

Variables aleatorias multidimensionales: independencia vs. dependencia, discusión

Antonio Sala

Dept. Ing. Sistemas y Automatica (DISA)
Universitat Politècnica de València (UPV)

Video-presentación disponible en:

<http://personales.upv.es/asala/YT/V/indepdis.html>



UNIVERSITAT
POLITÀCNICA
DE VALÈNCIA

Presentación

Motivación:

El objetivo del análisis multivariante es describir la relación entre múltiples variables aleatorias. El caso más sencillo es 2 variables, que pueden estar “relacionadas” o no, o una puede “causar” la otra.

Objetivos:

Comprender los conceptos “prácticos” asociados a la “dependencia” o “independencia” entre dos variables aleatorias y el elevado riesgo de sacar conclusiones incorrectas (falacias).

Contenidos:

Probabilidad condicional. Independencia. Discusión. Conclusiones.



UNIVERSITAT
POLITÉCNICA
DE VALÈNCIA

Revisión de conceptos

Probabilidad condicional de y dado x . Probabilidad condicional y fórmula de Bayes:

$$f(y|x) := \frac{f(x, y)}{f_x(x)} \quad f(y|x)f_x(x) = f(x, y) = f(x|y)f_y(y)$$

Independencia estadística: Vbles. estadísticamente independientes $\Leftrightarrow f(x, y) = f_x(x)f_y(y)$.

Equiv, la “condicional” es igual a la “marginal”, y no depende de la variable “medida”:

$$f(y|x) = \frac{f(x, y)}{f_x(x)} = f_y(y)$$



UNIVERSITAT
POLITÉCNICA
DE VALÈNCIA

Independencia vs. predicción

- Si dos variables son independientes, conocer una no permite estimar la otra: (x = “precio KWh en Vladivostok”, y = “precio del queso Cabrales en Madrid”).
- Si son “dependientes” (y se dispone de un modelo que explique esa dependencia, entonces sí se puede mejorar la predicción usando la probabilidad condicional).

Mejor predicción (puntual): Moda o media de probabilidad **condicional**.



UNIVERSITAT
POLITÉCNICA
DE VALÈNCIA

¿Independencia/dependencia con datos experimentales?


Probar dependencia/independencia de dos variables con un modelo matemático $f(x, y)$ es fácil. Sólo necesito “factorizar”, o hacer comprobaciones como en el ejemplo de los balones.

***Probar la “independencia” de variables “experimentales” es complicado...**


¿Son <precio KWh en Vladivostok> y <precio Cabrales en Utiel> independientes? ¿igual se pone de moda en Rusia el Cabrales, y incrementos de población en Vladivostok hacen subir el precio del KWh y la demanda mundial ($\rightarrow$ precio) de Cabrales (correlación positiva)?

***Probar la “dependencia” también.**

si consigo una “ley de la naturaleza” o “ecuación” que predice “muchas” muestras de un experimento (mejor que el puro azar, o la media), sospecho que son dependientes... salvo que mi ley tenga 2400 parámetros ajustables y el experimento tenga 1000 datos, con lo que el resultado es “basura”, o que los datos ajusten por “casualidad” (ver siguiente transp.).



Conclusiones erróneas por azar: “superstición”



El estado de Maine(US) recomienda incrementar el consumo de margarina entre las parejas casadas.

La recomendación no es cierta, la correlación sí.

Dependencia vs. Causalidad

Dependencia (o “correlación”) estadística **NO** implica **causalidad** (relación causa-efecto):

- El evento A ocurre antes en el tiempo que B y, de datos pasados, afirmamos que $p(B|A) > P(B|\neg A)$... ¿decimos que A causa B ? ¿Cuando vemos “ A ”, apostamos por “ B ”? **ufff... ¡cuidado!**
- El concepto de “causalidad” en sí es complicado de definir (desde Aristóteles llevan los filósofos discutiendo el tema).

Leer: https://en.wikipedia.org/wiki/Correlation_does_not_imply_causation



UNIVERSITAT
POLITÉCNICA
DE VALÈNCIA

Hay que ser cuidadosos con las conclusiones

- Estudio detecta correlación significativa entre “precio KWh Vladivostok” y “precio Cabrales en Utiel”. Tres posibles conclusiones:
 - 1 ¡No me lo creo! Esto es una pura casualidad, que más datos desmentirán.
 - 2 Hay una tercera variable que “causa” ambas: lanzamos hipótesis de que están “causados” por el incremento de población en Rusia (y que el Cabrales les encanta a los rusos). Habrá que “probar” o “desmentir” la hipótesis.
 - 3 ¿Superstición o visionario?: si sube el KWh en Vladivostok, eso causa que suba el Cabrales. Vista la tendencia alcista del KWh, voy a comprar acciones de queserías asturianas.
- Estudio estadístico detecta correlación positiva entre “buena salud” y “consumo moderado de alcohol”. Dos posibles conclusiones¹ :
 - 1 El alcohol es **saludable**: bebe vino y tendrás salud y felicidad.
 - 2 El alcohol es **perjudicial**: las personas con mala salud deben evitar el consumo de alcohol (los enfermos no beben, por prescripción médica).

¹Depende de quien pague el estudio (“asociación de productores de vino” versus “dinero público noruego” (esto es, de país cuyo gobierno no oculte resultados malos para un sector económico importante), saldrá en prensa una u otra conclusión. Los datos no mientan, las personas que los seleccionan o interpretan sí.

Hay que ser cuidadosos con las conclusiones

- Estudio detecta correlación significativa entre “precio KWh Vladivostok” y “precio Cabrales en Utiel”. Tres posibles conclusiones:
 - ① ¡No me lo creo! Esto es una pura casualidad, que más datos desmentirán.
 - ② Hay una tercera variable que “causa” ambas: lanzamos hipótesis de que están “causados” por el incremento de población en Rusia (y que el Cabrales les encanta a los rusos). Habrá que “probar” o “desmentir” la hipótesis.
 - ③ ¿Superstición o visionario?: si sube el KWh en Vladivostok, eso causa que suba el Cabrales. Vista la tendencia alcista del KWh, voy a comprar acciones de queserías asturianas.
- Estudio estadístico detecta correlación positiva entre “buena salud” y “consumo moderado de alcohol”. **Dos posibles conclusiones¹** :
 - ① El alcohol es **saludable**: bebe vino y tendrás salud y felicidad.
 - ② El alcohol es **perjudicial**: las personas con mala salud deben evitar el consumo de alcohol (los enfermos no beben, por prescripción médica).

¹Depende de quien pague el estudio (“asociación de productores de vino” *versus* “dinero público noruego” (esto es, de país cuyo gobierno no oculte resultados malos para un sector económico importante), saldrá en prensa una u otra conclusión. Los datos no mienten, las personas que los seleccionan o interpretan sí.

Resumen: life is hard

- Podemos inferir conclusiones **erróneas** (superstición, relación causa→efecto) a partir de unos datos por “casualidad” ...
dependencia afirmada que es falsa.
- Datos futuros pueden desmentir una dependencia que se suponía cierta** (siguientes años de estadística de divorcios en Mayne). Sobre todo en Medicina, Sociología, Psicología. En Física, datos más “precisos” o con más “energía” o “espectro” desmienten teorías.
- Dos variables pueden ser “dependientes” **pero no haber encontrado el modo de demostrarlo** por falta de “tiempo” (–a– No hemos hecho la estadística Vladivostok/Cabrales) o de “inteligencia” (–b– a nadie antes de Einstein se le había ocurrido $E = mc^2$).

La ciencia progresa por “Matemáticas” –b– o “coleccionismo de sellos” –a–.

Conclusiones

- Variables **independientes**: saber una variable no sirve para decir nada de la otra, **condicional = marginal**.
- Dependencia estadística / correlación NO implica “causa”.
- Dependencia/independencia es difícil de probar con muestras ruidosas. La estadística “bien hecha” intenta cuantificar la probabilidad de error.
- Es fácil equivocarse extrayendo conclusiones erróneas de “causalidad” en estudios estadísticos.