

# Thompson Sampling: Aplicaciones

Alvaro J. Riascos Villegas  
Universidad de los Andes y Quantil

Septiembre de 2024

# Contenido

## 1 Modelos Formales de Justicia Algorítmica

- Introducción
- Formalizacion

## 2 Justicia Calibrada

- Introducción
- Smooth fairness (subjetiva)
- Justicia Calibrada

## 3 Fair Stochastic Dominance Thompson Sampling

## 4 Aprendizaje Social

# Introducción

- Existen muchas definiciones formales de justicia algorítmica.
- Vamos a estudiar formalmente:
  - ① Paridad demográfica.
  - ② *Equalized odds*.
  - ③ Calibración y calibración condicional.
  - ④ Balance de clases positivas (igualdad de oportunidad).
  - ⑤ Balance de clases negativas.

- El grado, o evidencia de justicia puede depender de la medida cuantitativa que se use como definición de justicia.
- El siguiente ejemplo es uno de los principales que inicio y motivó mucho el interés en las implicaciones éticas de usar modelos de aprendizaje de máquinas para tomar decisiones en el ámbito público.

# El Caso de COMPAS

- COMPAS: Correctional Offender Management Profiling for Alternative Sanctions.

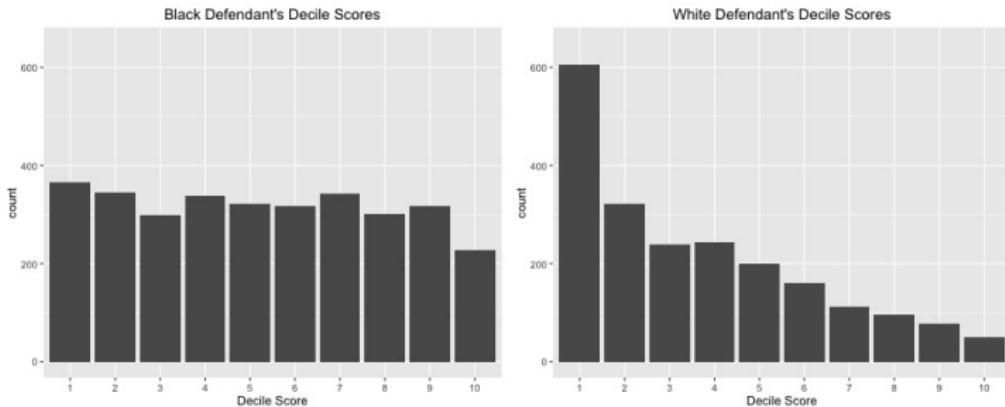


Figura: Histograma de los que no reincidieron

# El Caso de COMPAS

- ¿Qué explica el score de COMPAS?

Risk of General Recidivism Logistic Model	
	<i>Dependent variable:</i>
	Score (Low vs Medium and High)
Female	0.221*** (0.080)
Age: Greater than 45	-1.356*** (0.099)
Age: Less than 25	1.308*** (0.076)
Black	0.477*** (0.069)
Asian	-0.254 (0.478)
Hispanic	-0.428*** (0.128)
Native American	1.394* (0.766)
Other	-0.826*** (0.162)
Number of Priors	0.269*** (0.011)
Misdemeanor	-0.311*** (0.067)
Two year Recidivism	0.686*** (0.064)
Constant	-1.526*** (0.079)
Observations	6,172
Akaike Inf. Crit.	6,192.402

Note: \* $p<0.1$ ; \*\* $p<0.05$ ; \*\*\* $p<0.01$

Figura: Logit

- The accuracy, fairness, and limits of predicting recidivism.  
Julia Dressel and Hany Farid. 2018.
- El accuracy es 67 % y 63,8 % (aciertos positivos y negativos sobre el total de ejemplo) para blanco y negros respectivamente.
- Los negros que no reincidieron, COMPAS predice que en promedio van a reincidir con probabilidad 44,9 % mientras que el grupo análogo de blancos 23,5 %.
- Sin embargo COMPAS score satisface: predictive parity, AUC equity y calibration.
- Este estudio se concentra en entender si COMPAS realmente es más preciso o más sesgado que lo que un grupo de expertos haría: encuentran que no es mas accurate y que con solo 5 variables y un modelo lineal se puede tener la misma capacidad predictiva que COMPAS que usa 137 variables.

**Table 1. Human versus COMPAS algorithmic predictions from 1000 defendants.** Overall accuracy is specified as percent correct, AUC-ROC, and criterion sensitivity ( $d'$ ) and bias ( $\beta$ ). See also Fig. 1.

	(A) Human (no race)	(B) Human (race)	(C) COMPAS
Accuracy (overall)	67.0%	66.5%	65.2%
AUC-ROC (overall)	0.71	0.71	0.70
$d'/\beta$ (overall)	0.86/1.02	0.83/1.03	0.77/1.08
Accuracy (black)	68.2%	66.2%	64.9%
Accuracy (white)	67.6%	67.6%	65.7%
False positive (black)	37.1%	40.0%	40.4%
False positive (white)	27.2%	26.2%	25.4%
False negative (black)	29.2%	30.1%	30.9%
False negative (white)	40.3%	42.1%	47.9%

Figura: Humanos

# Formalización

- ①  $Y$  es una variable binaria que queremos predecir.
- ②  $\hat{Y}$  es la predicción.
- ③ La clase 1 se va considerar la decisión social preferida (otorgar un crédito, ser beneficiario de un programa social, etc.).
- ④  $X$  son las variables observadas de cada individuo.
- ⑤  $A$  es una variable binaria que representa la clase protegida (hombres, mujeres, blanco, negro, religioso, ateo, etc.)

## Definition

Decimos que un algoritmo satisface paridad demográfica si:

$$P(\hat{Y} = 1 | A) = P(\hat{Y} = 1) \quad (1)$$

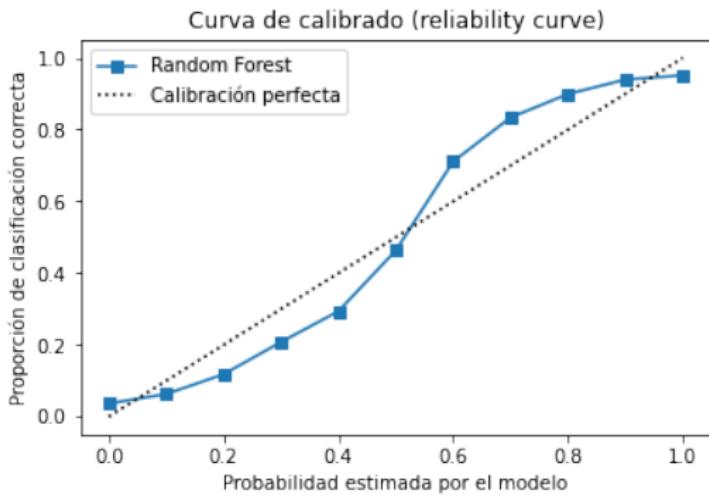
- Un modelo que le asigne la misma probabilidad a todos satisface la propiedad.

## Definition

Decimos que un algoritmo satisface la propiedad de calibración con respecto a la variable protegida si:

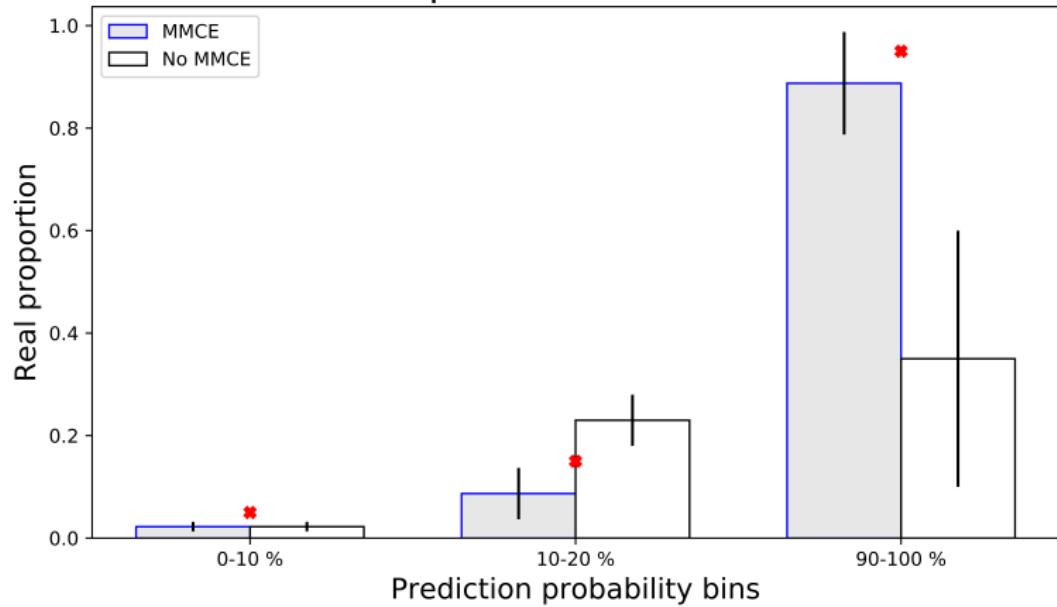
- ① El pronóstico está bien calibrado.
- ② Condicional a la variable protegida el pronóstico está bien calibrado.

# Calibración



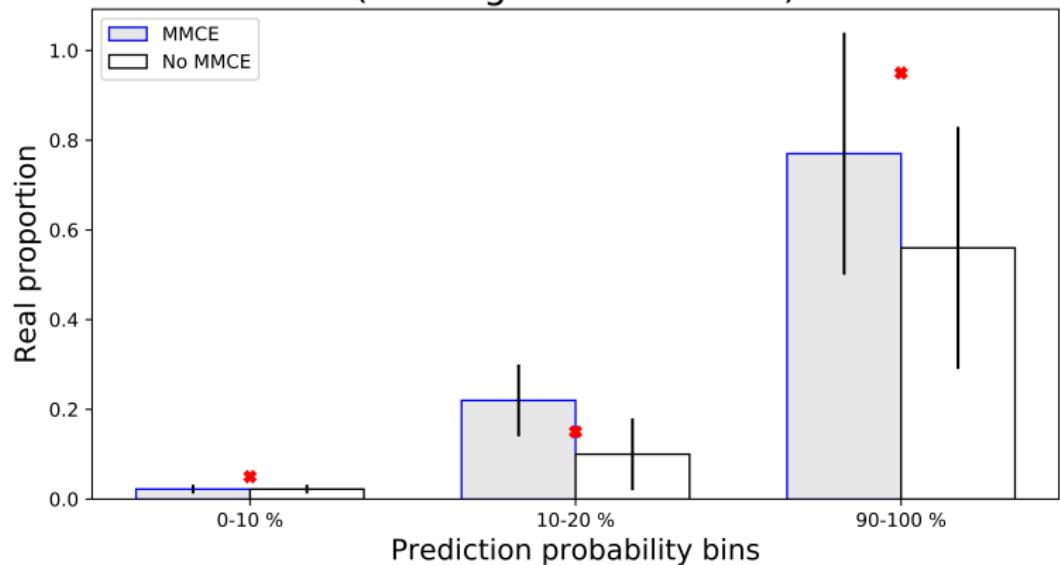
# Calibración: Ejemplo Predicción de Crimen

Spatial calibration



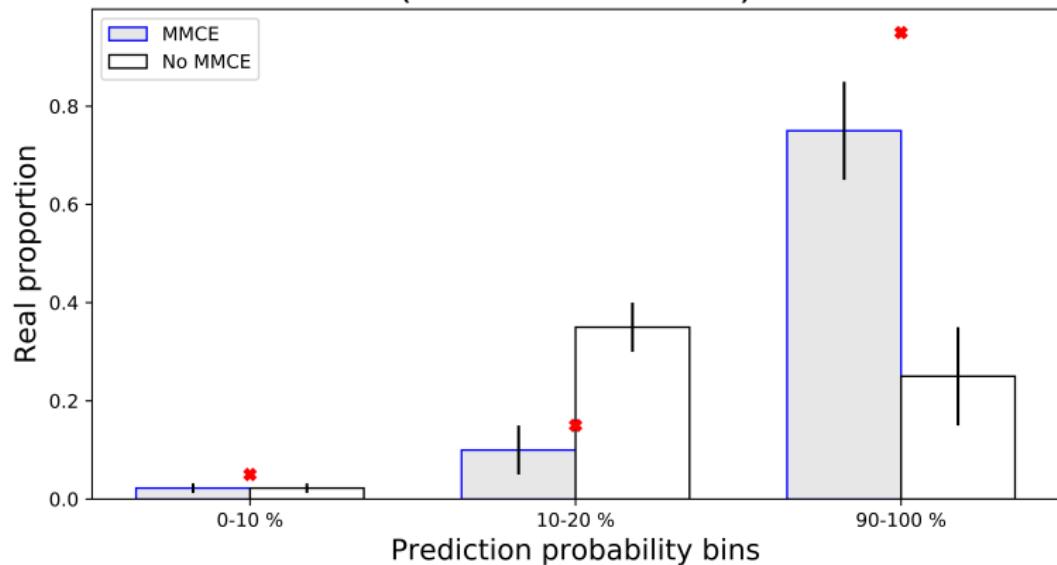
# Calibración: Ejemplo Predicción de Crimen

Spatial calibration  
(Mid-high income level)



# Calibración: Ejemplo Predicción de Crimen

Spatial calibration  
(Low income level)



## Definition

Decimos que un algoritmo satisface igualdad de oportunidad si:

$$P(\hat{Y} = 1 \mid Y = 1, A) = P(\hat{Y} = 1 \mid Y = 1) \quad (2)$$

## Definition

Decimos que un algoritmo satisface balance de clases negativas:

$$P(\hat{Y} = 1 \mid Y = 0, A) = P(\hat{Y} = 1 \mid Y = 0) \quad (3)$$

## Definition

Decimos que un algoritmo satisface igualdad de probabilidades si:

- ① Balance de clases positivas.
  - ② Balance de clases negativas.
- 
- Igualdad de probabilidades implica que la curva ROC es independiente de la variable protegida.

# Contenido

## 1 Modelos Formales de Justicia Algorítmica

- Introducción
- Formalizacion

## 2 Justicia Calibrada

- Introducción
- Smooth fairness (subjetiva)
- Justicia Calibrada

## 3 Fair Stochastic Dominance Thompson Sampling

## 4 Aprendizaje Social

# Introducción

- Calibrated Fairness in Bandits. 2017. Yang Liu and Goran Radanovic and Christos Dimitrakakis and Debmalya Mandal and David C. Parkes.
- Supongamos que estamos en presencia de un problema de Bandidos Multiarmados Estocásticos. La única diferencia con el modelo estudiado anteriormente es que en cada ronda  $t$  un agente debe elegir una distribución de probabilidad  $\pi$  sobre cada las armas.
- $\pi_t(k)$  es la probabilidad que elige el agente en esa ronda de elegir  $k$ .
- Si se elige  $k$ , la recompensa es aleatoria con distribución condicional a  $\theta_k$ :

$$R_t(k) \sim P(\cdot | \theta_k) \quad (4)$$

# Smooth fairness (subjetiva)

## Definition (Smooth fairness)

Una función de política en un problema de bandidos multiarmados es justa  $(\epsilon_1, \epsilon_2, \delta)$  con respecto a la divergencia  $D$ , con  $\epsilon_1 \geq 0, \epsilon_2 \geq 0, 0 \leq \delta \leq 1$ , y probabilidad mínimo  $1 - \delta$ , en cada ronda  $t$ , y para cada par de armas  $i$  and  $j$ :

$$D(\pi_t(i) \| \pi_t(j)) \leq \epsilon_1 D(r_i \| r_j) + \epsilon_2. \quad (5)$$

- La definición de *subjetive smooth fairness* es idéntica solo que se reemplaza  $D(r_i \| r_j)$  por la divergencia entre las distribuciones marginales de  $r_i, r_j$  con respecto a la posterior de los parámetros  $\theta$ .

# Arrepentimiento de la justicia

- Recordemos la definición de calibración. Decimos que la política  $\pi$  está bien calibrada si:

$$\pi(a) = P(a = \operatorname{argmax}_{j \in [k]} \{r_j\}) \quad (6)$$

## Example

Consider a bandits problem with two arms, whose respective reward functions are random variables with realization probabilities:

- $P(r_1 = 1) = 1,0$ ;
- $P(r_2 = 0) = 0,6$  and  $P(r_2 = 2) = 0,4$ .

Como  $E[r_1] = 1,0$  y  $E[r_2] = 0,8$ , un agente que conoce la distribución siempre va a elegir la arma 1 sobre la 2. Para un algoritmo que está aprendiendo mediante interacciones es difícil estar calibrado en todas las rondas.

- Como  $E[r_1] = 1,0$  y  $E[r_2] = 0,8$ , un agente que conoce la distribución siempre va a elegir la arma 1 sobre la 2.
- En contraste, justicia calibrada implica que la arma 1 debe seleccionarse el 60% de las veces.
- Para un algoritmo que está aprendiendo mediante interacciones es difícil estar calibrado en todas las rondas.

# Contenido

## 1 Modelos Formales de Justicia Algorítmica

- Introducción
- Formalización

## 2 Justicia Calibrada

- Introducción
- Smooth fairness (subjetiva)
- Justicia Calibrada

## 3 Fair Stochastic Dominance Thompson Sampling

## 4 Aprendizaje Social

---

### **Algorithm 1** (SD\_TS): Stoch.-Dom. Thompson sampling

---

For each action  $a \in \{1, 2, \dots, k\}$ , set  $S_a = F_a = 1/2$  (parameters for priors of Beta distributions).

**for**  $t = 1, 2, \dots$ , **do**

    For each action, sample  $\theta_a(t)$  from Beta( $S_a, F_a$ ).

    Draw  $\tilde{r}_a(t) \sim \text{Bernoulli}(\theta_a(t))$ ,  $\forall a$ .

    Play arm  $a_t := \text{argmax}_a \tilde{r}_a(t)$  (with random tie-breaking).

    Observe the true  $r_{a_t}(t)$ :

- If  $r_{a_t}(t) = 1$ ,  $S_{a_t} := S_{a_t} + 1$ ;
- else  $F_{a_t} := F_{a_t} + 1$ .

**end for**

---

## Definition (Fairness regret)

El fairness regret  $Regret_f$  de la política  $\pi$  en la ronda  $t$  es:

$$Regret_f(t) = E \left[ \sum_{i=1}^k \max(P(a = \operatorname{argmax}_{j \in [k]} \{r_j\}) - \pi_t(i), 0) \mid \theta \right].$$

El fairness regret acumulado se define como:

$$Regret_{f,T} = \sum_{t=1}^T Regret_f(t). \quad (7)$$

- Una modificación del algoritmo SD-TS denominada *Fair Stochastic Dominance Thompson Sampling* satisface smooth fairness subjetiva y se puede acotar el arrepentimiento de justicia.

# Contenido

## 1 Modelos Formales de Justicia Algorítmica

- Introducción
- Formalización

## 2 Justicia Calibrada

- Introducción
- Smooth fairness (subjetiva)
- Justicia Calibrada

## 3 Fair Stochastic Dominance Thompson Sampling

## 4 Aprendizaje Social

# Introducción

- Video Pentland.

# Aprendizaje Social

- Se propone un modelo de como una población de tomadores de decisión puede nutirse de la agregación de información de las acciones de los demás balanceando la exploración y explotación.

- $N$  agentes,  $M$  opciones cada uno. Recompensas  $r_{it} \sim Bernoulli(\eta_i)$ . Luego  $p(r_{it} = 1 | \eta_i) = \eta_i$  (aqui denominamos  $\eta_i$  la calidad de la elección). Sea  $\eta^*$  el mayor. Obsérvese que no sabemos cual es la elección con mayor  $\eta_i$ .
- El agente puede observar la historia de recompensas de una acción en particular o todas las acciones.
- La popularidad de una acción  $j$  es:  $p_{jt} = \sum_{i=1}^N I(x_{i,t-1} = j)$ .

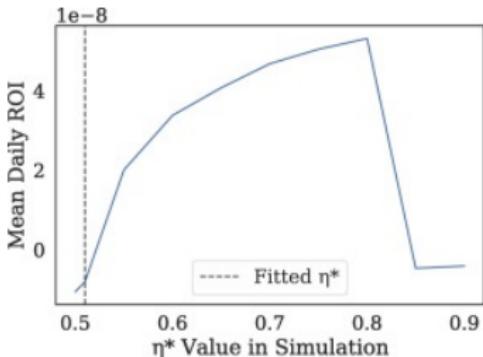
- **Prior:** Cada agente  $i$  elige una opción candidata  $j$ ,  $o_{it} = j$  de acuerdo a una probabilidad proporcional a la popularidad de la opción (i.e., prior social):

$$p(o_{it} = j) = \frac{p_{jt}}{\sum_{k=1}^M p_{kt}}$$

- **Aceptar/Rechazar:** El agente  $i$  acepta o rechaza la opción  $j$  con probabilidad:

$$p(a_{it} = j \mid o_{it} = j) = p(r_{jt} \mid \eta_j = \eta^*) = (\eta^*)^{r_{jt}} (1 - \eta^*)^{(1 - r_{jt})}$$

si la rechaza se repite este paso hasta elegir una acción.



**Figura:** Fig. 8. Simulated mean daily ROI within a population of ideal social samplers following the traders on eToro over the time period we study, for different values of  $\eta^*$ . These simulations check how well the social sampling model balances exploration versus exploitation. The fitted value of  $\eta^*$  that achieves the best predictive accuracy of eToro follow decisions is suboptimal in terms of mean daily ROI in these simulations.