



TRATAMIENTO DIGITAL DE SEÑALES

Ingeniería de Telecomunicación (4º, 2º c)

Unidad 9ª: Búsqueda

Aníbal R. Figueiras Vidal
Jesús Cid Sueiro
Ángel Navia Vázquez


Área de Teoría de la Señal y Comunicaciones
Universidad Carlos III de Madrid

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
LLAMA O ENVÍA WHATSAPP: 689 45 44 70

ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
CALL OR WHATSAPP:689 45 44 70

da. Tipos de Búsqueda

Como ya ha visto que, en la aproximación máquina, se trata de minimizar un costo definido a partir de las salidas deseadas, $d^{(k)}$, y las que proporciona la red, $o^{(k)} = F_w(\mathbf{x}^{(k)})$ (u $o^{(k)} = f_w(\mathbf{x}^{(k)})$), acumulando sus valores según k ; en general, una forma C_w , cuya variación con w es arbitraria:



El objetivo es buscar el mínimo absoluto, o, en su defecto, uno relativo aceptable.

ATSC-DTC/UCIIM

Cartagena99

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP:689 45 44 70

No siempre es posible obtener una solución cerrada (como en el caso de optimización lineal, p. ej.): en cuyo caso hay que recurrir a aplicar un algoritmo de optimización que encuentre el mínimo de la función objetivo.

Además, incluso cuando sea accesible una solución cerrada, puede interesar realizar una búsqueda para conseguir generalización: ya que la minimización sobre un conjunto de muestras no equivale a la minimización para todo el espacio de parámetros, y puede producirse sobreajuste; lo que debe evitarse:

Regularizando la solución;

Controlando un **coste** adecuado;

Deteniendo el entrenamiento hasta un cierto límite: lo que es posible, p.ej., mediante la detención de un **algoritmo iterativo** de búsqueda.

INFORMACIÓN DE CONTACTO: ATSC-DTC/UCHIM




CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70
 --
 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP:689 45 44 70

En algoritmo iterativo va modificando (por pasos) w con objeto de C_w : si se dividen las muestras disponibles en dos conjuntos:

Entrenamiento: con cuyos elementos se hace la búsqueda;

Retención (o validación): que simplemente se usa para ir midiendo C_w

Normalmente, el 80% y 20% de las muestras, respectivamente), se puede observar que, antes de llegar al mínimo coste en el conjunto de entrenamiento, el coste de validación (al perder capacidad de generalización): ahí se puede observar la búsqueda



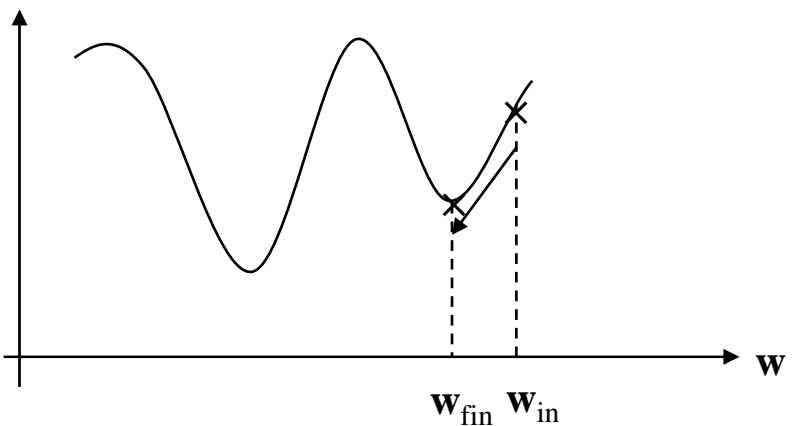
ATSC-DTC/UCIIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70

Hay dos tipos de métodos de búsqueda:

Locales: con los que se puede acceder a un mínimo relativo, a partir del punto en que se inicialice el algoritmo, que minimiza paso a paso el coste; con lo que sólo es posible llegar al mínimo que se encuentre en la cuenca de atracción del punto inicial



Globales: que persiguen alcanzar el mínimo absoluto.

ATSC-DTC/UCIIM

Cartagena99

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP:689 45 44 70

Los métodos de búsqueda globales son, como es fácil comprender, sencillos, delicados y lentos: computacionalmente muy costosos; por lo que solo se aplican en casos en que merezca la pena perseguir el mínimo absoluto (aunque, si basta un buen mínimo relativo, suele ser suficiente repetir búsquedas con distintas inicializaciones y seleccionar la mejor solución). Tienen procedimientos muy distintos: pero todos incluyen un mecanismo de **exploración** del espacio de soluciones (**w**) y uno de **explotación** de los resultados favorables a la exploración.

ATSC-DTC/UCHIM



CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

--

ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70



da local

oritmos de gradiente

trabajase mediante procedimientos analíticos, es decir, conociendo $\bar{C}(\mathbf{w})$ (el valor medio, que incluye la promediación sobre todo el espacio muestral), y $\nabla_{\mathbf{w}} \bar{C}(\mathbf{w})$ es su gradiente, está claro que proceder de la forma

$$\mathbf{w}^{\text{nuevo}} = \mathbf{w}^{\text{ant}} - \eta \mathbf{g}(\mathbf{w}^{\text{ant}}) \quad (\eta > 0)$$

irá a un mínimo local, si η es suficientemente pequeño.

Este procedimiento se conoce como **algoritmo del descenso más pendiente** (“steepest descent”): requiere conocer $\bar{C}(\mathbf{w})$, lo que no es habitual.

ATSC-DTC/UCHIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70

En situaciones muestrales, se puede trabajar con el coste para las muestras; aunque puede procederse para la totalidad (o subconjuntos del total), es más eficiente y recomendable hacerlo secuencialmente (muestra a muestra: una vez por cada muestra o éstas tantas veces como se precise, y extendiendo de este modo $\{k\}$):

$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} - \eta \mathbf{g}^{(k)}(\mathbf{w}^{(k)})$$

Este es el **algoritmo (secuencial) de gradiente**. En esta regla, $\mathbf{g}^{(k)}$ es el vector del gradiente del coste evaluado para la k -ésima muestra.

(Nótese que es adaptativo si k es el tiempo).

Discutiremos su comportamiento en media, sustituyendo $\mathbf{g}^{(k)}$ por \mathbf{g} : pero conviene aclarar que al coste mínimo teórico se añadirá un **error de desajuste** debido al efecto del muestreo.

ATSC-DTC/UCIIM



CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70

En las cercanías del mínimo buscado, \mathbf{w}_0 , se podrá escribir:

$$C(\mathbf{w}) = C(\mathbf{w}_0) + (\mathbf{w} - \mathbf{w}_0)^T \mathbf{g}(\mathbf{w}_0) + \frac{1}{2} (\mathbf{w} - \mathbf{w}_0)^T \mathbf{H}_w(\mathbf{w}_0) (\mathbf{w} - \mathbf{w}_0)$$

\mathbf{H}_w la matriz hessiana de $C(\mathbf{w})$

$$H_w]_{i_1 i_2} = \frac{\partial^2 C(\mathbf{w})}{\partial w_{i_1} \partial w_{i_2}}$$

Si \mathbf{w}_0 es un mínimo (local), el segundo término de la derecha es nulo; descomponiendo $\mathbf{H}_w(\mathbf{w}_0)$ en sus vectores propios

$$\mathbf{H}_w(\mathbf{w}_0) \mathbf{v}_i = \lambda_i \mathbf{v}_i$$

Definiendo

$$\mathbf{w} - \mathbf{w}_0 = \sum_i \alpha_i \mathbf{v}_i$$

$$C(\mathbf{w}) = C(\mathbf{w}_0) + \frac{1}{2} \left(\sum_i \alpha_i \mathbf{v}_i \right)^T \mathbf{H}_w(\mathbf{w}_0) \left(\sum_i \alpha_i \mathbf{v}_i \right) = C(\mathbf{w}_0) + \frac{1}{2} \sum_i \lambda_i \alpha_i^2$$

\mathbf{w}_0 es un mínimo si $\mathbf{H}_w(\mathbf{w}_0)$ es definida positiva: $\lambda_i > 0, \forall i$

ATSC-DTC/UCHIM

Cartagena99

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70
 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70

ando ahora gradientes sobre

$$C(\mathbf{w}) = C(\mathbf{w}_0) + \frac{1}{2}(\mathbf{w} - \mathbf{w}_0)^T H_{\mathbf{w}}(\mathbf{w}_0)(\mathbf{w} - \mathbf{w}_0)$$

$$\mathbf{g}(\mathbf{w}) = H_{\mathbf{w}}(\mathbf{w}_0)(\mathbf{w} - \mathbf{w}_0) = \sum_i \lambda_i \alpha_i \mathbf{v}_i$$

que el algoritmo $(\mathbf{w}^{\text{nuevo}} = \mathbf{w}^{\text{ant}} - \eta \mathbf{g}(\mathbf{w}^{\text{ant}}))$ resulta

$$\sum_i \alpha_i^{\text{nueva}} \mathbf{v}_i = \sum_i \alpha_i^{\text{ant}} \mathbf{v}_i - \eta \sum_i \lambda_i \alpha_i^{\text{ant}} \mathbf{v}_i$$

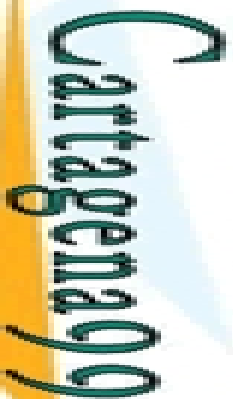
do los vectores propios linealmente independientes,

$$\alpha_i^{\text{nueva}} = (1 - \eta \lambda_i) \alpha_i^{\text{ant}}$$

para la correspondiente \mathbf{v}_i , la búsqueda empieza en un cierto punto $\alpha_i^{(0)}$ una progresión geométrica de razón $1 - \eta \lambda_i$; que converge si

$$|1 - \eta \lambda_i| < 1 : \quad \eta < 2/\lambda_i \quad (< 2/\lambda_{\text{max}})$$

ATSC-DTC/UCHIM



CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70

Nótese que la convergencia de la sucesión de \mathbf{v}_i es lo más rápida posible $\eta=1/\lambda_i$. Sin embargo, ésta puede ser una mala elección para otras λ_i diferentes.

Ejercicio:

Definiendo la velocidad de convergencia como

$$v_\eta = \min_i \left| \frac{1}{1 - \eta\lambda_i} \right|$$

entre que el valor de η que maximiza v_η es

$$\eta_{\text{opt}} = \arg \left\{ \max_\eta \{v_\eta\} \right\} = \frac{2}{\lambda_{\min} + \lambda_{\max}}$$

La velocidad no es el único factor a tener en cuenta en la elección del η . En general, cuanto mayor sea η , mayor será el **error de desajuste** debido a cada muestra a muestra.

ATSC-DTC/UCIIM



CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP:689 45 44 70

caso de coste cuadrático y estimador lineal:

$$C(\mathbf{w}) = \frac{1}{2} E\left\{ (s - \mathbf{w}^T \mathbf{x})^2 \right\}$$

$$\frac{\partial C}{\partial w_i} = -E\left\{ (s - \mathbf{w}^T \mathbf{x}) x_i \right\}$$

$$\frac{\partial^2 C}{\partial w_i \partial w_j} = E\left\{ x_i x_j \right\}$$

iano es la matriz de autocorrelación R_{xx} ; y el algoritmo secuencial de
te


$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} + \eta \left(s^{(k)} - \mathbf{w}^{(k)T} \mathbf{x}^{(k)} \right) \mathbf{x}^{(k)}$$

conoce como **LMS** (“Least Mean Squares”) o de **Widrow-Hoff**: muy
temente aplicado para tiempo discreto k , y del que hay que destacar su
z y su notable capacidad de seguimiento en casos no estacionarios.

ATSC-DTC/UCHIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
LLAMA O ENVÍA WHATSAPP: 689 45 44 70
--
ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
CALL OR WHATSAPP:689 45 44 70

La principal debilidad de estos algoritmos radica en su ineficiencia. El H tiene autovalores muy dispersos (recuérdese la discusión de la convergencia): lo que ocurre entonces es que la superficie del coste en el espacio del mínimo tiene aspecto fuertemente hiperelíptico, y los sucesivos pasos implican una ineficaz búsqueda en “zig-zag”.



Se necesitan técnicas para evitar este inconveniente de los algoritmos de gradiente.

ATSC-DTC/UCHIM

Cartagena99

--

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
LLAMA O ENVÍA WHATSAPP: 689 45 44 70

ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
CALL OR WHATSAPP: 689 45 44 70

Hay muchas variantes de estos algoritmos para evitar (otras) opciones: p. ej., para acelerar la búsqueda cuando se atraviesa una zona de $C(\mathbf{w})$

Se puede aplicar el **algoritmo del momento**

$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} - \eta \mathbf{g}^{(k)}(\mathbf{w}^{(k)}) + \beta [\mathbf{w}^{(k)} - \mathbf{w}^{(k-1)}]$$

donde el último término proporciona “inercia” a la actualización de los parámetros

Se puede realizar gestión del escalón: aumentándolo suavemente cuando el error va decreciendo, y reduciéndolo rápidamente si el error crece

Estudiar y aplicar algoritmos de gestión del escalón.

ATSC-DTC/UCHIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP:689 45 44 70

También es popular el **algoritmo NLMS** (“Normalized LMS”), en el que se elimina la dependencia del tamaño de las muestras utilizando como escalón

$\frac{1}{\epsilon + \|\mathbf{x}^{(k)}\|_2^2}$ (ϵ evita problemas numéricos)

$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} + \frac{1}{\epsilon + \|\mathbf{x}^{(k)}\|_2^2} \left(s^{(k)} - \mathbf{w}^{(k)T} \mathbf{x}^{(k)} \right) \mathbf{x}^{(k)}$$

que se satisface “naturalmente” la condición de convergencia, ya que

$\lambda_{\max} < 2$, y $\|\mathbf{x}^{(k)}\|_2^2$ es la traza muestral).

ATSC-DTC/UCHIM

Cartagena99

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP:689 45 44 70

es de otras búsquedas locales

queda en línea

de una dirección de búsqueda $\mathbf{d}^{(k)}$, y se aplica

$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} + \eta^{(k)} \mathbf{d}^{(k)}$$

do $\eta^{(k)}$ para la máxima reducción del coste

$$\begin{aligned} \frac{\partial C(\mathbf{w}^{(k+1)})}{\partial \eta^{(k)}} &= \left[\frac{\partial C(\mathbf{w}^{(k+1)})}{\partial \mathbf{w}^{(k+1)}} \right]^T \frac{\partial \mathbf{w}^{(k+1)}}{\partial \eta^{(k)}} = \mathbf{g}^T(\mathbf{w}^{(k+1)}) \frac{\partial (\mathbf{w}^{(k)} + \eta^{(k)} \mathbf{d}^{(k)})}{\partial \eta^{(k)}} = \\ &= \mathbf{g}^T(\mathbf{w}^{(k+1)}) \mathbf{d}^{(k)} = 0 \end{aligned}$$

ndose así los **algoritmos de descenso más rápido**.


En la práctica, $\eta^{(k)}$ se determina minimizando $C(\mathbf{w}^{(k)} + \eta^{(k)} \mathbf{d}^{(k)})$ por cada dirección unidimensional.

ATSC-DTC/UCHIM

Cartagena99

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70
 --
 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70

La condición $\mathbf{g}^T(\mathbf{w}^{(k+1)})\mathbf{d}^{(k)} = 0$ implica que, en el punto de destino, la dirección de búsqueda es siempre tangente a la curva de nivel:



Cómo determinar la dirección de búsqueda?

Obsérvese cómo al elegir $\mathbf{d}^{(k)} = -\mathbf{g}(\mathbf{w}^{(k)})$, los gradientes consecutivos son ortogonales, lo que suele llevar a búsqueda en zig-zag.


ATSC-DTC/UCHIM

Cartagena99

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP:689 45 44 70

sin embargo, nótese también que, admitiendo forma del coste de 2º en cualquier punto situado en la dirección óptima, \mathbf{d}^* , el gradiente es la dirección de búsqueda anterior.



lo anterior puede imponerse como condición: elíjase $\mathbf{d}^{(k+1)}$ de tal modo

$$\mathbf{g}^T(\mathbf{w}^{(k+2)})\mathbf{d}^{(k)} = 0$$

el fundamento de los algoritmos de gradiente conjugado.

ATSC-DTC/UCIIM



CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP:689 45 44 70

Algoritmos de gradiente conjugado

Las búsquedas en línea (óptimas) en que se eligen las $\mathbf{d}^{(k)}$ de modo que no se repite lo progresado en pasos anteriores: concretamente, obligando en cada paso a que el gradiente en el destino sea ortogonal a la dirección de búsqueda previa

$$\mathbf{d}^{(k)T} \mathbf{g}(\mathbf{w}^{(k+2)}) = \mathbf{g}^T(\mathbf{w}^{(k+1)} + \eta^{(k+1)} \mathbf{d}^{(k+1)}) \mathbf{d}^{(k)} = 0$$

de, admitiendo forma de 2º orden:

$$\begin{aligned} \mathbf{g}(\mathbf{w}^{(k+2)}) &= \mathbf{H}_w(\mathbf{w}_0) (\mathbf{w}^{(k+2)} - \mathbf{w}_0) = \\ &= \mathbf{H}_w(\mathbf{w}_0) (\mathbf{w}^{(k+1)} + \eta^{(k+1)} \mathbf{d}^{(k+1)} - \mathbf{w}_0) = \\ &= \mathbf{H}_w(\mathbf{w}_0) (\mathbf{w}^{(k+1)} - \mathbf{w}_0) + \eta^{(k+1)} \mathbf{H}_w(\mathbf{w}_0) \mathbf{d}^{(k+1)} = \\ &= \mathbf{g}(\mathbf{w}^{(k+1)}) + \eta^{(k+1)} \mathbf{H}_w(\mathbf{w}_0) \mathbf{d}^{(k+1)} \end{aligned}$$

de modo que la condición queda

$$\mathbf{d}^{(k)T} \mathbf{g}(\mathbf{w}^{(k+2)}) = \mathbf{d}^{(k)T} \mathbf{g}(\mathbf{w}^{(k+1)}) + \eta^{(k+1)} \mathbf{d}^{(k)T} \mathbf{H}_w(\mathbf{w}_0) \mathbf{d}^{(k+1)} = 0$$

de modo que el primer sumando del segundo miembro,

ATSC-DTC/UCIIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70
 --
 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70

$$\mathbf{d}^{(k)T} \mathbf{H}_w(\mathbf{w}_0) \mathbf{d}^{(k+1)} = 0$$

la condición de conjugación. Si se aplica consecutivamente en un espacio de dimensión P (nº de parámetros) bajo la hipótesis de superficie de 2º orden, se da lugar a P direcciones conjugadas que permiten resolver el problema de mínimos cuadrados (no es así si la superficie no es de 2º orden).

Las formas prácticas de estos algoritmos se obtienen de aplicar la condición de conjugación a

$$\mathbf{d}^{(k+1)} = -\mathbf{g}(\mathbf{w}^{(k+1)}) + \beta^{(k)} \mathbf{d}^{(k)}$$

Introduciendo en $\mathbf{d}^{(k+1)T} \mathbf{H}_w(\mathbf{w}_0) \mathbf{d}^{(k)} = 0$, se puede despejar

$$\beta^{(k)} = \frac{\mathbf{g}(\mathbf{w}^{(k+1)})^T \mathbf{H}_w(\mathbf{w}_0) \mathbf{d}^{(k)}}{\mathbf{d}^{(k)T} \mathbf{H}_w(\mathbf{w}_0) \mathbf{d}^{(k)}}$$

ATSC-DTC/UCHIM

Cartagena99

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70

Obviamente, $\beta^{(k)}$ no se puede obtener de esta expresión teórica, ya que no se conoce $H_w(\mathbf{w}_0)$:

Se sustituye $H_w(\mathbf{w}_0)\mathbf{d}^{(k)}$ por $[\mathbf{g}(\mathbf{w}^{(k+1)}) - \mathbf{g}(\mathbf{w}^{(k)})]/\eta^{(k)}$

La igualdad que se obtiene de la expresión de $\mathbf{g}(\mathbf{w}^{(k+2)})$ en la p. 9.18, cambiando $k+2$ por $k+1$, se llega al **algoritmo de Hestenes-Stiefel**

$$\beta_{\text{HS}}^{(k)} = \frac{\mathbf{g}^T(\mathbf{w}^{(k+1)})[\mathbf{g}(\mathbf{w}^{(k+1)}) - \mathbf{g}(\mathbf{w}^{(k)})]}{\mathbf{d}^{(k)T}[\mathbf{g}(\mathbf{w}^{(k+1)}) - \mathbf{g}(\mathbf{w}^{(k)})]}$$

Ahora se considera la expresión de $\mathbf{d}^{(k+1)}$ en la p. 9.19, se traspone y se multiplican por $\mathbf{g}(\mathbf{w}^{(k+1)})$ ambos términos, se tiene:

$$\mathbf{d}^{(k+1)T} \mathbf{g}(\mathbf{w}^{(k+1)}) = -\mathbf{g}^T(\mathbf{w}^{(k+1)}) \mathbf{g}(\mathbf{w}^{(k+1)}) + \beta^{(k)} \mathbf{d}^{(k)T} \mathbf{g}(\mathbf{w}^{(k+1)})$$

Como el segundo sumando del término de la derecha es nulo (por descenso más rápido), se deduce cambiando $k+1$ por k :

$$\mathbf{d}^{(k)T} \mathbf{g}(\mathbf{w}^{(k)}) = -\mathbf{g}^T(\mathbf{w}^{(k)}) \mathbf{g}(\mathbf{w}^{(k)})$$

ATSC-DTC/UCIIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70
 --
 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70

e, llevada al denominador de $\beta_{HS}^{(k)}$, considerando además que $\mathbf{g}^T(\mathbf{w}^{(k+1)})=0$, proporciona el **algoritmo de Polak-Ribiere**

$$\beta_{PL}^{(k)} = \frac{\mathbf{g}^T(\mathbf{w}^{(k+1)})[\mathbf{g}(\mathbf{w}^{(k+1)}) - \mathbf{g}(\mathbf{w}^{(k)})]}{\mathbf{g}^T(\mathbf{w}^{(k)})\mathbf{g}(\mathbf{w}^{(k)})}$$

Por último, si de la condición de descenso más rápido de la p. 9.15

$$\mathbf{g}^T(\mathbf{w}^{(k+1)})\mathbf{d}^{(k)} = 0$$

se inserta la expresión de $\mathbf{d}^{(k)}$ de la p. 9.19, se tiene

$$\mathbf{g}^T(\mathbf{w}^{(k+1)})[-\mathbf{g}(\mathbf{w}^{(k)}) + \beta^{(k-1)}\mathbf{d}^{(k-1)}] = 0$$

donde

$$-\mathbf{g}^T(\mathbf{w}^{(k+1)})\mathbf{g}(\mathbf{w}^{(k)}) + \beta^{(k-1)}\mathbf{g}^T(\mathbf{w}^{(k+1)})\mathbf{d}^{(k-1)} = 0$$

ATSC-DTC/UCHIM



CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70
 --
 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70

lo que, como es nulo el segundo sumando del primer término, lo es el primero: eliminándolo en el numerador de $\beta_{PL}^{(k)}$, queda establecido el

algoritmo de Fletcher-Reeves:

$$\beta_{FR}^{(k)} = \frac{\mathbf{g}^T(\mathbf{w}^{(k+1)})\mathbf{g}(\mathbf{w}^{(k+1)})}{\mathbf{g}^T(\mathbf{w}^{(k)})\mathbf{g}(\mathbf{w}^{(k)})}$$

Estos algoritmos

son más eficaces si la aproximación cuadrática es razonable: si no, pueden ser inferiores que uno de gradiente;

deben “reinicializarse” (mediante gradiente) cada cierto número de pasos, para evitar los efectos de acumulación de errores.

ATSC-DTC/UCHIM



CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70
 --
 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70

El Método de Newton

Supuesto que nos encontramos en \mathbf{w}^* y que es aceptable

$$C(\mathbf{w}) = C(\mathbf{w}^*) + (\mathbf{w} - \mathbf{w}^*)^T \mathbf{g}(\mathbf{w}^*) + \frac{1}{2} (\mathbf{w} - \mathbf{w}^*)^T \mathbf{H}_{\mathbf{w}}(\mathbf{w}^*) (\mathbf{w} - \mathbf{w}^*)$$

o gradientes

$$\mathbf{g}(\mathbf{w}) = \mathbf{g}(\mathbf{w}^*) + \mathbf{H}_{\mathbf{w}}(\mathbf{w}^*) (\mathbf{w} - \mathbf{w}^*)$$

á nulo si \mathbf{w} es el mínimo buscado; de donde

$$\mathbf{w} = \mathbf{w}^* - \mathbf{H}_{\mathbf{w}}^{-1}(\mathbf{w}^*) \mathbf{g}(\mathbf{w}^*)$$

plicación de forma iterada

$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} - \mathbf{H}_{\mathbf{w}}^{-1}(\mathbf{w}^{(k)}) \mathbf{g}(\mathbf{w}^{(k)})$$

goritmo correspondiente a este método.

ATSC-DTC/UCIIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70



No se aplica directamente por la carga que supone
 calcular H_w en cada paso
 invertir la matriz

En su lugar se utilizan

los métodos Seudo-Newton: reduciendo H_w a sus términos diagonales
 haciendo positivos los negativos; añadiendo una cte. ε para evitar
 inestabilidades numéricas)

los métodos Quasi-Newton: basados en aproximar iterativamente H_w^{-1}
 imponiendo la “condición Quasi-Newton”

$$\mathbf{w}^{(k+1)} - \mathbf{w}^{(k)} = H_w^{-1}(\mathbf{w}^{(k)}) \left[\mathbf{g}(\mathbf{w}^{(k+1)}) - \mathbf{g}(\mathbf{w}^{(k)}) \right]$$

discutir los métodos *Q-N*

de Davidson-Fletcher-Powell (DFP)

de Broyden-Fletcher-Goldfarb-Shanno (BFGS)

ATSC-DTC/UCIIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70



Aprendizaje de Boltzmann

cializar w

cializar la temperatura T a T_0 (valor alto)

licar un observable al azar y obtener C

egir un parámetro al azar y modificarlo (según $G(0, T^2/2\pi)$, p. ej.)

eniendo $C+\Delta C$

$\Delta C < 0$: aceptar el cambio

$\Delta C > 0$ y $\exp(-\Delta C/T) > U[0,1]$: aceptar el cambio

$\Delta C > 0$ y $\exp(-\Delta C/T) < U[0,1]$: no aceptarlo

olver a 4 hasta agotar los parámetros

olver a 3 hasta agotar los observables

licar un criterio de parada:

si se cumple, terminar

si no, reducir la temperatura según $T(l)=T_0/\ln(1+l)$, y volver a 3

Métodos de aceleración del Aprendizaje de Boltzmann

ATSC-DTC/UCIIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP:689 45 44 70



Algoritmos Genéticos

Propuestos por Holland a mediados de los 70, son búsquedas Neodarwinianas, con exploración por **cruce** y **mutación** sobre poblaciones de datos a la solución, y explotación mediante selección para **supervivencia**.

Algoritmo Genético Básico (AGB)

Los componentes de la solución (w) se expresan en binario)

Inicialización:

Construir una población inicial aleatoria de tiras binarias

Evaluación: aplicar una medida de calidad: ajuste (“fitness”) a un objetivo

Selección: aplicar un criterio de parada; si no se cumple

Reproducción: generar una nueva población, sorteando el paso de los individuos de acuerdo con su calidad

Cruce: tomar aleatoriamente dos individuos, cortarlos por un punto (mismo) aleatorio, y cruzar los trozos

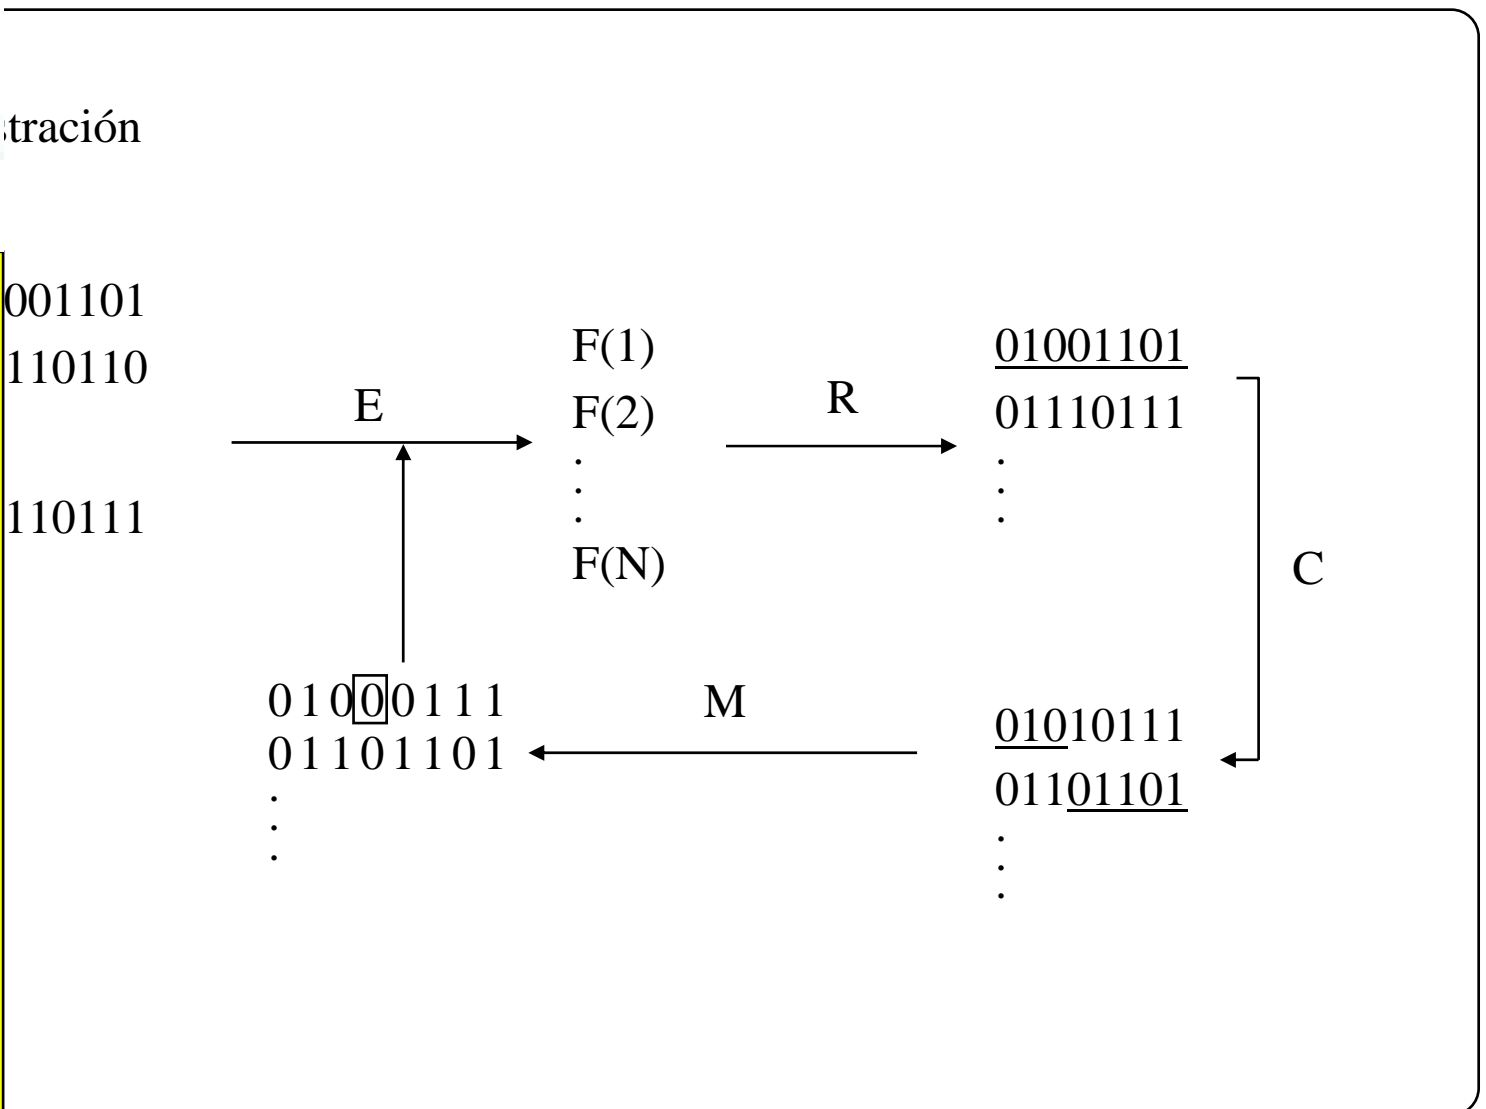
Reemplazo: por sorteo (de baja probabilidad) para cada bit de la población

Revertir a 2

Reproducción, cruce, mutación: operadores)

ATSC-DTC/UCIIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70
 --
 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70



ATSC-DTC/UCHIM



CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP:689 45 44 70



Formatos típicos:

Tamaño de la población: alrededor de 50 individuos

Tasa de cruce: 0.6 - 0.8

Tasa de mutación: 10^{-2} - 10^{-3}

Longitud de los individuos: hasta varios cientos


Con estas características, el algoritmo busca una solución global, avanzando (con oscilaciones) hacia mejores valores de calidad tanto del mejor individuo como en media para la población.

Los algoritmos tienen gran potencia de búsqueda.

ATSC-DTC/UCHIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70



Características de los AG

Restricciones

Problemas: no es fácil incorporar información previa

Es difícil introducir restricciones sobre las soluciones: se suele hacer aplicando heurísticas que las mantengan diversas

Alta gran carga computacional, debido a la evaluación de cada solución

La optimización directa no ofrece generalización, al calcular directamente la función de aptitud

Conduce al estancamiento

Hay pérdida de variedad “genética” (en los bits homólogos de todos los individuos), que imposibilita la exploración;

Esto se puede corregir: por aumento de la mutación o por renovación de parte de la población

ATSC-DTC/UCIIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP:689 45 44 70

... aparición de un superindividuo (muy bueno para su generación, pero como solución final): que tiende a ocupar toda la población por su ventaja en la reproducción;

... combate: equilibrando la reproducción; p. ej., procediendo según rango la evaluación, y no de modo directamente proporcional a la calidad.


... En este tipo de precaución, se pueden aplicar estrategias elitistas, pasando el mejor individuo de cada generación directamente a la siguiente, para evitar pérdidas de difícil reparación)

... ATSC-DTC/UCHIM



CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP: 689 45 44 70



en capacidad de seguimiento.

ueden combinarse con búsquedas locales (que, además, serán vía para generalización), según principios

marckistas: se heredan los resultados;

ldwinianas: no se hereda la búsqueda local, pero se emplea en la evaluación.

B es de aplicación limitada por la codificación binaria: la codificación requiere otros operadores para cruce (incluyendo fragmentación de cada n) y mutación.

ATSC-DTC/UCIIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
LLAMA O ENVÍA WHATSAPP: 689 45 44 70
--
ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
CALL OR WHATSAPP:689 45 44 70



SI

(dicha potencia de búsqueda)

quieren formulación analítica: la evaluación puede llevarse a cabo a través de la aplicación directa de las soluciones al problema (p. ej., haciendo uso de las estrategias que se diseñen para un juego)

Se pueden introducirse muchos otros operadores de búsqueda “ad hoc” para el problema; así como codificaciones diferentes de las tiras de bits

ATSC-DTC/UCHIM

CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP:689 45 44 70

Los métodos de búsqueda global son:

Los estrategias evolutivas

Los búsqueda “Tabú”

Los algoritmos “branch and bound”

Describese su aplicación y discútanse sus principales características.

ATSC-DTC/UCHIM



CLASES PARTICULARES, TUTORÍAS TÉCNICAS ONLINE
 LLAMA O ENVÍA WHATSAPP: 689 45 44 70

 ONLINE PRIVATE LESSONS FOR SCIENCE STUDENTS
 CALL OR WHATSAPP:689 45 44 70