



# Clasificación con costes funcionales: soluciones fundamentadas

Aníbal R. Figueiras Vidal  
AN, RAIng  
et al.

---

# Contenido



1. Problemas singulares
2. Clasificación con costes dependientes de la muestra
3. Solución en dos pasos
4. Un ejemplo de aplicación
5. Generalizaciones y extensiones
6. Agradecimientos



# 1. Problemas singulares

En clasificación (toma de decisiones, test de hipótesis...)

- Desequilibrados
- Con costes dependientes de la muestra
- Ordinales
- Multitarea/multietiqueta
- ...

Son frecuentes e importantes

Las DLMs convencionales dan malos resultados

Las modificaciones no fundamentadas encierran riesgos



## 2. Clasificación con costes dependientes del ejemplo

En Negocio y Finanzas:

- detección de fraudes
- calificación de créditos
- marketing personalizado
- gestión de la rotación de clientes
- predicción de quiebras
- ...

También en Salud, Seguridad...

No puede resolverse de modo fundamentado mediante  
modificación directa del coste subrogado

(sí con modificación Bayesiana, pero aprendiendo costes;  
sí con algoritmos Bayes-Parzen)



### 3. Solución en dos pasos (1)

(Para binarios)

Según Bayes:

$$j^* = \arg \min_j \left\{ \sum_i c_{ji}(\mathbf{x}) \Pr(C_i|\mathbf{x}) \right\}$$

de modo que basta  $\widehat{\Pr}(C_1|\mathbf{x})$ .

Para obtenerla: entrenamiento con divergencia de Bregman

$$\frac{\partial c_B(t, o)}{\partial o} = -g(o)(t - o)$$

como coste subrogado.

$$\text{Con } t = \pm 1: \quad \widehat{\Pr}(C_1|\mathbf{x}) = \frac{1 + o(\mathbf{x})}{2}$$



### 3. Solución en dos pasos (2)

De ese modo

– Paso 1:  $\widehat{\Pr}(C_1|\mathbf{x})$

– Paso 2:  $\hat{j}^* = \arg \min_j \left\{ \sum c_{ji}(\mathbf{x}) \widehat{\Pr}(C_i|\mathbf{x}) \right\}$

(permite evaluar política de costes;  
puede necesitar aprendizaje de costes)

---

Puede haber también desequilibrio muestral

⇒ Reequilibrado por invarianza del cociente de verosimilitudes:

a) Reequilibrado neutral:  $\widetilde{\Pr}(C_1|\mathbf{x})$

b) Recuperación de  $\widehat{\Pr}(C_1|\mathbf{x})$  vía  $\tilde{r}(\mathbf{x})$



### 3. Solución en dos pasos (3)

Proceso para b)

$$\widetilde{\text{Pr}}(C_1|\mathbf{x}) = \frac{p(\mathbf{x}|C_1)\tilde{P}_1}{p(\mathbf{x}|C_1)\tilde{P}_1 + p(\mathbf{x}|C_0)\tilde{P}_0} = \frac{1}{1 + \tilde{Q}_P/\tilde{r}(\mathbf{x})} \quad (\tilde{Q}_P = \tilde{P}_0/\tilde{P}_1)$$

$$\tilde{r}(\mathbf{x}) = \tilde{Q}_P \frac{\tilde{P}_r(C_1|\mathbf{x})}{1 - \tilde{P}_r(C_1|\mathbf{x})} \quad \left( = \tilde{Q}_P \frac{1 - o(\mathbf{x})}{1 + o(\mathbf{x})} \right) = \hat{r}(\mathbf{x}) \quad !$$

$$\Rightarrow \widehat{\text{Pr}}(C_1|\mathbf{x}) = \frac{1}{1 + \widehat{Q}_P/\tilde{r}(\mathbf{x})}$$

---

(puede trabajarse con  $\tilde{r}(\mathbf{x}) \stackrel{C_0}{\ll} Q_c(\mathbf{x}) \widehat{Q}_P$ )



## 4. Un ejemplo de aplicación

Problema: HMEQ (créditos vivienda),  $IB \simeq 4$

Ahorro (promedios en 100 particiones de media  $\pm$  desviación sobre 100 pases)

- Mejor de Bahnsen (Selva Aleat. + Riesgo Min.)  $75'2 \pm 1'8$
- Segundo de Bahnsen (Árbol de Decisión con Costes)  $65'7 \pm 0$
- Fundamentado 1 MLP subóptimo ( $RB \simeq 4$ , pond.)  $73'0 \pm 1'5$
- Fundamentado 1 MLP optimizado ( $RB = 1$ )  $75'3 \pm 1'6$
- Fundamentado 31 MLPs optimizado ( $RB = 3$ , 100% SMOTE)  $78'2 \pm 0'6$





---

## 5. Generalidades y extensiones

- G: – a problemas multiclase
  
- E: – a ordinales
- a multitarea/multietiqueta
- ...

Por esas vías, a diseños insesgados



## 6. Agradecimientos

A mi equipo de trabajo:

Dr. Marcelino Lázaro  
Dr. Francisco J. Glez. Serrano  
Dra. Lorena Álvarez  
Dr. Harold Molina  
Ing. Alexander Benítez  
Ing. Javier Mediavilla  
Ing. Aitor Gutiérrez  
Ing. Álvaro Callejas

y colaboradores externos:

Prof. Monson Hayes (GMU, USA)  
Prof. V. John Mathews (OrSU, USA)  
Dr. J.L. Sancho (UPCT)

A las entidades financiadoras: FBBVA

Teldat, S.A.

---

[anibalrfv@tsc.uc3m.es](mailto:anibalrfv@tsc.uc3m.es)