilidade de se receber um dado vector \mathbf{z} tendo-se enviado s_1 é maior que a de receber o mesmo \mathbf{z} se se tiver enviado s_0 . Se assim for somos inclinados a pensar que, provavelmente, foi enviado s_1 . Então uma maneira de escolher o ponto enviado é procurar aquele que está associado à maior das verosimilhanças $p(\mathbf{z}|\mathbf{s}_0)$ e $p(\mathbf{z}|\mathbf{s}_1)$. É por isso que se chama a esta opção de escolha *critério da máxima verosimilhança*, ou *critério ML*. As decisões são tomadas de acordo com

$$p(\mathbf{z}|\mathbf{s}_1) \underset{H_0}{\overset{H_1}{\geq}} p(\mathbf{z}|\mathbf{s}_0) \quad \text{critério ML} \quad (4)$$

A expressão significa que se $p(\mathbf{z}|\mathbf{s}_1) > p(\mathbf{z}|\mathbf{s}_0)$ escolhemos a hipótese H_1 (símbolo s_1), senão escolhemos a outra.

Embora possa não nos levar aos melhores resultados a detecção de máxima verosimilhança é a mais usada de todas.

2.2. Critério MAP (“maximum a posteriori probability”)

Imaginemos agora que, tendo-se recebido um certo ponto \mathbf{z} , a probabilidade de se ter enviado s_1 é maior que a de se ter enviado s_0 . Então o nosso decisor “pensará”, com certeza, que s_1 foi enviado, isto é, escolherá o ponto associado à maior das probabilidades condicionais a posteriori $p(s_0|\mathbf{z})$ e $p(s_1|\mathbf{z})$. Por isso se chama a este tipo de escolha *critério da máxima probabilidade a*

posteriori, ou *critério MAP*. Tínhamos acabado de ver que, pelo contrário, a estimação ML usa probabilidades a priori (as verosimilhanças).

Sem o provar por enquanto, podemos contudo ir já adiantando:

A estimação MAP minimiza a probabilidade de erro.

Com base na amostra observada \mathbf{z} as decisões MAP respeitam, portanto,

$$p(\mathbf{s}_1 | \mathbf{z}) \underset{H_0}{\overset{H_1}{\geq}} p(\mathbf{s}_0 | \mathbf{z}) \quad \text{critério MAP} \quad (5)$$

Porém, temos um problema: não conhecemos as probabilidades $p(\mathbf{s}_0 | \mathbf{z})$ e $p(\mathbf{s}_1 | \mathbf{z})$. "Felizmente temos Bayes". De facto, sendo P_i a probabilidade de ocorrência do símbolo s_i o teorema de Bayes $p(A)p(B|A) = p(B)p(A|B)$ permite-nos escrever

$$\frac{p(\mathbf{z} | \mathbf{s}_1)P_1}{p(\mathbf{z})} \underset{H_0}{\overset{H_1}{\geq}} \frac{p(\mathbf{z} | \mathbf{s}_0)P_0}{p(\mathbf{z})},$$

para logo a seguir nos desembaraçarmos do denominador comum $p(\mathbf{z})$ e obtermos a expressão final, uma razão de verosimilhanças:

$$\frac{p(\mathbf{z} | \mathbf{s}_1)P_1}{p(\mathbf{z} | \mathbf{s}_0)} \underset{H_0}{\overset{H_1}{\geq}} \frac{P_0}{P_1} \quad \text{critério MAP} \quad (6)$$

Se $P_0 = P_1$ então $p(\mathbf{z} | \mathbf{s}_1) \underset{H_0}{\overset{H_1}{\geq}} p(\mathbf{z} | \mathbf{s}_0)$. Mas... isto é o critério ML! Concluimos então que

Os critérios de estimação MAP e ML são equivalentes se os símbolos forem equiprováveis.

Resumindo um pouco:

- Na estimação MAP consideramos probabilidades a posteriori, isto é, probabilidades obtidas após observação da saída do canal.
- Na estimação ML consideramos probabilidades a priori (verosimilhanças), isto é, probabilidades já conhecidas antecipadamente. É um método mais simples e também o mais usado.
- Se as formas de onda $s_0(t)$ e $s_1(t)$ forem equiprováveis os dois critérios de estimação são equivalentes.
- A estimação MAP minimiza a probabilidade de erro. A estimação ML só minimiza a probabilidade de erro se os símbolos forem equiprováveis.
- Se não conhecermos as probabilidades de ocorrência dos símbolos o melhor é supor que são igualmente prováveis.

Exemplo 1: Transmissão binária em espaço unidimensional

Consideremos a transmissão digital de uma sequência de bits representados por formas de onda $s_0(t)$ e $s_1(t)$ a que correspondem os pontos \mathbf{s}_0 e \mathbf{s}_1 da Fig. 1, onde $\psi_1(t)$ é uma função-base de energia unitária. Foi recebido o ponto $z = 3,5$.

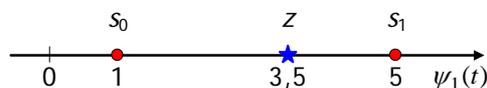


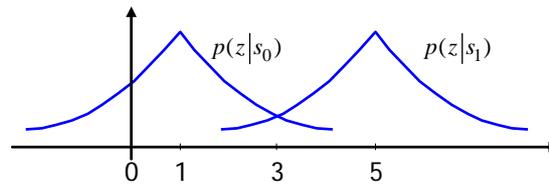
Fig. 1 Pontos enviados e ponto recebido.

Devemos escolher o ponto da Fig. 1 que estiver mais próximo do recebido (neste caso, s_1)? A resposta correcta pode ser esta, mas também pode não ser. Qual é a resposta correcta afinal? Para responder precisamos de encontrar um *limiar de decisão* γ , um valor que divida a recta da figura em duas semi-rectas: se z estiver "à direita" do limiar escolhemos um ponto (s_1 , por exemplo), se estiver "à esquerda" escolhemos o outro. Expressimos tal procedimento escrevendo

$$z \underset{H_0}{\overset{H_1}{\geq}} \gamma \text{ e para determinarmos } \gamma \text{ teremos de nos servir das Eqs. (4) e (6).}$$

P.: Admitamos que o ruído no canal tem função densidade de probabilidade $p_n(n) = \frac{1}{\sqrt{2\sigma^2}} e^{-\sqrt{2}|n|/\sigma}$, em que $\sigma^2 = 9$ representa a potência. Se $P_0 = 2/3$ quais deverão ser os limiares de decisão MAP e ML e quais as respectivas estimativas do ponto enviado?

R.: As verosimilhanças de que necessitamos estão representadas na figura seguinte.



A Eq. (4) diz-nos logo que o limiar de decisão ML está na intersecção das funções, isto é, 3. Já o confirmaremos. Quanto ao critério MAP, é expresso por $\frac{p(z|s_1)}{p(z|s_0)} \underset{H_0}{\overset{H_1}{\geq}} \frac{P_0}{P_1}$, que neste caso se escreve

$$\exp\left[\frac{\sqrt{2}}{\sigma} (|z-1| - |z-5|)\right] \underset{H_0}{\overset{H_1}{\geq}} \frac{P_0}{P_1} . \text{ O desenvolvimento desta expressão conduz-nos sucessivamente a}$$

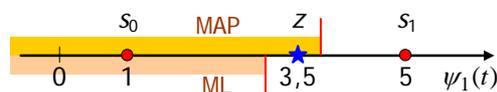
$$\exp\left[\frac{\sqrt{2}}{\sigma} (z-1 + z-5)\right] \underset{H_0}{\overset{H_1}{\geq}} \frac{P_0}{P_1} \quad \Rightarrow \quad z \underset{H_0}{\overset{H_1}{\geq}} 3 + \frac{\sigma}{2\sqrt{2}} \ln \frac{P_0}{P_1}$$

$$z \underset{H_0}{\overset{H_1}{\geq}} 3,7352 \quad \Rightarrow \quad \gamma_{MAP} = 3,7352$$

Ficámos a saber que, segundo o critério MAP, acima de 3,7352 decidimos uma coisa e abaixo decidimos outra.

O critério ML exprime-se fazendo $P_0 = P_1$ na expressão MAP $z \underset{H_0}{\overset{H_1}{\geq}} 3 + \frac{\sigma}{2\sqrt{2}} \ln \frac{P_0}{P_1}$:

$$z \underset{H_0}{\overset{H_1}{\geq}} 3 \quad \Rightarrow \quad \gamma_{ML} = 3 \quad (\text{confirma o valor antecipado})$$



O valor recebido, $z = 3,5$, conduz-nos a duas decisões distintas:

MAP: escolhemos s_0 .

ML: escolhemos s_1 .

A primeira é uma melhor escolha.

2.3. Decis es bin rias com ru do gaussiano branco aditivo

Sejam $d_0 = \|\mathbf{z} - \mathbf{s}_0\|$ e $d_1 = \|\mathbf{z} - \mathbf{s}_1\|$ as dist ncias do ponto recebido \mathbf{z} aos dois pontos \mathbf{s}_0 e \mathbf{s}_1 , respectivamente, e suponhamos que o ru do tem distribui o normal $\mathcal{N}(0, \sigma^2)$. As verosimilhan as de que precisamos s o as probabilidades gaussianas condicionais da Eq. (2),

$$p(\mathbf{z} | \mathbf{s}_0) = \left(\frac{1}{2\pi\sigma^2} \right)^{N/2} \exp \left(-\frac{\|\mathbf{z} - \mathbf{s}_0\|^2}{2\sigma^2} \right) = \left(\frac{1}{2\pi\sigma^2} \right)^{N/2} \exp \left(-\frac{d_0^2}{2\sigma^2} \right)$$

$$p(\mathbf{z} | \mathbf{s}_1) = \left(\frac{1}{2\pi\sigma^2} \right)^{N/2} \exp \left(-\frac{\|\mathbf{z} - \mathbf{s}_1\|^2}{2\sigma^2} \right) = \left(\frac{1}{2\pi\sigma^2} \right)^{N/2} \exp \left(-\frac{d_1^2}{2\sigma^2} \right).$$

Em fun o das dist ncias quadr ticas o crit rio MAP $\frac{p(\mathbf{z} | \mathbf{s}_1) \frac{1}{P_1}}{p(\mathbf{z} | \mathbf{s}_0) \frac{1}{P_0}} \geq 1$ exprime-se assim, independentemente de N :

$$\exp \left(\frac{-d_1^2 + d_0^2}{2\sigma^2} \right) \geq \frac{P_0}{P_1}$$

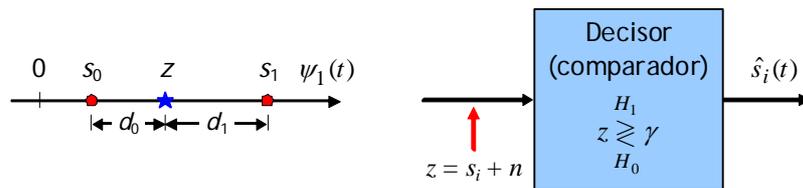
$$d_0^2 \geq d_1^2 + 2\sigma^2 \ln \frac{P_0}{P_1} \quad (\text{MAP}) \quad (7)$$

O crit rio da m xima verosimilhan a $\frac{1}{p(\mathbf{z} | \mathbf{s}_1)} \geq \frac{1}{p(\mathbf{z} | \mathbf{s}_0)}$, sempre mais simples, reduz-se a

$$d_0^2 \geq d_1^2 \quad (\text{ML})^2 \quad (8)$$

Note-se que a decis o de m xima verosimilhan a n o depende das probabilidades de ocorr ncia dos s mbolos nem do ru do, s  depende de dist ncias: escolhe-se o ponto que estiver mais perto do recebido.

No caso particular de um espa o unidimensional ($N = 1$) o receptor dever  tomar uma decis o bin ria $\frac{1}{z \geq \gamma}$. Quanto vale γ ?



As verosimilhan as (mostradas na Fig. 2) s o iguais a

$$p(z | s_0) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[-\frac{(z - s_0)^2}{2\sigma^2} \right] \quad p(z | s_1) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[-\frac{(z - s_1)^2}{2\sigma^2} \right]$$

Basta usar a Eq. (7) com $d_0 = z - s_0$ e $d_1 = s_1 - z$ que logo chegamos a

$$z \geq \frac{s_0 + s_1}{2} + \frac{\sigma^2}{s_1 - s_0} \ln \frac{P_0}{P_1} \quad \Rightarrow \quad \gamma_{MAP} = \frac{s_0 + s_1}{2} + \frac{\sigma^2}{s_1 - s_0} \ln \frac{P_0}{P_1} \quad (\text{MAP})$$

²   tentador usar a dist ncia em vez da dist ncia quadr tica (o resultado final seria o mesmo, evidentemente). No entanto... qual   mais f cil de calcular?

Daqui obtemos o limiar de decis o ML, que fica equidistante de s_0 e s_1 : $\gamma_{ML} = \frac{s_0 + s_1}{2}$.

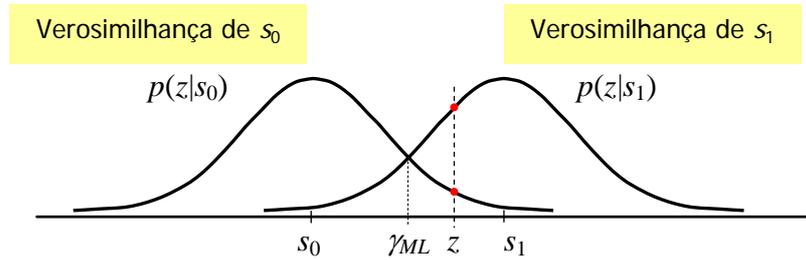


Fig. 2 As fun es de verosimilhan a gaussianas.

Exemplo 2:
Transmiss o bin ria com ru do gaussiano em espa o bidimensional

Uma constela o bin ria   formada pelos dois pontos $s_0 = [1 \ 2]^T$ e $s_1 = [5 \ 0]^T$. A densidade espectral de pot ncia do ru do gaussiano   $\sigma^2 = N_0/2$, com $N_0 = 3$, e os s mbolos ocorrem com as probabilidades $P_0 = p(s_0)$ e $P_1 = 1 - P_0$. O decisor recebeu o ponto $r = [2 \ -0,5]^T$.

Queremos determinar a equa o da linha que separa as regi es de decis o de s_0 e s_1 segundo os crit rios MAP e ML quando $P_0 = 0,5$ e $P_0 = 0,1$. Qual ser  a estimativa do ponto enviado se $P_0 = 0,1$?

R.: As dist ncias quadr ticas de um ponto recebido $r = [x \ y]^T$ a cada um dos s mbolos s o $d_0^2 = \|r - s_0\|^2 = (x-1)^2 + (y-2)^2$ e $d_1^2 = \|r - s_1\|^2 = (x-5)^2 + y^2$. Sabemos que $d_0^2 \stackrel{1}{\geq} d_1^2 + 2\sigma^2 \ln \frac{P_0}{P_1}$ (Eq. (7)) pelo que a regi o de decis o MAP de s_1   definida por

$$(x-1)^2 + (y-2)^2 > (x-5)^2 + y^2 + 2\sigma^2 \ln \frac{P_0}{P_1} \quad \Rightarrow \quad y < 2x - \frac{\sigma^2}{2} \ln \frac{P_0}{P_1} - 5$$

ou, tendo em conta que $\sigma^2 = N_0/2$, $y < 2x + \frac{N_0}{4} \ln \frac{1-P_0}{P_0} - 5$. Digamos, portanto, que

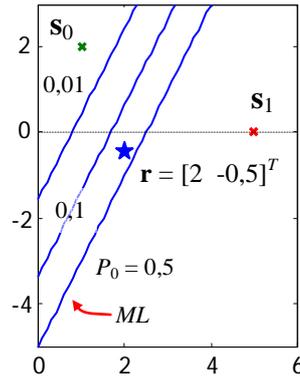
$$y \stackrel{0}{\geq} \underset{1}{2}x + \frac{N_0}{4} \ln \frac{1-P_0}{P_0} - 5.$$

A fronteira MAP   a recta $y = 2x + \frac{N_0}{4} \ln \frac{1-P_0}{P_0} - 5$, de declive 2 e que cruza o eixo dos yy em $\frac{N_0}{4} \ln \frac{1-P_0}{P_0} - 5$. Este cruzamento   tanto mais alto no eixo quanto maior for N_0 e quanto menos prov vel for s_0 (costuma ser assim, realmente: o limiar de decis o  ptimo est  mais pr ximo do s mbolo menos prov vel). Substituindo os valores de P_0 obtemos:

$$P_0 = 0,5 : y \stackrel{0}{\geq} \underset{1}{2}x - 5.$$

$$P_0 = 0,1 : y \stackrel{0}{\geq} \underset{1}{2}x + \frac{3}{4} \ln \frac{0,9}{0,1} - 5 = 2x - 3,35. \text{ (a recta est  a "subir", aproximando-se de } s_0)$$

A figura mostra as fronteiras para $N_0 = 3$ e tr s valores diferentes de P_0 .



A fronteira estabelecida pela regra de decisão ML é obtida da regra MAP fazendo $P_0 = 0,5$: $y_1 \geq_0 2x - 5$. A fronteira de decisão ML não depende do nível de ruído nem das probabilidades de ocorrência dos bits.

Como o ponto $\mathbf{r} = [2 \ -0,5]^T$ fica abaixo da linha de fronteira $y_1 \geq_0 2x - 3,35$ do critério MAP estimamos que foi transmitido o bit \mathbf{s}_1 . A linha divisória ML é outra, $y_1 \geq_0 2x - 5$, e como \mathbf{r} fica acima dela estimamos que foi transmitido o símbolo \mathbf{s}_0 .

2.4. Extensão à transmissão não-binária em espaço multidimensional

Agora temos M símbolos passíveis de ser enviados e recebemos um vector \mathbf{z} de N elementos. Consoante o tipo de estimação, ou escolhemos a maior de todas as verosimilhanças $p(\mathbf{z}|\mathbf{s}_i)$ (critério ML) ou a maior de todas as probabilidades a posteriori $p(\mathbf{s}_i|\mathbf{z})$ (critério MAP). O primeiro critério exprime-se assim:

$$\text{Escolhe-se } \mathbf{s}_K \text{ se } p(\mathbf{z}|\mathbf{s}_K) = \max p(\mathbf{z}|\mathbf{s}_i), \quad i = 1, 2, \dots, M \quad \text{critério ML}$$

Dado que a função logaritmo é crescente, o mesmo símbolo será escolhido se em vez da máxima verosimilhança $p(\mathbf{z}|\mathbf{s}_i)$ procurarmos a máxima *log-verosimilhança* $\ln p(\mathbf{z}|\mathbf{s}_i)$:

$$\text{Escolhe-se } \mathbf{s}_K \text{ se } \ln p(\mathbf{z}|\mathbf{s}_K) = \max [\ln p(\mathbf{z}|\mathbf{s}_i)], \quad i = 1, 2, \dots, M \quad \text{critério ML}$$

Quanto ao critério MAP faremos deste modo:

$$\text{Escolhe-se } \mathbf{s}_K \text{ se } p(\mathbf{s}_K|\mathbf{z}) = \max p(\mathbf{s}_i|\mathbf{z}), \quad i = 1, 2, \dots, M \quad \text{critério MAP}$$

Socorremo-nos de novo de Bayes e escrevemos

$$p(\mathbf{s}_i|\mathbf{z}) = \frac{P_i p(\mathbf{z}|\mathbf{s}_i)}{p(\mathbf{z})}$$

(ou seja, $p(\mathbf{s}_1|\mathbf{z}) = \frac{P_1 p(\mathbf{z}|\mathbf{s}_1)}{p(\mathbf{z})}$, $p(\mathbf{s}_2|\mathbf{z}) = \frac{P_2 p(\mathbf{z}|\mathbf{s}_2)}{p(\mathbf{z})}$, etc.). Como o denominador $p(\mathbf{z})$ é comum a todas as $p(\mathbf{s}_i|\mathbf{z})$ tanto faz procurar a maior probabilidade $p(\mathbf{s}_i|\mathbf{z})$ como o maior produto $P_i p(\mathbf{z}|\mathbf{s}_i)$. Diremos então que

$$\text{Escolhe-se } \mathbf{s}_K \text{ se } P_K p(\mathbf{z}|\mathbf{s}_K) = \max [P_i p(\mathbf{z}|\mathbf{s}_i)], \quad i = 1, 2, \dots, M \quad \text{critério MAP}$$

ou, aplicando logaritmos,

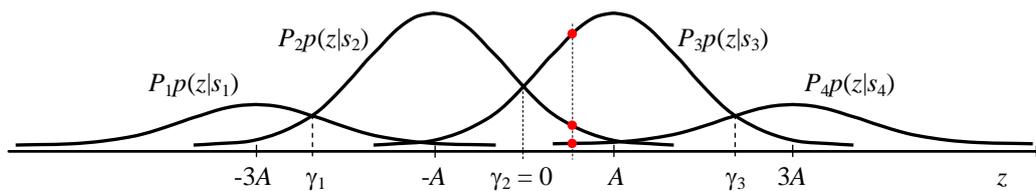
$$\text{Escolhe-se } s_K \text{ se } \ln[P_K p(\mathbf{z} | s_K)] = \max \ln[P_i p(\mathbf{z} | s_i)], \quad i = 1, 2, \dots, M \quad \text{crit rio MAP}$$

E se os s mbolos forem equiprov veis? Nesse caso todas as probabilidades P_i s o iguais e tanto faz procurar o m ximo de $P_i p(\mathbf{z} | s_i)$ como o m ximo de $p(\mathbf{z} | s_i)$. Mas... n o   este o crit rio ML? Pois  ! Voltamos a concluir que com equiprobabilidade os dois tipos de escolha s o equivalentes.

Exemplo 3:
Transmiss o quatern ria com ru do gaussiano em espa o unidimensional

Uma constela o de sinal unidimensional   constitu da pelos quatro pontos $s_1 = -3A$, $s_2 = -A$, $s_3 = A$ e $s_4 = 3A$. As suas probabilidades de ocorr ncia s o $P_1 = P_4 = 1/8$ e $P_2 = P_3 = 3/8$ e o ru do   gaussiano aditivo com m dia nula e vari ncia $\sigma^2 = A^2/\ln 3$. Vamos determinar os limiares de decis o MAP.

A figura seguinte apresenta os quatro produtos $P_i p(z | s_i) = P_i \frac{1}{\sqrt{2\pi\sigma^2}} e^{-(z-s_i)^2/2\sigma^2}$, $i = 1, 2, 3, 4$, necess rios ao crit rio MAP; segundo este, deveremos escolher o s mbolo para o qual $P_i p(z | s_i)$ seja o maior de todos.



As curvas intersectam-se em $z = \gamma_1$, $z = \gamma_2 = 0$ e $z = \gamma_3$. Se $z < \gamma_1$ o valor de $P_1 p(z | s_1)$   maior que os outros tr s produtos e deveremos escolher o s mbolo s_1 ; do mesmo modo, se $z \geq \gamma_3$ o valor de $P_4 p(z | s_4)$   o maior e deveremos escolher s_4 , enquanto que s_2 e s_3 dever o ser escolhidos se $\gamma_1 \leq z < \gamma_2$ e $\gamma_2 \leq z < \gamma_3$, respectivamente. As interse es indicam assim os limiares de decis o MAP. J  conhecemos um ($\gamma_2 = 0$) e, dada a simetria, sabemos que $\gamma_3 = -\gamma_1$. Determinemos γ_3 , por exemplo:

$$P_3 p(z | s_3) = P_4 p(z | s_4) \quad \Rightarrow \quad \frac{3}{8\sqrt{2\pi\sigma^2}} e^{-(\gamma_3 - A)^2/2\sigma^2} = \frac{1}{8\sqrt{2\pi\sigma^2}} e^{-(\gamma_3 - 3A)^2/2\sigma^2}$$

Tomando logaritmos obtemos

$$\ln 3 - \frac{(\gamma_3 - A)^2}{2\sigma^2} = -\frac{(\gamma_3 - 3A)^2}{2\sigma^2} \quad \Rightarrow \quad \gamma_3 = 2A + \frac{\sigma^2 \ln 3}{2A} = 2,5A$$

Em conclus o: no crit rio ML os limiares  ptimos encontram-se nas interse es de $p(z | s_i)$ ao passo que no crit rio MAP se encontram nas interse es de $P_i p(z | s_i)$.

2.4.1. Decis es com ru do gaussiano branco aditivo

Seja $d_i = \|\mathbf{z} - s_i\|$ a dist ncia do ponto recebido \mathbf{z} ao ponto gen rico s_i e suponhamos que o ru do tem distribui o normal $\mathcal{N}(0, \sigma^2)$. A verossimilhan a gen rica   $p(\mathbf{z} | s_i) = \left(\frac{1}{2\pi\sigma^2}\right)^{N/2} \exp\left(-\frac{d_i^2}{2\sigma^2}\right)$.

Comecemos pelo critério MAP, como de costume. Em vez de

$$\max [P_i p(\mathbf{z} | \mathbf{s}_i)] = \max \left[P_i \left(\frac{1}{2\pi\sigma^2} \right)^{N/2} \exp \left(-\frac{d_i^2}{2\sigma^2} \right) \right]$$

podemos usar $\max [P_i \exp(-d_i^2/2\sigma^2)]$ por causa do factor comum $(1/2\pi\sigma^2)^{N/2}$, e depois $\max(\ln P_i - d_i^2/2\sigma^2)$ após aplicarmos logaritmos. Mas procurar este máximo equivale a procurar o mínimo de $d_i^2/2\sigma^2 - \ln P_i$. Portanto,

$$\text{Escolhe-se } \mathbf{s}_K \text{ se } \frac{d_K^2}{2\sigma^2} - \ln P_K = \min \left(\frac{d_i^2}{2\sigma^2} - \ln P_i \right), \quad i=1,2,\dots,M \quad \text{critério MAP}$$

Como é hábito, para obter o critério ML basta considerar que no critério MAP os símbolos são equiprováveis ($P_i = 1/M$). Logo, procurar $\min(d_i^2/2\sigma^2 - \ln P_i) = \min(d_i^2/2\sigma^2 + \ln M)$ equivale a procurar $\min(d_i^2/2\sigma^2)$ e também $\min d_i^2$. Assim,

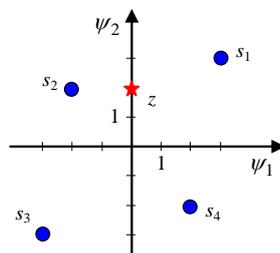
$$\text{Escolhe-se } \mathbf{s}_K \text{ se } d_K^2 = \min d_i^2, \quad i=1,2,\dots,M \quad \text{critério ML}$$

A conclusão não é inesperada: tal como na transmissão binária, com símbolos equiprováveis devemos escolher o ponto enviado que estiver mais próximo do recebido.

Nota: a distância só serve como critério se o ruído for gaussiano.

Exemplo 4: Constelação de 4 pontos no plano

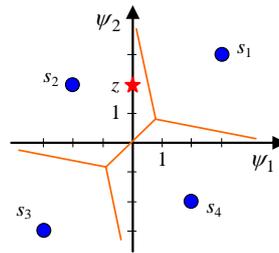
P.: Os pontos \mathbf{s}_i da constelação rômbrica da figura têm coordenadas $\mathbf{s}_1 = [3 \ 3]^T$, $\mathbf{s}_2 = [-2 \ 2]^T$, $\mathbf{s}_3 = [-3 \ -3]^T$ e $\mathbf{s}_4 = [2 \ -2]^T$ e probabilidades de ocorrência $P_1 = P_3 = 1/8$ e $P_2 = P_4 = 3/8$. Se com ruído gaussiano com $\sigma^2 = N_0/2 = 5$ se tiver sido recebido o ponto $\mathbf{z} = [0 \ 2]^T$ quais são as estimativas MAP e ML do ponto enviado?



R.: Na escolha ML procura-se a menor distância quadrática $d_i^2 = \|\mathbf{z} - \mathbf{s}_i\|^2$ e na escolha MAP o menor valor $\frac{d_i^2}{2\sigma^2} - \ln P_i$:

$$\begin{array}{llll} d_1^2 = (0-3)^2 + (2-3)^2 = 10 & d_2^2 = 4 & d_3^2 = 34 & d_4^2 = 20 \\ \frac{d_1^2}{2\sigma^2} - \ln P_1 = 3,08 & \frac{d_2^2}{2\sigma^2} - \ln P_2 = 1,38 & \frac{d_3^2}{2\sigma^2} - \ln P_3 = 5,48 & \frac{d_4^2}{2\sigma^2} - \ln P_4 = 2,98 \end{array}$$

A escolha ML é o símbolo s_2 e a escolha MAP também. A figura seguinte mostra as regiões de decisão de máxima verosimilhança, que confirmam que o ponto z está situado na região de s_2 .



3. Minimização da probabilidade de erro

Afirmou-se atrás: “A estimação MAP minimiza a probabilidade de erro”. Vamos ver porquê, cingindo-nos à transmissão binária.

A probabilidade de erro numa decisão binária entre os símbolos s_0 e s_1 é calculada através da média ponderada $P_e = P_0P(\text{erro}|s_0) + P_1P(\text{erro}|s_1)$. É sabido que o limiar óptimo γ_0 , aquele para o qual P_e atinge o valor mínimo, é determinado pela relação

$$\frac{p(\gamma_0|s_1)}{p(\gamma_0|s_0)} = \frac{P_0}{P_1},$$

em que $p(\gamma_0|s_0)$ e $p(\gamma_0|s_1)$ são os valores das verosimilhanças $p(z|s_i)$ para $z = \gamma_0$. Olhando para a relação MAP $\frac{p(z|s_1)}{p(z|s_0)} \underset{H_0}{\underset{H_1}{\geq}} \frac{P_0}{P_1}$ vemos que o seu limiar de decisão é obtido quando $\frac{p(z|s_1)}{p(z|s_0)} = \frac{P_0}{P_1}$, ou melhor, quando $\frac{p(\gamma_{MAP}|s_1)}{p(\gamma_{MAP}|s_0)} = \frac{P_0}{P_1}$. Ora não quer isto dizer que $\gamma_{MAP} = \gamma_0$?

O limiar γ_{ML} só é óptimo quando os símbolos são equiprováveis.

Um pequeno exemplo vai mostrar a diferença. Seja então $P_0 = 3/4$, $s_1 = -s_0 = 3$ e $\sigma^2 = 6$, a que correspondem os limiares $\gamma_{ML} = 0$ e $\gamma_{MAP} = \ln 3 = 1,1$. Não será difícil de obter as correspondentes probabilidades de erro previstas:

$$\text{ML: } P_e = P(\text{erro}|s_0) = Q\left(\frac{\gamma_{ML} - s_0}{\sigma}\right) = Q\left(\frac{\sqrt{6}}{2}\right) = 0,11$$

$$\text{MAP: } P_e = P_0P(\text{erro}|s_0) + P_1P(\text{erro}|s_1) = P_0Q\left(\frac{\gamma_{MAP} - s_0}{\sigma}\right) + P_1Q\left(\frac{s_1 - \gamma_{MAP}}{\sigma}\right) = 0,09$$

O que é melhor?

Exemplo 5: Probabilidade de erro em transmissão quaternária unidimensional

Retomemos o Exemplo 3 para calcular a probabilidade de erro resultante da escolha dos limiares de decisão óptimos $\gamma_2 = 0$ e $\gamma_3 = -\gamma_1 = 2,5A$:

$$\begin{aligned} P_e &= P_1P(\text{erro}|s_1) + P_2P(\text{erro}|s_2) + P_3P(\text{erro}|s_3) + P_4P(\text{erro}|s_4) = \\ &= \frac{1}{8}Q\left(\frac{\gamma_1 + 3A}{\sigma}\right) + 2 \times \frac{3}{8} \left[Q\left(\frac{A}{\sigma}\right) + Q\left(\frac{\gamma_3 - A}{\sigma}\right) \right] + \frac{1}{8}Q\left(\frac{3A - \gamma_3}{\sigma}\right) = \\ &= \frac{1}{4}Q\left(\frac{A}{2\sigma}\right) + \frac{3}{4} \left[Q\left(\frac{A}{\sigma}\right) + Q\left(\frac{3A}{2\sigma}\right) \right] = \\ &\approx 0,12 \end{aligned}$$

A escolha de outros limiares de decis o conduzir  a uma probabilidade de erro superior a esta.

