

# Test de pruebas de hipótesis via discrepancia de Stein kernelizada

Arturo Jaramillo

October 16, 2024

# Problemática

Contexto:

Proponemos un modelo  $q$  para un conjunto de datos en  $\mathbb{R}^d$ .

## Pregunta central

Los datos realmente se ajustan a  $q$ ?

Dificultad:

Sólo puedo acceder a la función score  $\mathbf{s}_q(x) := \nabla V(x)$ , donde

$$q(x) = \exp\{V(x)\}.$$

Relevancia:

Útil cuando sólo se conoce a  $q$  salvo múltiplos constantes.

# Propuesta metodológica

- ▶ Discrepancia de Stein kernelizada (KSD).
- ▶ Debe permitir buenos ajustes para distribuciones complejas.
- ▶ Funciona sin acceso completo a las verosimilitudes.

# Ingredientes teóricos: Identidad de Stein

Sea  $\mathcal{F}$  una familia de funciones reales en  $\mathbb{R}^d$ .

## Theorem

*Dos distribuciones  $p$  y  $q$  son iguales si para toda  $f \in \mathcal{F}$ ,*

$$\mathbb{E}_{x \sim p} [\mathcal{A}_q[f](x)] = 0, \quad (1)$$

*donde  $\mathcal{A}_q[f](x) := \mathbf{s}_q(x)f(x) + \nabla f(x)$ .*

# Ingredientes teóricos: Identidad de Stein

Sea  $\mathcal{F}$  una familia de funciones reales en  $\mathbb{R}^d$ .

## Theorem

*Dos distribuciones  $p$  y  $q$  son iguales si para toda  $f \in \mathcal{F}$ ,*

$$\mathbb{E}_{x \sim p} [\mathcal{A}_q[f](x)] = 0, \quad (1)$$

donde  $\mathcal{A}_q[f](x) := \mathbf{s}_q(x)f(x) + \nabla f(x)$ .

## Definition

La **discrepancia de Stein** se define como

$$\mathbb{S}(p, q) := \sup_{f \in \mathcal{F}} (\mathbb{E}_{x \sim p} [\mathcal{A}_q[f](x)])^2$$

## Cómo escogemos a $\mathcal{F}$ ?

Ingrediente inicial: un kernel  $K : \mathbb{R}^d \times \mathbb{R}^d \rightarrow \mathbb{R}$  positivo definido.

### Theorem

*Existe un espacio de funciones  $\mathcal{H}$  con producto interno  $\langle \cdot, \cdot \rangle_{\mathcal{H}}$ , tal que  $k(\cdot, x) \in \mathcal{H}$  para  $x \in \mathbb{R}^d$ , y*

$$f(x) = \langle f(\cdot), k(\cdot, x) \rangle_{\mathcal{H}},$$

*para toda  $f \in \mathcal{H}$ .*

# Cómo escogemos a $\mathcal{F}$ ?

Ingrediente inicial: un kernel  $K : \mathbb{R}^d \times \mathbb{R}^d \rightarrow \mathbb{R}$  positivo definido.

## Theorem

Existe un espacio de funciones  $\mathcal{H}$  con producto interno  $\langle \cdot, \cdot \rangle_{\mathcal{H}}$ , tal que  $k(\cdot, x) \in \mathcal{H}$  para  $x \in \mathbb{R}^d$ , y

$$f(x) = \langle f(\cdot), k(\cdot, x) \rangle_{\mathcal{H}},$$

para toda  $f \in \mathcal{H}$ .

## Idea

Proponer  $\mathcal{F}$  como el disco unitario de  $\mathcal{H}$  en la discrepancia de Stein.

## Otras formas de la identidad de Stein

Si  $\mathbf{f}$  es una función con valores en  $\mathbb{R}^{d'}$ , definimos  $\mathcal{A}_q[\mathbf{f}](x)$  como la matriz  $d \times d'$ , dada por

$$\mathcal{A}_q[\mathbf{f}](x) := \mathbf{s}_q(x)\mathbf{f}(x)^T + \nabla\mathbf{f}(x).$$

## Otras formas de la identidad de Stein

Si  $\mathbf{f}$  es una función con valores en  $\mathbb{R}^{d'}$ , definimos  $\mathcal{A}_q[\mathbf{f}](x)$  como la matriz  $d \times d'$ , dada por

$$\mathcal{A}_q[\mathbf{f}](x) := \mathbf{s}_q(x)\mathbf{f}(x)^T + \nabla\mathbf{f}(x).$$

Lemma (Ley, Swan, 2013)

Sean  $p$  y  $q$  densidades ciertas condiciones de regularidad. Entonces

$$\mathbb{E}_{x \sim p}[\mathcal{A}_q[\mathbf{f}](x)] = \mathbb{E}_p[(\mathbf{s}_q(x) - \mathbf{s}_p(x))\mathbf{f}(x)^T].$$

En particular, si  $d' = d$ , se tiene

$$\mathbb{E}_{x \sim p}[\text{Tr}(\mathcal{A}_q[\mathbf{f}](x))] = \mathbb{E}_p[(\mathbf{s}_q(x) - \mathbf{s}_p(x)) \cdot \mathbf{f}(x)].$$

# Discrepancia de Stein kernelizada

Bajo las consideraciones previas

Definition (Discrepancia de Stein kernelizada, KSD)

Está definida por

$$\mathbb{S}_K(p, q) := \mathbb{E}_{x, x' \sim p}[(\mathbf{s}_q(x) - \mathbf{s}_p(x))K(x, x')(\mathbf{s}_q(x') - \mathbf{s}_p(x'))]$$

# Discrepancia de Stein kernelizada

Bajo las consideraciones previas

Definition (Discrepancia de Stein kernelizada, KSD)

Está definida por

$$\mathbb{S}_K(p, q) := \mathbb{E}_{x, x' \sim p}[(\mathbf{s}_q(x) - \mathbf{s}_p(x))K(x, x')(\mathbf{s}_q(x') - \mathbf{s}_p(x'))]$$

Ok... definimos algo pero no parece servir de nada..

# Representación de KSD

## Theorem

*Se tiene que*

$$\mathbb{S}_K(p, q) := \mathbb{E}_{x, x' \sim p}[u_q(x, x')],$$

*donde  $u_q$  es una función completamente explícita que sólo depende de  $\mathbf{s}_q$  y de  $K$ .*

# Representación de KSD

## Theorem

Se tiene que

$$\mathbb{S}_K(p, q) := \mathbb{E}_{x, x' \sim p}[u_q(x, x')],$$

donde  $u_q$  es una función completamente explícita que sólo depende de  $s_q$  y de  $K$ .

## Estimador

$$\hat{\mathbb{S}}_K(p, q) := \frac{1}{n(n-1)} \sum_{1 \leq i \neq j \leq n} u_q(x_i, x_j),$$

donde  $x_1, \dots, x_n$  son muestreadas de  $p$ .

Ok, ok, si insisten...

La función  $u_q$  está dada por

$$\begin{aligned}u_q(x, x') &:= \mathbf{s}_q(x)^T k(x, x') \mathbf{s}_q(x') \\ &+ \mathbf{s}_q(x)^T \nabla_{x'} k(x, x') \\ &+ \nabla_x k(x, x')^T \mathbf{s}_q(x') \\ &+ \text{Tr}[\nabla_{x, x'} K(x, x')]\end{aligned}$$

# Cómo funciona la prueba de hipótesis?

## Fundamento teórico

Se puede mostrar que bajo la hipótesis  $\text{Datos} \sim q$ , se tiene que  $n\hat{\mathbb{S}}_K(p, q)$  converge a un límite con cuantiles calculables numéricamente en términos de  $\mathbf{s}_q$ .

# Cómo funciona la prueba de hipótesis?

## Fundamento teórico

Se puede mostrar que bajo la hipótesis  $\text{Datos} \sim q$ , se tiene que  $n\hat{S}_K(p, q)$  converge a un límite con cuantiles calculables numéricamente en términos de  $s_q$ . **Algoritmo**

- Calculamos un  $(1 - \alpha)$ -cuantil de la ley asintótica antes mencionada.
- Calculamos  $n\hat{S}_K(p, q)$  y comparamos con el cuantil. Rechazamos si es mayor.

# Comparación con métodos clásicos

- ▶ **Alternativas:** Pruebas ( $\chi^2$ ) y Kolmogorov-Smirnov test.
- ▶ Limitaciones: la constante normalizadora :-)
- ▶ KSD funciona bien en éstas situaciones.

# Bibliography

-  Liu, Q. and Lee, J. D. (2016).  
*A kernelized Stein discrepancy for goodness-of-fit tests.*  
Advances in Neural Information Processing Systems  
(NeurIPS), 29.
-  Chwialkowski, K., Strathmann, H., and Gretton, A. (2016).  
*A kernel test of goodness of fit.*  
In Proceedings of the 33rd International Conference on  
Machine Learning (ICML).

Gracias!

Preguntas?