



UNIVERSIDAD NACIONAL AUTONOMA DE MEXICO

FACULTAD DE CIENCIAS

INTRODUCCION A LA TEORIA DE GRANDES DESVIACIONES

237-10017

T E S I S

QUE PARA OBTENER EL TITULO DE:

A C T U A R I O

P R E S E N T A :

ERWIN LUIS HERRERA DOMINGUEZ



DIRECTOR DE TESIS: DRA. MA. EMILIA CABALLERO ACOSTA



FACULTAD DE CIENCIAS UNAM

FACULTAD DE CIENCIAS SECCION ESCOLAR



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

TESIS CON FALLA DE ORIGEN



MAT. MARGARITA ELVIRA CHÁVEZ CANO
Jefa de la División de Estudios Profesionales de la
Facultad de Ciencias
Presente

Comunicamos a usted que hemos revisado el trabajo de Tesis

INTRODUCCION A LA TEORIA DE GRANDES DESVIACIONES
realizado por **Erwin Luis Herrera Domínguez**

con número de cuenta **9455523-7**, pasante de la carrera de **Actuaría**

Dicho trabajo cuenta con nuestro voto aprobatorio.

Atentamente

Director de Tesis

Propietario	Dra. Ma. Emilia Caballero Acosta	<i>Emilia Caballero</i>
Propietario	Dra. Ana Meda Guardiola	<i>Ana Meda</i>
Propietario	DR. JOSE MARIA GONZALEZ BARRIOS	<i>Jose M. Gonzalez Barrios</i>
Suplente	Dr. Fernando Avila Murillo	<i>Fernando Avila</i>
Suplente	M. en C. ALBERTO MOLINA ESCOBAR	<i>Molina</i>

Consejo Departamental de
Matemáticas

Jose Antonio Flores Diaz
M. en C. JOSE ANTONIO FLORES DIAZ

MATEMÁTICAS

Agradecimientos.

Gracias a mis padres, Margarita y Raúl por apoyarme siempre y por los principios que me han inculcado.

A mis hermanos, idem, que además han sido mis mejores amigos. A mi tío Dante, le dedico este trabajo.

Gracias a Ma. Emilia Caballero por las observaciones, comentarios, correcciones y la paciencia que nos ha tenido para terminar este material.

A la Dra. Ana Meda, los Drs. José María Barrios, Fernando Avila y el M.C. Roberto Molina por las observaciones y correcciones que hicieron al trabajo.

Gracias al Instituto de Matemáticas por la beca de tesis y el apoyo otorgado.

A Ulises, y porque terminemos pronto lo que resta del tema.

A mis amigos, Chucho, Cruz, Ulises, Ricardo, Moises, Yudico, Cesar, Andres, Carlos, Emilio, Julio, Veronica, Octavio, Gerardo, Salomon, Dulce, Dasha, Tatiana, Tatiana, Mónica.

Gracias a todos aquellos que han contribuido a mi formación académica y como persona.

Erwin.

Índice General

Introducción.	I
El Principio de Grandes Desviaciones.	1
1.1 Colas de la distribución binomial.	1
1.2 Colas de la distribución normal.	6
1.3 Colas de la distribución estable.	8
1.4 El Principio de Grandes Desviaciones.	9
PGD para Espacios Discretos.	13
2.1 El Método de Tipos.	13
2.2 Aplicación en Teoría de la Información.	25
2.3 Teorema de Cramér y Alfabetos Finitos	28
2.4 Aplicación en Teoría del Riesgo.	32
2.5 PGD para Muestreo sin Reemplazo	34
El Teorema de Cramér Real.	45
3.1 Transformada de Cramér.	45
3.2 El Teorema de Cramér.	52
3.3 Cálculo de $\Lambda(\lambda)$ y $\Lambda^*(\lambda)$ para algunas variables aleatorias	63
El Teorema de Cramér \mathbb{R}^d Dimensional.	71
4.1 Tensión exponencial.	71
4.2 Transformada de Cramér en \mathbb{R}^d	74
4.3 El Teorema de Cramér Multidimensional.	77
PGD en los casos dependientes.	83
5.1 Descripción del teorema.	83

5.2	Propiedades de Λ y Λ^*	
5.3	Teorema de Gartner-Ellis.	

Bibliografía.

Introducción.

El presente trabajo tiene como objetivo dar una introducción al tema de la teoría de grandes desviaciones, el cual es de gran interés actualmente en el campo de la teoría de la probabilidad. Mostraremos las ideas principales que motivan el estudio del tema, así como el desarrollo de los resultados teóricos básicos. En esta parte hemos hecho un esfuerzo especial en dar las demostraciones completas y detalladas de todos estos resultados, buscando siempre dar la presentación más accesible de ellos. En general los textos que tratan el tema no hacen esto ya que comúnmente solo dan la idea de la demostración sin hacer los detalles. Esto permitirá que este trabajo pueda ser usado como introducción para estudiantes de los últimos semestres de licenciatura con conocimientos básicos de teoría de probabilidad. Además, en este trabajo nos interesa presentar los elementos teóricos en los que se fundamenta la teoría y se desarrollan algunas aplicaciones.

El primer resultado en la teoría de *grandes desviaciones* se debe a Harald Cramér. Cramér era un matemático suizo que daba asesoría a una compañía de seguros. Para compañías como estas es fundamental protegerse del riesgo de que ocurran sucesos inesperados o raros y en este contexto podemos hablar de *grandes desviaciones*. Es decir, sabemos que el Teorema del Límite Central nos da información acerca del comportamiento de alguna distribución de probabilidad alrededor de su media o valor esperado, mientras que la teoría del riesgo en seguros se ocupa de eventos *raros*, es decir, que están en la “cola” de la distribución de probabilidad. Más adelante mostraremos el teorema debido a Cramér que es fundamental en este trabajo así como la aplicación mencionada en teoría del riesgo, la cual es muy sencilla y además ilustra muy bien el tema.

El desarrollo moderno de la teoría de *desviaciones grandes* se debe en gran medida al trabajo fundamental de S.R.S. Varadhan en el que muestra una clara y concisa descripción de los principales resultados. En el libro de [Dem98]

A. Dembo y O. Zeitouni, se pueden encontrar mayores referencias históricas. partir del trabajo de Varadhan el estudio de grandes desviaciones recobra importancia y esto puede obedecer a dos razones:

1. Las estimaciones de grandes desviaciones son una herramienta crucial que se utilizan en diversos problemas en estadística, ingeniería, mecánica estadística y probabilidad aplicada.
2. Las técnicas empleadas en grandes desviaciones nos proporciona métodos que funcionan en otras ramas de la probabilidad y han ayudado a resolver problemas en dichas ramas.

Como decíamos anteriormente la teoría de grandes desviaciones es el estudio de *eventos raros*, en el sentido de que son sucesos muy poco probables. Es decir es el cálculo asintótico de probabilidades tan pequeñas que se estudian en escala exponencial.

El término *grandes* en grandes desviaciones se debe a lo siguiente: El teorema del Límite Central (TLC) nos dice que : Si X_1, \dots, X_n es una sucesión de variables aleatorias independientes e idénticamente distribuidas (v.a.i.i.d.) con media μ y varianza $\sigma^2 < \infty$, entonces la media muestral $\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$ es aproximadamente normal con media μ y varianza σ^2/n , y la aproximación es válida solamente en una vecindad de radio σ/\sqrt{n} alrededor de μ . Esto es, el TLC gobierna fluctuaciones aleatorias sólo cerca de la media, desviaciones del orden de σ/\sqrt{n} . Las fluctuaciones que son del orden de σ son, en relación con las fluctuaciones típicas, mucho más grandes: son grandes desviaciones de la media. Ocurren sólo raramente, por lo que la teoría de las grandes desviaciones se describe frecuentemente como la *teoría de los eventos raros*, eventos que ocurren lejos de la media, en las colas de la distribución.

En el capítulo 1 estudiamos ciertas propiedades de las “colas” de algunas distribuciones de probabilidad. En el primer caso, que corresponde a la distribución Binomial, realizamos un sencillo experimento y nos preguntamos por la probabilidad de que algún evento se encuentre en las colas de la distribución (un *evento raro*). De una forma muy intuitiva y usando elementos gráficos podemos encontrar estas probabilidades.

En el segundo caso, el de la distribución normal, hallamos la tasa de convergencia (a la que llamaremos función de tasa) de eventos raros, en este caso, de que la media muestral difiere significativamente del valor esperado. Y en el último caso, el de la distribución estable, se muestra que no siempre se puede hallar una tasa de convergencia usando la técnica del caso anterior. Finalmente, enunciaremos el concepto de función de tasa y el Principio de Grandes Desviaciones (PGD) en su forma más general.

Para el capítulo 2, estudiaremos el PGD para espacios discretos de dimensión finita. Utilizaremos métodos de combinatoria para obtener un PGD para la distribución empírica de procesos que toman valores en un conjunto finito, en este caso obtendremos el importante Teorema de Sanov; además emplearemos el método para obtener grandes desviaciones en el tema de muestreo sin reemplazo, un procedimiento que surge en muchos problemas estadísticos.

Empleando los métodos combinatorios, también tendremos un PGD para la media empírica de procesos que toman valores en conjuntos finitos, en este caso obtendremos el Teorema de Cramér para conjuntos finitos en \mathbb{R} el cual será una consecuencia casi inmediata del Teorema de Sanov.

Como consecuencia de los teoremas antes mencionados, mostramos como se pueden aplicar estos resultados en el área de teoría del riesgo y teoría de la información.

Es importante señalar que los resultados obtenidos en este capítulo, utilizando el método de tipos para conjuntos finitos, nos darán una idea aproximada acerca de los resultados que podríamos esperar para conjuntos más abstractos.

En el capítulo 3 daremos la demostración del Teorema de Cramér en el caso real, es decir, obtendremos un PGD para la media empírica de una sucesión de v.a.i.i.d. con valores en \mathbb{R} y función de tasa que en este caso será la transformada de Cramér. Enunciaremos propiedades de la transformada de Cramér que nos serán útiles en la demostración del teorema. Finalmente, haremos el cálculo explícito de la función de tasa para algunas distribuciones de probabilidad.

Damos la definición de *tensión exponencial*, así como la noción de PGD débil en el capítulo 4. Obtendremos, como en el capítulo anterior, un PGD para la media empírica de una sucesión de v.a.i.i.d. con valores en \mathbb{R}^d . Veremos las propiedades análogas de la transformada de Cramér en \mathbb{R}^d al caso en \mathbb{R} .

Por último, en el capítulo 5, tratamos el caso de variables aleatorias que no

son independientes. Situaciones de este tipo se encuentran en diversos problemas de probabilidad, por ejemplo, las cadenas de Markov. También obtendremos un PGD para este caso.

Estas son algunas situaciones en las cuales se pueden obtener PGD. Este no es exhaustivo y desde luego hay muchos otros casos en donde también hay PGD, pero en éste trabajo hemos buscado exponer los casos más accesibles ya que la teoría de grandes desviaciones es una rama activa dentro de la probabilidad y frecuentemente se obtienen nuevos resultados en el área que además pueden llegar a ser sumamente complicados técnicamente y usar herramientas muy sofisticada, todo lo cual queda fuera del objetivo de ésta tesis.

Cabe mencionar que un trabajo posterior, se presentarán distintas aplicaciones de la teoría de Grandes Desviaciones a diversos problemas en estadística, teoría de la información, mecánica estadística y probabilidad aplicada. Este material y lo que se presente posteriormente es resultado del trabajo en equipo que he hecho con Ulises Salas y bajo la dirección de la Dra. Ma. Emilia Caballero y la Dra. Ana Meda.

Capítulo 1

El Principio de Grandes Desviaciones.

.1 Colas de la distribución binomial.

Comenzaremos la exposición del tema con un ejemplo que nos ayudará a entender de manera sencilla e intuitiva el concepto subyacente en el principio de grandes desviaciones. Consideremos el experimento de lanzar una moneda n veces y registramos los resultados. Supongamos que hay dos posibles resultados para cada lanzamiento (águila o sol), por lo que tenemos en total 2^n posibles resultados. ¿Qué podemos decir del número total de águilas? Existen $n + 1$ posibles valores, desde 0 hasta n ; ahora bien, de los 2^n posibles resultados, C_r^n representa las distintas formas de obtener r águilas en n lanzamientos (C_r^n son las combinaciones de n tomadas en r). Si la moneda es justa, es decir, que tenemos la misma probabilidad de obtener águila o sol, entonces los resultados son igualmente probables y por lo tanto la probabilidad de obtener r águilas en n lanzamientos es $\frac{C_r^n}{2^n}$. Por lo que el número promedio de águilas por lanzamiento tiene $n + 1$ posibles valores, $\{0, 1/n, 2/n, \dots, 1\}$ y el valor r/n tiene peso $\frac{C_r^n}{2^n}$. Calculemos la probabilidad de que el número promedio de águilas se encuentre en un cierto rango. Sea M_n el número promedio de águilas en n lanzamientos, entonces para x y y reales en el intervalo $[0, 1]$ tenemos que

$$\mathbb{P}(x < M_n < y) = \sum_{\{r: x < \frac{r}{n} < y\}} \frac{C_r^n}{2^n}.$$

Utilizando la expresión anterior, obtenemos los histogramas de la distribución de probabilidad de M_n para distintos valores de n . En la figura 1 se presentan los histogramas para $n = 16$, $n = 64$ y $n = 100$.

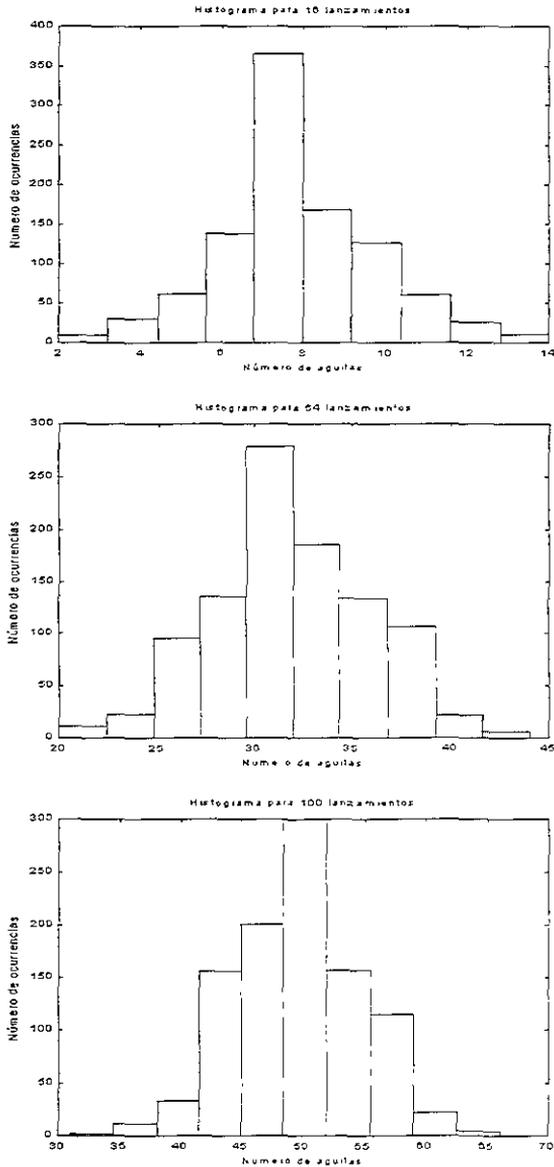


Figura 1. Distribución del número de águilas en n lanzamientos.

Como era de esperarse, observamos en las gráficas que conforme n es grande, la distribución se concentra alrededor de la media $1/2$, mientras que

as de la distribución se hacen cada vez más pequeñas. Es decir, los eventos que están significativamente de la media tienen probabilidad de ocurrencia pequeña nos interesará estudiar este fenómeno. Para esto consideremos dos casos:

1. Escogemos cualquier punto x mayor que la media de la distribución ($1/2$ en éste caso), es decir, el evento raro $\{M_n > x\}$, calculamos ahora para un rango de valores de n el logaritmo de la probabilidad de que M_n sea mayor que x . Fijamos el valor $x = 0.7$ y obtenemos las gráficas de $\ln \mathbb{P}(M_n > x)$ contra n que se muestran en la figura 2.

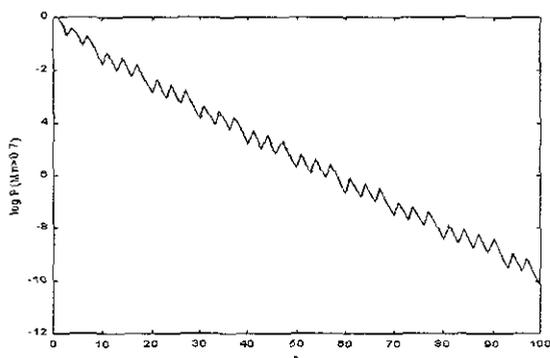


Figura 2. $\log \mathbb{P}(M_n > 0.7)$ contra n .

En las gráficas podemos observar que aunque éstas tienen oscilaciones (las cuales se repiten periódicamente), cuando el valor de n es grande podemos ver que la gráfica de $\log \mathbb{P}(M_n > x)$ contra n tiene un comportamiento aproximadamente lineal. Ahora cambiamos el valor a $x = 0.8$ y después a $x = 0.9$ y obtenemos las gráficas que se muestran en la figura 3; otra vez para valores de n grandes éstas siguen un comportamiento aproximadamente lineal, si denotamos por $-I(x)$ al valor de la pendiente asintótica la cual es negativa, tenemos la siguiente aproximación.

$$\log \mathbb{P}(M_n > x) \approx -nI(x).$$

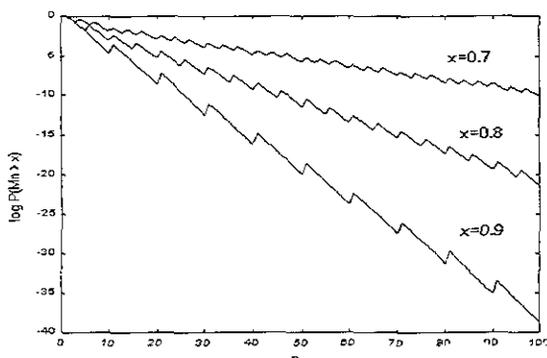


Figura 3. $\log \mathbb{P}(M_n > x)$ para $x = 0.8$ y $x = 0.9$ contra n .

2. Escogemos cualquier punto x menor que la media de la distribución (1), y obtenemos como en el caso anterior las gráficas de $\ln \mathbb{P}(M_n < x)$ contra n para distintos valores de x (figura 4), $x = 0.4$, $x = 0.2$, $x = 0.1$ y n varía de 1 a 100. Observemos como antes que para n grande, la gráfica tiene un comportamiento aproximadamente lineal con pendiente asintótica $-I(x)$ por consiguiente

$$\log \mathbb{P}(M_n < x) \approx -nI(x).$$

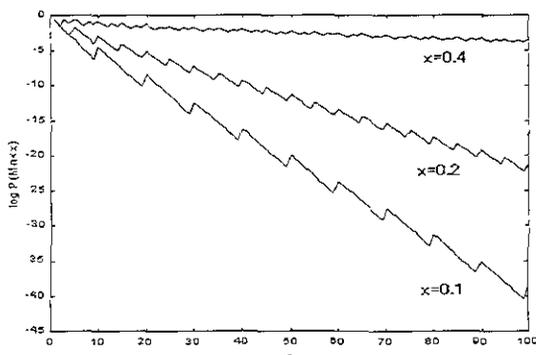


Figura 4. $\log \mathbb{P}(M_n < x)$ para $x = 0.4$ y $x = 0.2$ y $x = 0.1$ contra n .

Finalmente de las gráficas anteriores, para $1/2 < x < 1$ e igualmente para $0 < x < 1/2$ medimos la pendiente asintótica $-I(x)$ en cada caso y graficamos

los valores de $I(x)$ contra x , es decir, obtenemos la gráfica que corresponde a lo que llamaremos la *función de tasa* $I(x)$ que se muestra en la figura 5.

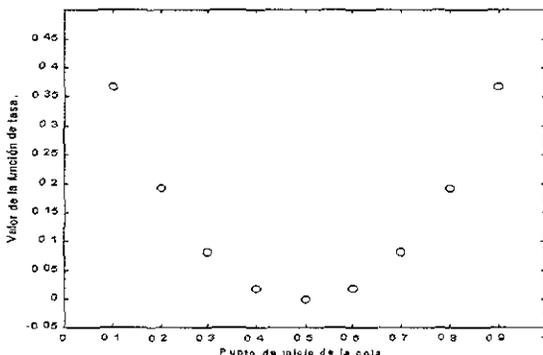


Figura 5. Función de tasa $I(x)$.

Podemos decir entonces que: *La cola de la distribución del número promedio de caras en n lanzamientos decae exponencialmente conforme n se incrementa.* Es decir,

$$\begin{aligned} \mathbb{P}(M_n > x) &\approx e^{-nI(x)} && \text{para } x > 1/2 \\ \mathbb{P}(M_n < x) &\approx e^{-nI(x)} && \text{para } x < 1/2 \end{aligned} \quad 1.1.1$$

n crece.

Como se mencionó en la introducción, la teoría de las grandes desviaciones estudia los sucesos poco frecuentes, los sucesos exponenciales pequeños cuando se pasa al límite y uno de los objetivos principales es encontrar una manera sistemática de calcular la función de tasa. Más adelante mostraremos una forma de hacer esto en algunos casos.

Observación. *La Ley Débil de los Grandes Números.*

Una consecuencia del resultado anterior, el cual se demostrará rigurosamente más adelante, es la Ley Débil de los Grandes Números en el caso del lanzamiento de monedas, tenemos que para n grande la distribución de M_n se concentra alrededor de la media, es decir, para todo $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} \mathbb{P}\left(\left|M_n - \frac{1}{2}\right| < \varepsilon\right) = 1. \quad 1.1.2$$

Otra forma de decirlo es que las colas se hacen cada vez más pequeñas, es decir para todo $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} \mathbb{P}(|M_n - \frac{1}{2}| > \varepsilon) = 0,$$

para lo cual vemos que

$$\mathbb{P}(|M_n - \frac{1}{2}| > \varepsilon) = \mathbb{P}(M_n > \frac{1}{2} + \varepsilon) + \mathbb{P}(M_n < \frac{1}{2} - \varepsilon).$$

Como las colas de la distribución de M_n para n grande decaen exponencialmente usando 1.1.1 en el miembro derecho de la igualdad anterior tenemos que

$$\begin{aligned} \mathbb{P}(M_n > x) &\approx e^{-nI(x)} \xrightarrow{n \rightarrow \infty} 0 && \text{para } x > 1/2 \text{ y} \\ \mathbb{P}(M_n < x) &\approx e^{-nI(x)} \xrightarrow{n \rightarrow \infty} 0 && \text{para } x < 1/2 \end{aligned}$$

obteniendo el resultado 1.1.2.

1.2 Colas de la distribución normal.

El siguiente ejemplo, el estudio de las colas gaussianas, es la forma clásica con la que se aborda la idea subyacente en la teoría de grandes desviaciones. También veremos que no siempre funciona este método para el caso de otras distribuciones. Consideremos $X_1 \dots X_n$ una sucesión de variables aleatorias independientes e idénticamente distribuidas (v.a.i.i.d.), $X_i \sim N(0, 1)$. Si

$$\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$$

entonces

$$\bar{X}_n \sim N(0, 1/n),$$

por lo tanto

$$\mathbb{P}(\bar{X}_n \geq t) \xrightarrow{n \rightarrow \infty} 0.$$

La idea es entonces buscar la velocidad de la convergencia a cero, y para hacer esto hacemos estimaciones de “colas” de gaussianas. Sean $a > 0$ y $Y \sim N(0, 1)$.

$$\mathbb{P}(Y \geq a) = \int_a^{+\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right) dx.$$

tiene, para $\mathbb{P}(Y \geq a)$, que $(Y/a) \geq 1$, por lo que

$$\begin{aligned} \mathbb{P}(Y \geq a) &\leq \frac{1}{\sqrt{2\pi}} \left[\frac{1}{a} \int_a^{+\infty} x \exp\left(\frac{-x^2}{2}\right) dx \right] \\ &= \frac{1}{\sqrt{2\pi}} \left[\frac{\exp\left(-\frac{a^2}{2}\right)}{a} \right] \end{aligned}$$

para $\mathbb{P}(Y \leq a)$ se tiene que $(Y/a) \leq 1$, por lo que

$$\begin{aligned} \mathbb{P}(Y \leq a) &\geq \frac{1}{\sqrt{2\pi}} \left[\frac{1}{2a} \int_a^{2a} x \exp\left(\frac{-x^2}{2}\right) dx \right] \\ &= \frac{1}{\sqrt{2\pi}} \left[\frac{\exp\left(-\frac{a^2}{2}\right) - \exp(-2a^2)}{a} \right]. \end{aligned}$$

en el caso que nos interesa.

$$\mathbb{P}(Y \geq t) \leq \frac{1}{\sqrt{2\pi}} \left[\frac{1}{t\sqrt{n}} \exp\left(\frac{-nt^2}{2}\right) \right] \quad y$$

$$\mathbb{P}(Y \leq t) \geq \frac{1}{\sqrt{2\pi}} \cdot \frac{1}{t\sqrt{n}} \left[\exp\left(-\frac{nt^2}{2}\right) - \exp(-2nt^2) \right],$$

tomamos logaritmo, dividimos entre n y finalmente tomando límite superior e inferior, al cual denotaremos respectivamente como $\overline{\lim}$ y $\underline{\lim}$, tenemos

$$\overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log(\mathbb{P}(\overline{X}_n \geq t)) \leq -\frac{t^2}{2} \quad y \quad \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log(\mathbb{P}(\overline{X}_n \leq t)) \geq -\frac{t^2}{2}.$$

Lo que nos da la convergencia hacia $-t^2/2$. Observemos que en este caso la función de tasa $I(x)$ como se vió en la sección anterior es

$$I(x) = \frac{x^2}{2}. \tag{1.2.1}$$

Sin embargo, existen casos donde esta forma de resolver el problema no es conveniente, lo que veremos a continuación.

1.3 Colas de la distribución estable.

Definición 1.3.1. Se dice que una v.a. X tiene distribución estable si para toda $k > 0$, y para toda sucesión X_1, \dots, X_k de v.a.i.i.d. con la distribución de X , existen constantes $a_k > 0$, b_k tal que

$$\mathcal{L}(X_1 + \dots + X_k) = \mathcal{L}(a_k X + b_k)$$

donde \mathcal{L} denota la distribución de probabilidad de la variable.

Si X tiene una distribución estable y si además esta distribución es simétrica, es decir, $F(x) = F(-x)$ para toda $x > 0$, entonces ocurre alguna de las siguientes dos cosas:

(a) X tiene una distribución normal ($\alpha = 2$).

(b) Existe $\alpha \in (0, 2)$ y tal que la función característica de X es

$$\mathbb{E}[\exp(ixX)] = \phi_\alpha(x) = \exp(-d|x|^\alpha) \quad d > 0. \quad 1.3$$

A α se le llama índice de la distribución estable y d es un número real y positivo, ver [Bre75] pag. 199 y 204. El hecho de que la distribución estable sea simétrica simplifica significativamente la expresión de la función característica en el caso general.

También en [Bre75] pag. 202 se prueba la siguiente estimación para la “cola” de esta distribución.

Si $M^+(t) := \mathbb{P}(X \geq t)$, $t > 0$, entonces

$$M^+(t) = t^{-\alpha} M^+(1).$$

Es decir,

$$\mathbb{P}(X \geq t) \approx Ct^{-\alpha}. \quad 1.3$$

otra parte, si $\bar{X}_n = \frac{1}{n} \sum_{j=1}^n X_j$ entonces

$$\begin{aligned} \mathbb{E}[\exp(ix\bar{X}_n)] &= \mathbb{E}\left[\exp\left(\frac{1}{n}ix \sum_{j=1}^n X_j\right)\right] \\ &= \mathbb{E}\left[\exp\left(\sum_{j=1}^n \left(\frac{1}{n}ix\right)X_j\right)\right] = \prod_{j=1}^n \mathbb{E}\left[\exp\left(\frac{ix}{n}X_j\right)\right] \\ &= \prod_{j=1}^n \phi_\alpha\left(\frac{x}{n}\right) = \left[\exp(-d\left|\frac{x}{n}\right|^\alpha)\right]^n \\ &= \exp\left(-d|x|^\alpha n^{1-\alpha}\right) = \exp\left(-d\left|n^{\frac{1-\alpha}{\alpha}}x\right|^\alpha\right) \\ &= \phi_\alpha\left(n^{\frac{1-\alpha}{\alpha}}x\right) = \mathbb{E}\left[\exp\left(n^{\frac{1-\alpha}{\alpha}}X_1\right)\right]. \end{aligned}$$

lo que

$$\bar{X}_n \sim n^{\frac{1-\alpha}{\alpha}}X_1. \tag{1.3.3}$$

ahora $\mathbb{P}(\bar{X}_n \geq t)$, de 1.3.2 y 1.3.3 tenemos que

$$\mathbb{P}(\bar{X}_n \geq t) \approx Ct^{-\alpha}n^{1-\alpha},$$

tomando logaritmo, dividimos entre n , y tomando límite obtenemos

$$\frac{1}{n} \ln \mathbb{P}(\bar{X}_n \geq t) \approx \frac{1}{n}(\ln Ct^{-\alpha} + (1-\alpha) \log n)$$

lo tanto

$$\frac{1}{n} \ln \mathbb{P}(\bar{X}_n \geq t) \xrightarrow[n \rightarrow \infty]{} 0.$$

en esta aproximación no encontramos una función que nos indique la velocidad de convergencia hacia cero. Por lo que, obteniendo cotas para la cola de la distribución no siempre se obtiene un resultado satisfactorio, por lo tanto se buscará una manera sistemática de hallar la función de tasa.

A continuación daremos la definición del PGD.

1 El Principio de Grandes Desviaciones.

en las secciones anteriores vimos algunas técnicas para encontrar la función de tasa, también se vio que no siempre es posible hallar dicha tasa. Ahora se

mostrará que bajo ciertas condiciones podremos encontrar una manera sistemática de hallar esta función de tasa. Para definir el PGD, previamente daremos la definición de función de tasa.

Usaremos la siguiente notación: A° y \bar{A} denota el interior y la cerradura del conjunto A respectivamente y A^c el complemento de A para cualquier conjunto A . El ínfimo de una función sobre un conjunto vacío se interpreta como ∞ .

Definición 1.4.1. Sea f una función en un espacio métrico X en $[0, +\infty]$, se dice que f es semicontinua inferiormente (s.c.i.) si una de las dos propiedades siguientes se cumple:

1. Si $x_n \rightarrow x$ entonces $f(x) \leq \varliminf_{n \rightarrow \infty} f(x_n)$.
2. Para todo a , el conjunto de nivel $\{x : f(x) \leq a\}$ es cerrado.

Es claro que una función continua es semicontinua inferiormente.

Definición 1.4.2. Diremos que una función $I : X \rightarrow [0, \infty]$ es una *función de tasa* si I es semicontinua inferiormente. Además, si para todo $a > 0$ el conjunto de nivel $\{x : I(x) \leq a\}$ es compacto, entonces I es una *función de tasa buena*.

Definición 1.4.3. PGD. Sea X un espacio métrico y sea $\{\mu_\varepsilon\}, \varepsilon > 0$ una familia de probabilidades sobre un σ -álgebra F sobre X . Diremos que la familia $\{\mu_\varepsilon\}, \varepsilon > 0$ satisface un Principio de Grandes Desviaciones (PGD) con función de tasa I si para todo $A \in F$ tenemos que

$$\begin{aligned} -\inf\{I(x) : x \in A^\circ\} &\leq \varliminf_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(A) \\ &\leq \varlimsup_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(A) \\ &\leq -\inf\{I(x) : x \in \bar{A}\}. \end{aligned} \tag{1.4}$$

Observaciones.

1. El PGD caracteriza el comportamiento en el límite de una familia de medidas de probabilidad $\{\mu\}_\varepsilon$ conforme $\varepsilon \rightarrow 0$ sobre un σ -álgebra F en un espacio métrico X en términos de una función de tasa. Esta caracterización está dada por las cotas exponenciales asintóticas superior e inferior sobre los valores que μ_ε asigna a los subconjuntos medibles de X . En los casos que consideraremos, F será la σ -álgebra de Borel sobre X .

2. Es claro que si $\{\mu\}_\epsilon$ satisface el PGD y $A \in F$ es tal que

$$\inf_{x \in A^\circ} I(x) = \inf_{x \in \bar{A}} I(x) := I_A, \tag{1.4.2}$$

entonces

$$\lim_{\epsilon \rightarrow 0} \epsilon \log \mu_\epsilon(A) = -I_A. \tag{1.4.3}$$

Un conjunto A que satisface 1.4.2 es llamado un conjunto de *continuidad*. En general, el PGD implica un limite preciso en 1.4.3 solamente para conjuntos de continuidad A .

3. En cualquier situación que involucre medidas aisladas (no atómicas), es decir, $\mu_\epsilon(\{x\}) = 0$ para todo $x \in X$. Tenemos en la cota inferior de 1.4.1 que

$$-\inf_{x \in A^\circ} I(x) \leq \liminf_{\epsilon \rightarrow 0} \epsilon \log(0) = -\infty,$$

ya si tomamos el ínfimo sobre A en vez de A° , concluimos que $I(x) = \infty$, lo cual contradice la cota superior en 1.4.1 porque $\mu_\epsilon(X) = 1$ para todo ϵ . Por lo que es necesario que $\inf_{x \in X} I(x) = 0$ y así la cota superior es válida. Y si I es una función de tasa buena, significa que existe al menos un punto x tal que $I(x) = 0$.

Luego, la cota superior es trivial siempre que $\inf_{x \in \bar{A}} I(x) = 0$, de igual manera, la cota inferior también es trivial siempre que $\inf_{x \in A^\circ} I(x) = \infty$.

Esto nos lleva a una formulación alternativa del PGD, que resulta ser útil cuando este se demuestra. Supongamos que I es una función de tasa y $\Gamma(a) = \{x : I(x) < a\}$ su conjunto de nivel. Entonces, la desigualdad 1.4.1 es equivalente a las siguientes cotas:

(a) *Cota Superior:* Para todo $a < \infty$ y todo conjunto medible A , tal que $\bar{A} \subset \Gamma(a)^c$

$$\overline{\lim}_{\epsilon \rightarrow 0} \epsilon \log \mu_\epsilon(A) \leq -a, \tag{1.4.4}$$

lo anterior se sigue ya que si $x \in \bar{A}$

$$I(x) \geq a$$

y entonces

$$-\inf_{x \in A} I(x) \leq -a.$$

(b) *Cota Inferior:* Para cualquier $x \in \{x : I(x) < \infty\}$ y cualquier conjunto medible A y $x \in A^\circ$,

$$\liminf_{\epsilon \rightarrow 0} \epsilon \log \mu_\epsilon(A) \geq -I(x), \quad 1.4$$

ya que para $x \in A^\circ$,

$$I(x) \geq \inf_{x \in A^\circ} I(x).$$

Por lo tanto

$$-I(x) \leq -\inf_{x \in A^\circ} I(x).$$

Como decíamos anteriormente, en los casos que consideraremos, F será σ -álgebra de Borel sobre X , y entonces 1.4.1 es equivalente a:

$$\text{para todo } O \text{ abierto } \liminf_{\epsilon \rightarrow 0} \epsilon \log \mu_\epsilon(O) \geq -\inf\{I(x) : x \in O\} \quad \text{y} \quad 1.4$$

$$\text{para todo } F \text{ cerrado } \overline{\lim}_{\epsilon \rightarrow 0} \epsilon \log \mu_\epsilon(F) \leq -\inf\{I(x) : x \in F\}.$$

Si ahora consideramos $\{X_n\}_n$ una sucesión de v.a., la media empírica de v.a. es $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ y μ_n es la distribución de la media empírica, diremos que la sucesión de probabilidades μ_n satisface un Principio de Grandes Desviaciones en el caso $\epsilon = 1/n$ con función de tasa I si :

$$\text{para todo } O \text{ abierto } \liminf_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(O) \geq -\inf\{I(x) : x \in O\} \quad \text{y}$$

$$\text{para todo } F \text{ cerrado } \overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(F) \leq -\inf\{I(x) : x \in F\}.$$

1.4

capítulo 2

PGD para Espacios Discretos de Dimensión Finita.

Métodos Combinatorios.

En este capítulo, utilizaremos métodos combinatorios para obtener el PGD para la distribución empírica de procesos que toman valores en un conjunto finito y para la correspondiente media empírica. El empleo de estos métodos está limitado a espacios de dimensión finita. Estos métodos nos ilustrarán los resultados que se esperarían obtener para conjuntos más abstractos. También, daremos algunos ejemplos de como se aplica la teoría.

1 El Método de Tipos.

En este capítulo, salvo que se indique lo contrario, todas las variables aleatorias que consideremos toman valores en un conjunto finito $\Sigma = \{a_1, \dots, a_{|\Sigma|}\}$, donde $|\Sigma|$ denota la cardinalidad o tamaño de un conjunto A . A Σ se le conoce como alfabeto subyacente. Denotaremos por $M_1(\Sigma)$ al espacio de todas las medidas de probabilidad (leyes) en el alfabeto Σ . $M_1(\Sigma)$ se identifica con un subconjunto de $\mathbb{R}^{|\Sigma|}$. El conjunto de todos los vectores $|\Sigma|$ -dimensionales con entradas reales no negativas que suman 1. A $M_1(\Sigma)$ se le asocia la topología inducida por los ℓ_1 norm en $\mathbb{R}^{|\Sigma|}$.

Sea Y_1, Y_2, \dots, Y_n una sucesión de v.a.i.i.d. con distribución de probabilidad $\mu \in M_1(\Sigma)$. Definimos Σ_μ como el soporte de la distribución de probabilidad μ , es decir, $\Sigma_\mu = \{a_i : \mu(a_i) > 0\}$. En general, Σ_μ podría ser un subconjunto

propio de Σ , y cuando consideremos una medida μ podemos suponer, sin pérdida de generalidad, que $\Sigma_\mu = \Sigma$ al ignorar aquellos elementos que aparecen con probabilidad cero.

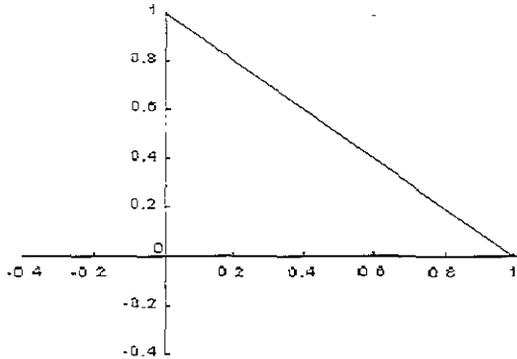


Figura 6. $M_1(\Sigma)$ para $|\Sigma| = 2$.

A continuación daremos la definición de **tipo**, el cual está asociado a una sucesión finita.

Definición 2.1.1. El **tipo** L_n^y de una sucesión finita $y = (y_1, \dots, y_n) \in \Sigma^n$ es la distribución de probabilidad empírica (o medida empírica) inducida por la sucesión. Explícitamente, $L_n^y = (L_n^y(a_1), \dots, L_n^y(a_{|\Sigma|}))$ es el elemento de $M_1(\Sigma)$ dado por

$$L_n^y(a_i) = \frac{1}{n} \sum_{j=1}^n \mathbf{1}_{a_i}(y_j), \quad i = 1, \dots, |\Sigma|$$

es decir, $L_n^y(a_i)$ es el promedio de ocurrencias de a_i en la sucesión y_1, \dots, y_n .

Definimos \mathcal{L}_n como conjunto de todas las posibles sucesiones de **tipos** de longitud n . Entonces $\mathcal{L}_n := \{v : v = L_n^y \text{ para alguna } y\} \subset \mathbb{R}^{|\Sigma|}$ y la distribución de probabilidad empírica L_n^Y asociada con la sucesión $Y := (Y_1, \dots, Y_n)$ es un elemento aleatorio del conjunto \mathcal{L}_n . Los conceptos anteriores son útiles como veremos más adelante. Por ahora, implican las siguientes estimaciones del volumen y la distancia variacional.

Se define la **distancia variacional** entre dos medidas en $M_1(\Sigma)$ como $d_V(v, v') := \sup_{A \subset \Sigma} |v(A) - v'(A)|$.

Podemos decir que la distancia variacional mide la 'semejanza' entre dos medidas de probabilidad. Para mayores referencias ver [Cor94] pag.52-57.

Tenemos el siguiente lema.

ma 2.1.1. *Con la notación definida arriba,*

$$a) |\mathcal{L}_n| \leq (n+1)^{|\Sigma|}.$$

b) Para todo vector de probabilidad $v \in M_1(\Sigma)$

$$d_V(v, \mathcal{L}_n) := \inf_{v' \in \mathcal{L}_n} d_V(v, v') \leq \frac{|\Sigma|}{2n}. \quad 2.1.1$$

Demostración.

Observemos que cualquier componente del vector L_n^y pertenece al conjunto $= \{\frac{0}{n}, \frac{1}{n}, \dots, \frac{n}{n}\}$, cuya cardinalidad es $(n+1)$, y como el vector L_n^y está dado por a lo más $|\Sigma|$ de tales cantidades, la parte (a) del lema está demostrada. Más aún, como los componentes de dicho vector suman 1, la última entrada está dada automáticamente al conocer las primeras $|\Sigma| - 1$ coordenadas del vector, por lo que $|\mathcal{L}_n| \leq (n+1)^{|\Sigma|-1}$.

Para demostrar la parte (b), antes probaremos la siguiente expresión equivalente a la distancia variacional

$$d'_V(v, v') = \frac{1}{2} \sum_{i=1}^{|\Sigma|} |v(a_i) - v'(a_i)|.$$

la prueba de la igualdad anterior se hace en dos partes:

$$i) d'_V(v, v') \leq d_V(v, v').$$

Sea $I = \{a_i : v(a_i) > v'(a_i)\}$, entonces,

$$\begin{aligned}
 2d'_V(v, v') &= \sum_{i=1}^{|\Sigma|} |v(a_i) - v'(a_i)| \\
 &= \sum_{a_i \in I} v(a_i) - v'(a_i) + \sum_{i \in I^c} v'(a_i) - v(a_i) \\
 &\leq \left| \sum_{a_i \in I} v(a_i) - v'(a_i) \right| + \left| \sum_{a_i \in I^c} v(a_i) - v'(a_i) \right| \\
 &= |v(I) - v'(I)| + |v(I^c) - v'(I^c)| \\
 &\leq 2 \sup_{A \subset \Sigma} \{v(A) - v'(A)\} \\
 &= 2d_V(v, v')
 \end{aligned}$$

por lo tanto, $d'_V(v, v') \leq d_V(v, v')$.

ii) $d_V(v, v') \leq d'_V(v, v')$.

Sea $A \subset \Sigma$, entonces,

$$\begin{aligned}
 2|v(A) - v'(A)| &= |v(A) - v'(A)| + |v(A) - v'(A)| \\
 &= |v(A) - v'(A)| + |v(A^c) - v'(A^c)| \\
 &= \left| \sum_{a_i \in A} v(a_i) - v'(a_i) \right| + \left| \sum_{a_i \in A^c} v(a_i) - v'(a_i) \right| \\
 &\leq \sum_{a_i \in A} |v(a_i) - v'(a_i)| + \sum_{a_i \in A^c} |v(a_i) - v'(a_i)| \\
 &= \sum_{i=1}^{|\Sigma|} |v(a_i) - v'(a_i)| \\
 &= 2d'_V(v, v')
 \end{aligned}$$

y por lo tanto,

$$2 \sup_{A \subset \Sigma} \{|v(A) - v'(A)|\} \leq 2d'_V(v, v').$$

De esta forma obtenemos que $d_V(v, v') = \frac{1}{2} \sum_{i=1}^{\Sigma} |v(a_i) - v'(a_i)|$.

Como se definió anteriormente, \mathcal{L}_n contiene todos los vectores de probabilidad compuestos de $|\Sigma|$ componentes del conjunto A , por lo que, para toda $v \in M_1$ (existe un $v' \in \mathcal{L}_n$ con $|v(a_i) - v'(a_i)| \leq \frac{1}{n}$ para $i = 1, \dots, |\Sigma|$; y por la iguald

anterior

$$d_V(v, v') = \frac{1}{2} \sum_{i=1}^{|\Sigma|} |v(a_i) - v'(a_i)| \leq \frac{|\Sigma|}{2n}.$$

en lo que se tiene el resultado.

Observemos que para cada $v \in \mathcal{L}_n$ existen distintas sucesiones $y = (y_1, \dots, y_n)$ que inducen la medida empírica v . Esto nos lleva a la siguiente definición.

Definición 2.1.2. La **clase tipo** $T_n(v)$ de una distribución de probabilidad $v \in \mathcal{L}_n$ es el conjunto $T_n(v) = \{y \in \Sigma^n : L_n^y = v\}$.

Note que una clase tipo consiste de todas las permutaciones de un vector dado en el conjunto. En la siguiente definición se usará la convención $0 \log 0 := 0$ y $\log(0/0) := 0$.

Definición 2.1.3. Entropía y Entropía Relativa.

a) La entropía de un vector de probabilidad v es

$$H(v) := - \sum_{i=1}^{|\Sigma|} v(a_i) \log v(a_i).$$

b) La entropía relativa de un vector de probabilidad v con respecto a otro vector de probabilidad μ es

$$H(v | \mu) := \sum_{i=1}^{|\Sigma|} v(a_i) \log \frac{v(a_i)}{\mu(a_i)}.$$

Nota : El nombre de entropía de un vector de probabilidad v , $H(v)$, es un término conocido en el área de teoría de la información. Esta cantidad es interpretada como la cantidad promedio de información recibida cuando el valor v es observado. Otra interpretación es , $H(v)$ mide la no-uniformidad de la medida de probabilidad. A la entropía también se le conoce con el nombre de entropía de Shannon. Al final de este capítulo veremos un ejemplo en este contexto.

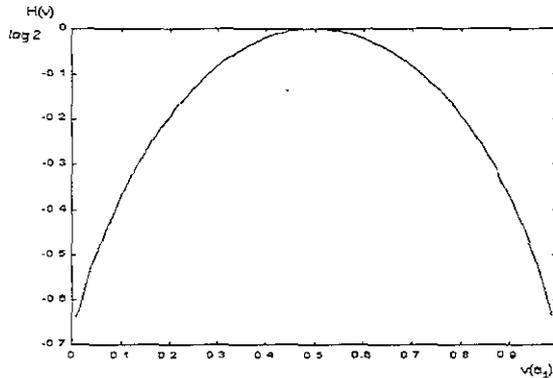


Figura 7. $H(v)$ para $|\Sigma| = 2$.

Demostremos ahora que la entropía relativa es una función de tasa buena es decir, no negativa, semicontinua inferiormente y para todo $a \in \mathbb{R}$ el conjunto $\{v : H(\cdot|\mu) \geq a\}$ es compacto, (ver definición 1.4.2). Veamos que $H(\cdot|\mu)$ es una función no negativa. La desigualdad de Jensen afirma que: si X es una variable aleatoria y $U : \mathbb{R} \rightarrow \mathbb{R}$ una función convexa, entonces, $E(U(X)) \geq U(E(X))$. Si aplicamos esta desigualdad a la función convexa $x \log x$ tenemos que $E(x \log x) \geq E(x) \log E(x)$. Sea $v \in M_1(\Sigma)$ y con $x = \frac{v(a_i)}{\mu(a_i)}$ se tiene

$$\begin{aligned} H(v|\mu) &= \sum_{i=1}^{\Sigma} v(a_i) \log \frac{v(a_i)}{\mu(a_i)} = \sum_{i=1}^{\Sigma} \frac{v(a_i)}{\mu(a_i)} \log \left(\frac{v(a_i)}{\mu(a_i)} \right) \mu(a_i) \\ &\geq \sum_{i=1}^{\Sigma} \frac{v(a_i)}{\mu(a_i)} \mu(a_i) \log \sum_{i=1}^{\Sigma} \frac{v(a_i)}{\mu(a_i)} \mu(a_i) \\ &= \log 1 = 0 \end{aligned}$$

por lo que $H(v|\mu)$ es no negativa.

Además, $H(\cdot|\mu)$ es continua en el conjunto compacto $\{v \in M_1(\Sigma) : \Sigma_v \subset \Sigma_\mu\}$ ya que $x \log x$ es continua en $0 \leq x \leq 1$ y $H(v|\mu) = \infty$ en el complemento de este conjunto, de donde se sigue que $H(\cdot|\mu)$ es una función de tasa buena.

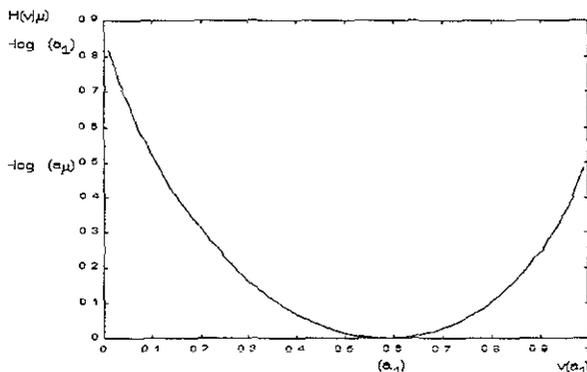


Figura 8. $H(v|\mu)$ para $|\Sigma| = 2$. y $\mu = (0.5842, .4158)$.

Los siguientes tres lemas nos dan estimaciones de las probabilidades de los eventos $\{L_n^Y = v\}$, $v \in \mathcal{L}_n$, los cuales son eventos raros. Primero se demuestra que los resultados que pertenecen a la misma clase tipo son igualmente probables, y luego se estima el crecimiento exponencial de la tasa de cada clase tipo.

Sea \mathbb{P}_μ la ley de probabilidad $\mu^{\mathbb{Z}^n}$ - asociada a una sucesión infinita de v.a.i.i.d. $\{Y_j\}$ distribuidas de acuerdo a $\mu \in M_1(\Sigma)$. En el siguiente lema veremos que las sucesiones que pertenecen a la misma clase tipo tienen la misma probabilidad.

Lema 2.1.2. Si $y \in T_n(v)$ para $v \in \mathcal{L}_n$, entonces

$$\mathbb{P}_\mu((Y_1, Y_2, \dots, Y_n) = \mathbf{y}) = e^{-n[H(v)+H(v|\mu)]}.$$

Demostración.

Por la propiedad de independencia tenemos que

$$\mathbb{P}_\mu((Y_1, Y_2, \dots, Y_n) = \mathbf{y}) = \prod_{i=1}^{|\Sigma|} \mathbb{P}_\mu(Y_i = y_i)$$

por la definición de **tipo** (ver 2.1.1) se tiene

$$\begin{aligned} \prod_{i=1}^{|\Sigma|} \mathbb{P}_\mu(Y_i = y_i) &= \prod_{i=1}^{|\Sigma|} \mu(a_i)^{nv(a_i)} \\ &= \exp \left(\log \left(\prod_{i=1}^{|\Sigma|} \mu(a_i)^{nv(a_i)} \right) \right) \end{aligned}$$

$$\begin{aligned}
&= \exp \left(n \sum_{i=1}^{|\Sigma|} v(a_i) \log (\mu(a_i)) \right) \\
&= e^{-n[H(v)+H(v|\mu)]}
\end{aligned}$$

donde la última igualdad se explica debido a que

$$\begin{aligned}
-[H(v) + H(v | \mu)] &= - \sum_{i=1}^{|\Sigma|} v(a_i) \left(\log \frac{v(a_i)}{\mu(a_i)} - \log v(a_i) \right) \\
&= \sum_{i=1}^{|\Sigma|} v(a_i) \log \mu(a_i).
\end{aligned}$$

En particular, debido a que $H(\mu | \mu) = 0$, se sigue que para todo $\mu \in \mathcal{L}_n$ y $y \in T_n(\mu)$

$$\mathbb{P}_\mu((Y_1, Y_2, \dots, Y_n) = y) = e^{-nH(\mu)}. \quad 2.1$$

Con lo que se concluye la demostración.

Se tiene una estimación de la cardinalidad de la clase tipo.

Lema 2.1.3. *Para todo $v \in \mathcal{L}_n$,*

$$(n+1)^{-|\Sigma|} e^{nH(v)} \leq |T_n(v)| \leq e^{nH(v)}.$$

Observación.

Como la clase tipo $T_n(v)$ consiste de todas las diferentes permutaciones de elementos del vector dado en el conjunto, de los cuales $nv(a_i)$, ($i = 1, \dots, |\Sigma|$) son iguales, tenemos que,

$$|T_n(v)| = \frac{n!}{(nv(a_1))! \dots (nv(a_{|\Sigma|}))!} \quad i = 1, 2, \dots, |\Sigma|. \quad 2.2$$

Usando la aproximación de Stirling se puede obtener una estimación de $|T_n(v)|$ la cual se puede ver en [Fel71].

Otra manera de obtener una estimación para $|T_n(v)|$ se muestra aquí.

Demostración.

Bajo \mathbb{P}_v , cualquier clase tipo tiene probabilidad a lo más uno y todos los eventos son equiprobables. Por lo que, para todo $v \in \mathcal{L}_n$ y por la ecuación 2.2.

enemos

$$1 \geq \mathbb{P}_v(L_n^Y = v) = \mathbb{P}_v((Y_1, \dots, Y_n) \in T_n(v)) = e^{-nH(v)} |T_n(v)|$$

por lo tanto

$$|T_n(v)| \leq e^{nH(v)}.$$

Encontraremos ahora la cota inferior. Sea $v' \in \mathcal{L}_n$ tal que $\Sigma_{v'} \subset \Sigma_v$, y por conveniencia de notación restringiremos Σ de manera tal que $\Sigma_v = \Sigma$. Entonces,

$$\begin{aligned} \frac{\mathbb{P}_v(L_n^Y = v)}{\mathbb{P}_v(L_n^Y = v')} &= \frac{|T_n(v)| \prod_{i=1}^{|\Sigma|} v(a_i)^{nv(a_i)}}{|T_n(v')| \prod_{i=1}^{|\Sigma|} v(a_i)^{nv'(a_i)}} \\ &= \frac{(nv'(a_1))! \dots (nv'(a_{|\Sigma|}))!}{(nv(a_1))! \dots (nv(a_{|\Sigma|}))!} \prod_{i=1}^{|\Sigma|} v(a_i)^{(nv(a_i) - nv'(a_i))} \quad \text{por 2.1.3} \\ &= \prod_{i=1}^{|\Sigma|} \frac{(nv'(a_i))!}{(nv(a_i))!} v(a_i)^{(nv(a_i) - nv'(a_i))}. \end{aligned}$$

Esta última expresión es un producto de términos de la forma $\frac{m!}{\ell!} \left(\frac{\ell}{n}\right)^{\ell-m}$. Veamos que $\frac{m!}{\ell!} \geq \ell^{m-\ell}$ para todo $m, \ell \in \mathbb{Z}^+$. Consideremos el caso $m \geq \ell$ (para $m < \ell$ la prueba es similar), entonces existe $k \in \mathbb{Z}^+$ tal que $m = \ell + k$, así

$$\frac{m!}{\ell!} = (m)(m-1) \dots (m-(k-1)) \geq \ell^k = \ell^{m-\ell}.$$

De la desigualdad anterior con $m = nv'(a_i)$ y $\ell = nv(a_i)$ obtenemos que

$$\begin{aligned} \frac{\mathbb{P}_v(L_n^Y = v)}{\mathbb{P}_v(L_n^Y = v')} &= \prod_{i=1}^{|\Sigma|} \frac{(nv'(a_i))!}{(nv(a_i))!} v(a_i)^{nv(a_i) - nv'(a_i)} \\ &\geq \prod_{i=1}^{|\Sigma|} (nv(a_i))^{nv'(a_i) - nv(a_i)} [v(a_i)]^{nv(a_i) - nv'(a_i)} \\ &= \prod_{i=1}^{|\Sigma|} n^{nv'(a_i) - nv(a_i)} \\ &= n^{n(\sum_{i=1}^{|\Sigma|} v'(a_i) - \sum_{i=1}^{|\Sigma|} v(a_i))} = 1. \end{aligned}$$

Notemos que $\mathbb{P}_v(L_n^Y = v) > 0$ solamente cuando $\Sigma_{v'} \subset \Sigma_v$ y $v' \in \mathcal{L}_n$, por tanto lo anterior implica que para todo $v, v' \in \mathcal{L}_n$

$$\mathbb{P}_v(L_n^Y = v) \geq \mathbb{P}_v(L_n^Y = v')$$

con lo que

$$\begin{aligned} 1 &= \sum_{v' \in \mathcal{L}_n} \mathbb{P}_v(L_n^Y = v') \leq |\mathcal{L}_n| \mathbb{P}_v(L_n^Y = v) \\ &= |\mathcal{L}_n| e^{-nH(v)} |T_n(v)| \\ &\leq (n+1)^{|\Sigma|} e^{-nH(v)} |T_n(v)|, \end{aligned}$$

la última desigualdad se sigue del lema 2.1.1 y así obtenemos la cota inferior

$$|T_n(v)| \geq (n+1)^{-|\Sigma|} e^{nH(v)}.$$

Lema 2.1.4 (Estimación de Grandes Desviaciones). *Para cualquier $v \in \mathcal{L}_n$*

$$(n+1)^{-|\Sigma|} e^{-nH(v|\mu)} \leq \mathbb{P}_\mu(L_n^Y = v) \leq e^{-nH(v|\mu)}.$$

Demostración. La prueba es sencilla aplicando los lemas antes demostrados. Por el lema 2.1.2.

$$\begin{aligned} \mathbb{P}_\mu(L_n^Y = v) &= |T_n(v)| \mathbb{P}_\mu((Y_1, \dots, Y_n) = \mathbf{y}, L_n^Y = v) \\ &= |T_n(v)| e^{-n[H(v) + H(v|\mu)]} \\ &\leq e^{nH(v)} e^{-n[H(v) + H(v|\mu)]} = e^{-n[H(v) + H(v|\mu)]}. \end{aligned}$$

La última desigualdad se tiene del lema 2.1.3 y por la cota inferior del mismo lema se concluye la demostración.

Veamos ahora el teorema de Sanov, el cual establece que la familia de distribuciones de probabilidad $\mathbb{P}_\mu(L_n^Y \in \cdot)$ satisface el PGD con función de tasa $H(\cdot|\mu)$. Comparese este resultado con 1.4.7.

Teorema 2.1 (Sanov). *Para todo conjunto Γ de vectores de probabilidad $\mathcal{M}_1(\Sigma)$.*

$$\begin{aligned} - \inf_{v \in \Gamma^\circ} H(v | \mu) &\leq \liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}_\mu(L_n^Y \in \Gamma) \\ &\leq \lim_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}_\mu(L_n^Y \in \Gamma) \leq - \inf_{v \in \Gamma} H(v | \mu) \end{aligned} \quad 2.$$

donde Γ° es el interior de $\Gamma \subset \mathbb{R}^{|\Sigma|}$.

Demostación.

Por el lema 2.1.1 y la cota superior del lema 2.1.4

$$\begin{aligned}
 \mathbb{P}_\mu(L_n^Y \in \Gamma) &= \sum_{v \in \Gamma \cap \mathcal{L}_n} \mathbb{P}_\mu(L_n^Y = v) \\
 &\leq \sum_{v \in \Gamma \cap \mathcal{L}_n} e^{-nH(v|\mu)} \\
 &\leq |\Gamma \cap \mathcal{L}_n| e^{-n \inf_{v \in \Gamma \cap \mathcal{L}_n} H(v|\mu)} \\
 &\leq (n+1)^{|\Sigma|} e^{-n \inf_{v \in \Gamma \cap \mathcal{L}_n} H(v|\mu)}
 \end{aligned}
 \tag{2.1.5}$$

Por la cota inferior del mismo lema se tiene

$$\begin{aligned}
 \mathbb{P}_\mu(L_n^Y \in \Gamma) &= \sum_{v \in \Gamma \cap \mathcal{L}_n} \mathbb{P}_\mu(L_n^Y = v) \\
 &= \sum_{v \in \Gamma \cap \mathcal{L}_n} (n+1)^{-|\Sigma|} e^{-nH(v|\mu)} \\
 &\geq (n+1)^{-|\Sigma|} e^{-n \inf_{v \in \Gamma \cap \mathcal{L}_n} H(v|\mu)}.
 \end{aligned}
 \tag{2.1.6}$$

Dividimos entre n , tomando logaritmo y límite superior en 2.1.5 y 2.1.6, debido a que $\lim_{n \rightarrow \infty} \frac{1}{n} \log(n+1)^{|\Sigma|} = 0$ tenemos

$$\begin{aligned}
 \overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log(\mathbb{P}_\mu(L_n^Y \in \Gamma)) &\leq \overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log((n+1)^{|\Sigma|} e^{-n \inf_{v \in \Gamma \cap \mathcal{L}_n} H(v|\mu)}) \\
 &= \lim_{n \rightarrow \infty} \frac{1}{n} \log(n+1)^{|\Sigma|} + \overline{\lim}_{n \rightarrow \infty} \left(- \inf_{v \in \Gamma \cap \mathcal{L}_n} H(v|\mu) \right) \\
 &= \overline{\lim}_{n \rightarrow \infty} \left(- \inf_{v \in \Gamma \cap \mathcal{L}_n} H(v|\mu) \right)
 \end{aligned}$$

$$\begin{aligned}
 \overline{\lim}_{n \rightarrow \infty} \log(\mathbb{P}_\mu(L_n^Y \in \Gamma)) &\geq \overline{\lim}_{n \rightarrow \infty} \log((n+1)^{-|\Sigma|} e^{-n \inf_{v \in \Gamma \cap \mathcal{L}_n} H(v|\mu)}) \\
 &\geq \overline{\lim}_{n \rightarrow \infty} \left(- \inf_{v \in \Gamma \cap \mathcal{L}_n} H(v|\mu) \right)
 \end{aligned}$$

lo que,

$$\begin{aligned}
 \overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log(\mathbb{P}_\mu(L_n^Y \in \Gamma)) &= \overline{\lim}_{n \rightarrow \infty} \left(- \inf_{v \in \Gamma \cap \mathcal{L}_n} H(v|\mu) \right) \\
 &= - \underline{\lim}_{n \rightarrow \infty} \left(\inf_{v \in \Gamma \cap \mathcal{L}_n} H(v|\mu) \right)
 \end{aligned}
 \tag{2.1.7}$$

donde la última igualdad es cierta por propiedades de límite superior e inferior. De igual manera, como en 2.1.7, obtenemos una igualdad para el límite inferior

$$\begin{aligned} \liminf_{n \rightarrow \infty} \frac{1}{n} \log(\mathbb{P}_\mu(L_n^Y \in \Gamma)) &= \liminf_{n \rightarrow \infty} \left(- \inf_{v \in \Gamma \cap \mathcal{L}_n} H(v | \mu) \right) \\ &= - \overline{\lim}_{n \rightarrow \infty} \left(\inf_{v \in \Gamma \cap \mathcal{L}_n} H(v | \mu) \right). \end{aligned} \quad 2.$$

Para obtener la cota superior en la ecuación 2.1.4, observemos que $\Gamma \cap \mathcal{L}_n \subset \Gamma$ para todo n , se sigue que $\inf_{v \in \Gamma \cap \mathcal{L}_n} H(v | \mu) \geq \inf_{v \in \Gamma} H(v | \mu)$. Entonces

$$- \liminf_{n \rightarrow \infty} \inf_{v \in \Gamma \cap \mathcal{L}_n} H(v | \mu) \leq - \liminf_{n \rightarrow \infty} \inf_{v \in \Gamma} H(v | \mu) = - \inf_{v \in \Gamma} H(v | \mu)$$

y por la ecuación 2.1.7 se tiene el resultado.

Ahora obtendremos la cota inferior en 2.1.4. Fijemos un punto arbitrario $v \in \Gamma^\circ$ tal que $\Sigma_v \subset \Sigma_\mu$, entonces para un $\delta > 0$ suficientemente pequeño, el conjunto $\{v' : d_V(v, v') < \delta\}$ está contenido en Γ , por el inciso (b) del lema 2.1.1 existe una sucesión $v_n \subset \Gamma$ tal que $v_n \xrightarrow{n \rightarrow \infty} v$ para toda v en $M_1(\Sigma)$. Además, por pérdida de generalidad, supongamos que $\Sigma_{v_n} \subset \Sigma_\mu$, y como $v_n \subset \Gamma \cap \mathcal{L}_n$ para toda n , entonces

$$\begin{aligned} \inf_{v' \in \Gamma \cap \mathcal{L}_n} \{H(v' | \mu)\} &\leq H(v_n | \mu) \\ \overline{\lim}_{n \rightarrow \infty} \left\{ \inf_{v' \in \Gamma \cap \mathcal{L}_n} H(v' | \mu) \right\} &\leq \overline{\lim}_{n \rightarrow \infty} H(v_n | \mu) = -H(v | \mu) \\ - \overline{\lim}_{n \rightarrow \infty} \left\{ \inf_{v' \in \Gamma \cap \mathcal{L}_n} H(v' | \mu) \right\} &\geq -H(v | \mu). \end{aligned}$$

Recordemos que $H(v | \mu) = \infty$ cuando el soporte de v no está contenido en el soporte de μ , es decir, para algún $i \in \{1, 2, \dots, |\Sigma|\}$, $v(a_i) > 0$ mientras que $\mu(a_i) = 0$. Por lo tanto, por la desigualdad anterior tenemos,

$$\begin{aligned} - \overline{\lim}_{n \rightarrow \infty} \left\{ \inf_{v \in \Gamma \cap \mathcal{L}_n} H(v | \mu) \right\} &\geq \inf_{v \in \Gamma^\circ} \{-H(v | \mu)\} \\ &= - \inf_{v \in \Gamma^\circ} \{H(v | \mu)\} \end{aligned}$$

y aplicando la igualdad 2.1.8 obtenemos la cota inferior del teorema de Sancho

2 Aplicación en Teoría de la Información.

En esta sección no pretendemos dar una exposición completa de las ideas principales en teoría de la información. Veremos que, como una aplicación del teorema de Sanov obtenemos un resultado muy importante en esta área. Se verá como la definición de entropía de Shannon surge a partir de la función de tasa de grandes desviaciones. Consideremos el siguiente problema, sea $\Sigma = \{a_1, \dots, a_r\}$ un alfabeto finito con $|\Sigma| = r$. Pensemos en un lenguaje escrito usando este alfabeto tal forma que asignamos probabilidades a cada una de las letras; estas representan la frecuencia relativa de ocurrencia de las letras en textos escritos con el lenguaje. Escribimos p_k para la frecuencia relativa de la letra a_k . Supongamos que no hay correlación entre las letras y entonces la probabilidad de un texto será el producto de las probabilidades de las letras. Es decir, la sucesión de letras en cualquier texto es una sucesión independiente e idénticamente distribuidas de letras aleatorias. Sea Ω_n el conjunto de todos los textos que contienen exactamente n letras; entonces la probabilidad del texto $\omega = (\omega_1, \omega_2, \dots, \omega_n)$ es $p_1^{n_1} \dots p_r^{n_r}$, donde cada una de las ω_i representa una letra y n_k es el número de ocurrencias de la letra a_k en el texto ω . Escribamos $\mathbb{P}(\omega) = p_1^{n_1} \dots p_r^{n_r}$ para denotar explícitamente la dependencia de esta probabilidad en el texto.

Claude Shannon hizo un descubrimiento notable: Si algunas letras son más probables, es decir, aparecen más frecuentemente, entonces existe un subconjunto Γ_n de Ω_n que consiste de “textos típicos” con las siguientes propiedades:

- Los textos que no están en Γ_n ocurren muy raramente, de manera que $\mathbb{P}(\Gamma_n) = \sum_{\omega \in \Gamma_n} \mathbb{P}(\omega)$ es casi uno.
- Para n grande, Γ_n es mucho más pequeño que Ω_n

$$\frac{\#\Gamma_n}{\#\Omega_n} \approx e^{-n\delta} \quad \text{para alguna } \delta > 0.$$

- Todos los textos en Γ_n tienen aproximadamente la misma probabilidad.

Este resultado es conocido como la *Propiedad de Equipartición Asintótica* o *EA*. Como sabemos, para un vector de probabilidad p (donde $p_i = \mathbb{P}(Y = a_i)$,

para Y v.a. con $i = 1, \dots, |\Sigma|$), la entropía de Shannon está definida por

$$H(p) = \sum_{i=1}^r p_i \log p_i.$$

Sabemos que $0 \leq H(p) \leq \log r$; la función de entropía alcanza su valor máximo cuando todas las p_k son iguales. El número de elementos en Ω_n es

$$\#\Omega_n = r^n = e^{n \log r},$$

por lo que la cardinalidad crece exponencialmente en n . El número de elementos en Γ_n también crece exponencialmente en n , y la entropía de Shannon nos da la tasa de crecimiento

$$\#\Gamma_n \approx e^{nH(p)},$$

por lo tanto, por la segunda parte del PEA tenemos que

$$\frac{\#\Gamma_n}{\#\Omega_n} \approx e^{-n(H(p) - \log r)},$$

donde la constante δ es la diferencia en las tasas de crecimiento, es decir, $\delta = \log r - H(p)$.

Si la distribución de probabilidad de p es muy diferente a la distribución de probabilidad uniforme, entonces $H(p) < \log r$ y Γ_n es significativamente más pequeño que Ω_n aún para valores de n cercanos a 1.

Nota: Debido a las aplicaciones de teoría de la información a la computación e ingeniería computacional, un alfabeto binario es frecuentemente considerado tal manera que $r = 2$, $a_1 = 0$, $a_2 = 1$ y la entropía de Shannon es frecuentemente definida usando logaritmo en base 2 en lugar del logaritmo natural; en este caso la entropía máxima es uno.

Para demostrar la PEA, ubicamos el problema en el contexto del teorema de Sanov. Sean Y_i v.a.i.i.d. con distribución de probabilidad p para todo i . La variable aleatoria toma la i -ésima letra en el texto, es decir, si $\omega = (\omega_1, \dots, \omega_n)$ entonces $Y_i(\omega) = \omega_i$. Como antes, para cada $a \in A$, sea $1_a(\cdot)$ la función indicadora definida sobre los subconjuntos de A por

$$1_a(B) = \begin{cases} 1 & \text{si } a \in B \\ 0 & \text{e.o.c.} \end{cases}$$

$$L_n^Y(\omega, B) = \frac{1}{n} \sum_{i=1}^n 1_{Y_i(\omega)}(B)$$

nde L_n es llamada la distribución empírica ya que $L_n(\omega, \{a_k\}) = n_k/n$, donde es el número de ocurrencias de la letra a_k en el texto ω . Aplicaremos ahora el teorema de Sanov a $\{L_n^Y\}$, el cual nos dice que existe una función convexa $I(\cdot)$ sobre el espacio de probabilidad $M(\Sigma)$ tal que para todo $v \in M(\Sigma)$ (v representa una medida de distribución empírica de cualquier texto $\omega \in \Omega_n$).

$$\mathbb{P}(L_n^Y = v) \approx e^{-nI(v)}$$

Por el teorema sabemos que $I(v) = \sum_{i=1}^r v(a_i) \log \frac{v(a_i)}{p_i}$, es decir $H(v | p)$, a la cual también se le conoce por *Divergencia Informacional*.

En el teorema de Sanov, la función de tasa es $H(v | p)$; ésta se hace cero si y sólo si $v = p$, y tenemos que

$$\lim_{n \rightarrow \infty} \mathbb{P}(L_n^Y = p) = 1,$$

es decir sigue que si elegimos Γ_n como aquellos textos en los cuales las frecuencias relativas de las letras son cercanas a las especificadas por p , entonces $\mathbb{P}(\Gamma_n)$ convergerá a 1 si n crece. Por lo tanto, Γ_n consiste de los textos más probables y por lo tanto, los textos que no pertenecen a Γ_n ocurren raramente. Para estimar el tamaño de Γ_n , aplicaremos el teorema de Sanov por segunda ocasión. Sea β una distribución de probabilidad uniforme, la cual asigna probabilidad $1/r$ a cada una de las r letras en Σ ; entonces la probabilidad $\mathbb{P}_\beta(\Gamma_n) = \#\Gamma_n / \#\Omega_n$. Ahora, β es el conjunto de los textos ω para los cuales $L_n^Y(\omega)$ está cercano a p , por lo tanto podemos aplicar el teorema de Sanov a la distribución de L_n^Y con respecto a β , así,

$$\mathbb{P}_\beta(\Gamma_n) = \mathbb{P}_\beta(L_n^Y = p) \approx e^{-nH(p|\beta)}.$$

Entonces

$$\begin{aligned} H(p | \beta) &= p_1(\log p_1 - \log \frac{1}{r}) + \dots + p_r(\log p_r - \log \frac{1}{r}) \\ &= \log r - H(p) \\ &= \delta \end{aligned}$$

Por lo tanto, $\frac{\#\Gamma_n}{\#\Omega_n} \approx e^{-n\delta}$. Con lo que demostramos la segunda parte de la PEA.

2.3 El Teorema de Cramér para Alfabetos Finitos en \mathbb{R}

Mostraremos, como aplicación del teorema de Sanov, una versión del teorema de Cramér para Grandes Desviaciones de la media empírica de v.a.i.i.d. Como en la sección anterior, las v.a. toman valores en un conjunto finito. Consideremos $\bar{S}_n = \frac{1}{n} \sum_{j=1}^n X_j$, donde $X_j = f(Y_j)$, $f : \Sigma \rightarrow \mathbb{R}$ y $\{Y_j\} \in \Sigma$ son v.a.i.i.d. con distribución de probabilidad μ , sin pérdida de generalidad asumiremos que $\Sigma = \Sigma_\mu$ y que $f(a_1) < f(a_2) < \dots < f(a_{|\Sigma|})$. El teorema de Cramér establece un PGD asociado a la sucesión de v.a. \bar{S}_n que toman valores en un conjunto finito. En el siguiente capítulo se demostrará el caso en que las v.a. toman valores reales. Por ahora, en el caso que nos encontramos observemos que las v.a. \bar{S}_n toman valores en el intervalo compacto $K := [f(a_1), f(a_{|\Sigma|})]$, además se puede escribir de la siguiente manera $\bar{S}_n = \sum_{i=1}^{|\Sigma|} f(a_i) L_n^Y(a_i) := \langle f, L_n^Y \rangle$. Por lo tanto, para todo conjunto A y todo entero n ,

$$\bar{S}_n \in A \iff L_n^Y \in \{v : \langle f, v \rangle \in A\} := \Gamma. \quad 2.3.1$$

Por lo anterior, la siguiente versión del teorema de Cramér es una consecuencia directa del Teorema de Sanov.

Teorema 2.2. *Para todo conjunto $A \subset \mathbb{R}$,*

$$\begin{aligned} - \inf_{x \in A^\circ} I(x) &\leq \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}_\mu(\bar{S}_n \in A) \\ &\leq \overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}_\mu(\bar{S}_n \in A) \leq - \inf_{x \in A} I(x) \end{aligned} \quad 2.3.2$$

donde A° es el interior de A y definimos $I(x) := \inf_{\{v : \langle f, v \rangle = x\}} H(v \mid \mu)$. La función de tasa $I(x)$ es continua para $x \in K$ y satisface además que

$$I(x) = \sup_{\lambda \in \mathbb{R}} \{\lambda x - \Lambda(\lambda)\}, \quad 2.3.3$$

donde

$$\Lambda(\lambda) = \log \sum_{i=1}^{|\Sigma|} \mu(a_i) e^{\lambda f(a_i)}. \quad 2.3.4$$

Observación. Como la función de tasa $I(\cdot)$ es continua en el conjunto compacto K , se sigue de 2.3.2 que si $A \subset \bar{A}^\circ \subseteq K$ se cumple que

$$\lim_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}_\mu(\bar{S}_n \in A) = - \inf_{x \in A} I(x).$$

Comentario. La función de tasa $I(x)$ como se define en 2.3.3 también recibe nombre de transformada de Cramér o transformada de Fenchel-Legendre y la función $\Lambda(\lambda)$ en 2.3.4 recibe el nombre de función log-Laplace o función generadora logarítmica. En el siguiente capítulo se verán propiedades importantes de estas funciones.

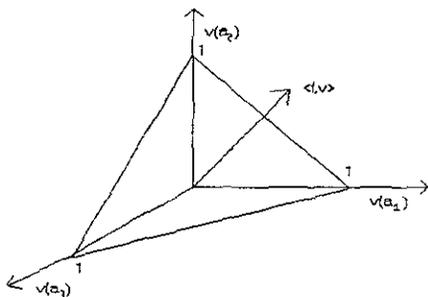


Figura 9. $M_1(\Sigma)$ para $|\Sigma| = 3$ y $\langle f, v \rangle$.

Demostración.

Cuando el conjunto A es abierto, el conjunto Γ de 2.3.1 también lo es, además, las cotas del teorema son las mismas que las del teorema de Sanov(2.1) para Γ . Solo falta mostrar que $I(x)$ satisface la ecuación 2.3.3. Por la desigualdad de Jensen tenemos que si X es una v.a., y $U : \mathbb{R} \rightarrow \mathbb{R}$ una función cóncava, entonces

$$\mathbb{E}(U(X)) \leq U(\mathbb{E}(X)).$$

Aplicando esta desigualdad a la función cóncava $\log x$, tenemos que para todo $\lambda \in M_1(|\Sigma|)$, y todo $\lambda \in \mathbb{R}$

$$\begin{aligned} \Lambda(\lambda) &= \log \sum_{i=1}^{|\Sigma|} \mu(a_i) e^{\lambda f(a_i)} \\ &= \log \sum_{i=1}^{|\Sigma|} \frac{\mu(a_i) e^{\lambda f(a_i)}}{v(a_i)} v(a_i) \\ &\geq \mathbb{E}_v \left(\log \frac{\mu(a_i) e^{\lambda f(a_i)}}{v(a_i)} \right) \end{aligned}$$

$$\begin{aligned}
&= \sum_{i=1}^{|\Sigma|} v(a_i) \log \left(\frac{\mu(a_i) e^{\lambda f(a_i)}}{v(a_i)} \right) \\
&= \sum_{i=1}^{|\Sigma|} v(a_i) \log \mu(a_i) + \sum_{i=1}^{|\Sigma|} v(a_i) \lambda f(a_i) - \sum_{i=1}^{|\Sigma|} v(a_i) \log v(a_i) \\
&= \sum_{i=1}^{|\Sigma|} \lambda f(a_i) v(a_i) - \sum_{i=1}^{|\Sigma|} v(a_i) \log v(a_i) + \sum_{i=1}^{|\Sigma|} v(a_i) \log \mu(a_i) \\
&= \lambda \langle f, v \rangle - H(v | \mu)
\end{aligned}$$

por lo que,

$$\Lambda(\lambda) \geq \lambda \langle f, v \rangle - H(v | \mu) \quad 2.3.5$$

y la igualdad se cumple para $v(a_i) = \mu(a_i) e^{\lambda f(a_i) - \Lambda(\lambda)}$, para verificar esto, sustituimos el valor de $v(a_i)$ en el miembro derecho de la ecuación anterior, así

$$\begin{aligned}
\sum_{i=1}^{|\Sigma|} v(a_i) \log \frac{\mu(a_i) e^{\lambda f(a_i)}}{v(a_i)} &= \sum_{i=1}^{|\Sigma|} \mu(a_i) e^{\lambda f(a_i) - \Lambda(\lambda)} \log \left(\frac{\mu(a_i) e^{\lambda f(a_i)}}{\mu(a_i) e^{\lambda f(a_i) - \Lambda(\lambda)}} \right) \\
&= e^{-\Lambda(\lambda)} \Lambda(\lambda) \sum_{i=1}^{|\Sigma|} \mu(a_i) e^{\lambda f(a_i)} \\
&= e^{-\Lambda(\lambda)} \cdot e^{\Lambda(\lambda)} \cdot \Lambda(\lambda) \\
&= \Lambda(\lambda).
\end{aligned}$$

Como la ecuación 2.3.5 es válida para todo $v \in M_1(\Sigma)$ y todo $\lambda \in \mathbb{R}$, se tiene

$$\lambda x - \Lambda(\lambda) \leq \inf_{\{v: \langle f, v \rangle = x\}} H(v | \mu) = I(x)$$

por lo tanto,

$$\sup_{\lambda \in \mathbb{R}} \{\lambda x - \Lambda(\lambda)\} \leq \inf_{\{v: \langle f, v \rangle = x\}} H(v | \mu) = I(x)$$

y la igualdad se da para $x = \langle f, v_\lambda \rangle$.

La función log-Laplace $\Lambda(\lambda)$ es diferenciable (en el siguiente capítulo daremos una demostración de este hecho) y su derivada es $\Lambda'(\lambda) = \frac{\mathbb{E}(f(x) e^{\lambda f(x)})}{\mathbb{E} e^{\lambda f(x)}}$. Simplif

do la expresión para $\Lambda(\lambda)$, tenemos,

$$\begin{aligned} \Lambda'(\lambda) &= \frac{\mathbb{E}(f(x)e^{\lambda f(x)})}{\mathbb{E}e^{\lambda f(x)}} \\ &= e^{-\Lambda(\lambda)}\mathbb{E}(f(x)e^{\lambda f(x)}) \\ &= \sum_{i=1}^{|\Sigma|} f(a_i)e^{\lambda f(a_i)}e^{-\Lambda(\lambda)} \\ &= \sum_{i=1}^{|\Sigma|} f(a_i)e^{\lambda f(a_i)-\Lambda(\lambda)} \\ &= \langle f, v_\lambda \rangle. \end{aligned}$$

Por lo que $\Lambda'(\lambda) = \langle f, v_\lambda \rangle$ y entonces la ecuación 2.3.3 es válida para todas las x tales que $x \in \{\Lambda'(\lambda) : \lambda \in \mathbb{R}\}$.

Ya que $\Lambda(\lambda)$ es una función estrictamente convexa, entonces $\Lambda(\lambda)$ es estrictamente creciente, de lo cual, por el supuesto que hicimos al inicio sobre f resulta que $f(a_1) = \inf_\lambda \Lambda'(\lambda)$ y $f(a_{|\Sigma|}) = \sup_\lambda \Lambda'(\lambda)$. Por lo tanto, 2.3.3 funciona para todas las $x \in K^o$. Consideremos ahora el punto inicial de K , $x = f(a_1)$, y sea $\mu(a_1) = 1$ tal que $\langle f, v^* \rangle = x$ por lo que $H(v^* | \mu) = -\log \mu(a_1)$, entonces

$$\begin{aligned} -\log \mu(a_1) &= H(v^* | \mu) \\ &\geq I(x) \\ &= \sup_{\lambda \in \mathbb{R}} \{\lambda x - \Lambda(\lambda)\} \\ &= \lim_{\lambda \rightarrow \infty} (\lambda x - \Lambda(\lambda)) \\ &= -\log \mu(a_1), \end{aligned}$$

Por lo tanto

$$I(x) = \sup_{\lambda \in \mathbb{R}} \{\lambda x - \Lambda(\lambda)\}$$

se cumple para $f(a_1)$. Análogamente se prueba para $f(a_{|\Sigma|})$. La continuidad de $I(x)$ para $x \in K$ es una consecuencia de la continuidad de la entropía relativa $H(v^* | \mu)$.

2.4 Aplicación en Teoría del Riesgo.

En la sección anterior vimos una versión del teorema de Cramér para la media empírica de una sucesión de v.a.i.i.d que tomaban valores en un alfabeto finito. En el siguiente capítulo veremos el teorema de Cramér en el caso que las variables aleatorias toman valores reales. Supongamos por ahora, para fines de esta sección que el teorema en su versión real es válido.

Como mencionamos antes, la teoría de grandes desviaciones se ha aplicado a distintos modelos en teoría del riesgo que pueden llegar a ser muy complejos. En esta continuación daremos un ejemplo de un modelo sencillo de como es hecho esto.

Supongamos que una compañía aseguradora recibe un número fijo de reclamaciones (una reclamación es un pago que debe hacer la aseguradora al beneficiario en caso de siniestro) en un periodo de tiempo dado, y supongamos también que recibe un ingreso producto del pago de primas, sea esta una cantidad k diaria. Como el importe de las reclamaciones es una variable aleatoria, existe el riesgo de que, al término de un período de tamaño T , la cantidad pagada a los asegurados exceda los ingresos de la compañía aseguradora en dicho periodo de tiempo. Este riesgo es inevitable, pero a la compañía le gustaría tener la certeza de que dicho evento ocurra muy raramente. Es decir, estamos interesados en las probabilidades pequeñas relacionadas con la suma de un número grande de variables aleatorias. Si las cantidades X_T de las reclamaciones son v.a.i.i.d., utilizaremos el Teorema de Cramér para calcular la probabilidad de que la cantidad $\sum_{t=1}^T X_t$ pagada durante el periodo T exceda los ingresos kT recibidos en dicho periodo. Esto es

$$\mathbb{P} \left(\sum_{t=1}^T X_t > kT \right) \approx e^{-TI(k)}.$$

Por lo que, si queremos asegurarnos que el riesgo de ruina sea pequeño, digamos de tamaño e^{-r} , para $r > 0$ suficientemente grande, podemos usar la función tasa $I(k)$ para hallar un valor apropiado de k .

$$\begin{aligned} \mathbb{P} \left(\frac{1}{T} \sum_{t=1}^T X_t > k \right) &\approx e^{-r} \\ e^{-TI(k)} &\approx e^{-r} \\ I(k) &\approx \frac{r}{T}. \end{aligned}$$

Dado que $I(x)$ es convexa, es monótonamente creciente para x mayor que la media de X_t , y por lo tanto la ecuación

$$I(k) = \frac{r}{T}$$

tiene solución única.

Por supuesto, para resolver ésta ecuación debemos conocer qué es $I(x)$, es decir, conocer las estadísticas de las cantidades de las reclamaciones. Veamos dos ejemplos:

- En primer lugar, supongamos que el tamaño de cada reclamación se distribuye binomial con media np . Calculamos la función de tasa como se indica en 2.3.3 y tenemos que

$$I(x) = x \log \left(\frac{x}{p} \right) + (n - x) \log \left(\frac{n - x}{1 - p} \right) - n \log n.$$

Si fijamos el valor de np , r y T , tenemos que resolver la ecuación

$$k \log \left(\frac{k}{p} \right) + (n - k) \log \left(\frac{n - k}{1 - p} \right) - n \log n = \frac{r}{T}.$$

La solución de la ecuación para k en este caso se obtiene numericamente.

- Ahora, supongamos que el tamaño de cada reclamación tiene distribución normal con media m y varianza σ^2 . En este caso utilizamos el teorema de Cramér Real y por la ecuación 3.1.1, que veremos más adelante, obtenemos la función de tasa

$$I(x) = \frac{1}{2} \left(\frac{x - m}{\sigma} \right)^2.$$

Notese que con $m = 0$ y $\sigma^2 = 1$ se tiene la función de tasa que se obtuvo en 1.2.1

La solución de la ecuación para k es en éste caso: $k = m + \sigma \sqrt{2r/T}$; por lo que el valor de la prima debería ser tal que el ingreso diario sea la media de las reclamaciones más una cantidad adicional para cubrir el riesgo; en éste caso, está dada por $\sigma \sqrt{2r/T}$. Observemos que σ es una medida de las fluctuaciones en la cantidad de las reclamaciones, mientras que $\sqrt{2r/T}$ es fijado por la aseguradora.

2.5 Grandes Desviaciones para Muestreo sin Reemplazo

Usaremos el método de Tipos para un procedimiento de uso común en muchos problemas de estadística, el muestreo sin reemplazo. Consideremos una urna con un número finito m de distintos objetos, definimos el vector $y = (y_1, \dots, y_m)$, el cual cada entrada representa un elemento de la urna, tomemos una muestra sin reemplazo de tamaño n a la que representaremos como una n -ada $Y = (y_{i_1}, \dots, y_{i_n})$, los índices $\{i_1, i_2, \dots, i_n\}$ se escogen aleatoriamente, de tal forma que cada subconjunto de n elementos distintos de $\{1, 2, \dots, m\}$ es igualmente probable.

Supongamos que para todo m , cada elemento del vector $(y_1^{(m)}, y_2^{(m)}, \dots, y_m^{(m)})$ pertenece al alfabeto finito $\Sigma = \{a_1, a_2, \dots, a_{|\Sigma|}\}$, además suponemos que el número de elementos en la urna depende del tamaño de la muestra, es decir $m = m(n)$, y si $n \rightarrow \infty$, los vectores deterministas de frecuencia relativa $L_m^Y = (L_m^Y(a_1), \dots, L_m^Y(a_{|\Sigma|}))$ convergen a una medida de probabilidad $\mu \in M_1(\Sigma)$ recordemos que

$$L_m^Y(a_i) = \frac{1}{m} \sum_{j=1}^m 1_{a_i}(y_j^{(m)}), \quad i = 1, 2, \dots, |\Sigma|.$$

Supongamos también que Y es un vector aleatorio obtenido del muestreo sin reemplazo al escoger n de m posibles elementos de la urna. Estableceremos el PGD para la media empírica aleatoria L_n^Y y veremos el análogo al Teorema de Sanov con $m = m(n)$ y $\lim_{n \rightarrow \infty} \frac{n}{m(n)} = \beta$, para $0 < \beta < 1$. Para ello consideremos la siguiente función de tasa

$$I(v \mid \beta, \mu) := \begin{cases} H(v \mid \mu) + \frac{1-\beta}{\beta} H\left(\frac{\mu - \beta v}{1-\beta} \mid \mu\right) & \text{si } \mu(a_i) \geq \beta v(a_i) \text{ para toda } a_i \\ \infty & \text{en otro caso.} \end{cases}$$

2.5

Veamos que cuando $\beta \rightarrow 0$, la función $I(\cdot \mid \beta, \mu)$ se simplifica a $H(\cdot \mid \mu)$, para lo cual desarrollamos $\frac{1-\beta}{\beta} H\left(\frac{\mu - \beta v}{1-\beta} \mid \mu\right)$ y tomando el límite cuando $\beta \rightarrow 0$ se tiene que

$$\lim_{\beta \rightarrow 0} \frac{1-\beta}{\beta} H\left(\frac{\mu - \beta v}{1-\beta} \mid \mu\right) = \lim_{\beta \rightarrow 0} \sum_{i=1}^{|\Sigma|} (\mu(a_i) - \beta v(a_i)) \cdot \frac{\log \frac{\mu(a_i) - \beta v(a_i)}{(1-\beta)\mu(a_i)}}{\beta} = 0$$

para lo cual se aplicó regla de L'Hopital al segundo factor de la parte derecha. Por otra parte, cuando $\beta \rightarrow 1$, el dominio de v para el cual $I(v | \beta, \mu) < \infty$ se restringe a una única medida de probabilidad $v = \mu$ porque no puede suceder que $\mu(a_i) > v(a_i)$ para toda i . Intuitivamente vemos que si β se incrementa, el grado de aleatoriedad de la muestra disminuye.

Recordemos del lema 2.1.1 que L_n^Y pertenece al conjunto $\{\mathcal{L}_n\}$ cuyo tamaño crece de manera polinomial en n . Las siguientes estimaciones de las probabilidades de grandes desviaciones para L_n^Y se obtienen a través de los métodos combinatorios que hemos estado empleando.

lema 2.5.1. *Para todo vector de probabilidad $v \in \mathcal{L}_n$*

(a) *Si $I(v | \frac{n}{m}, L_m^y) < \infty$, entonces*

$$\left| \frac{1}{n} \log \mathbb{P}(L_n^Y = v) + I(v | \beta, \mu) \right| \leq 2(|\Sigma| + 1) \left(\frac{\log(m+1)}{n} \right) \quad 2.5.2$$

(b) *Si $I(v | \beta, \mu) = \infty$, entonces $\mathbb{P}(L_n^Y = v) = 0$.*

Demostración.

En primer lugar demostraremos el inciso (b) que es inmediato.

Notemos que $I(v | \frac{n}{m}, L_m^y) = \infty$ si y sólo si se cumple que $nv(a_i) > mL_m^y(a_i)$ para algún $a_i \in \Sigma$. Esto no es posible en el caso de muestreo sin reemplazo, ya que para $v \in \mathcal{L}_n$, se tiene que $L_n^Y = v$ y $nL_n^Y(a_i) \leq mL_m^y(a_i)$ para toda $a_i \in \Sigma$.

Ahora demostraremos el inciso (a).

En el caso de muestreo sin reemplazo, la probabilidad del evento $\{L_n^Y = v\}$ para $v \in \mathcal{L}_n$ es exactamente el número de n -adas $i_1 \neq i_2 \neq \dots \neq i_n$ resultantes

en el tipo v , comparadas con el número total de n -adas, es decir

$$\begin{aligned}
 \mathbb{P}(L_n^Y = v) &= \mathbb{P}((L_n^Y(a_1), \dots, L_n^Y(a_{|\Sigma|})) = (v(a_1), \dots, v(a_{|\Sigma|}))) \\
 &= \mathbb{P}((L_n^Y(a_1) = v(a_1), \dots, L_n^Y(a_{|\Sigma|}) = v(a_{|\Sigma|}))) \\
 &= \prod_{i=1}^{|\Sigma|} \mathbb{P}(L_n^Y(a_i) = v(a_i)) \\
 &= \prod_{i=1}^{|\Sigma|} \mathbb{P}\left(\sum_{j=1}^n 1_{a_i}(Y_j) = nv(a_i)\right) \\
 &= \frac{\prod_{i=1}^{|\Sigma|} \binom{mL_m^Y(a_i)}{nv(a_i)}}{\binom{m}{n}}.
 \end{aligned}$$

Por otra parte, sustituyendo $|\Sigma| = 2$, $v(a_1) = k/n$, y $v(a_2) = 1 - k/n$, en la ecuación 2.1.3, se tiene que $|T_n(v)| = \binom{n}{k}$ y por el lema 2.1.3 se tiene,

$$\max_{0 \leq k \leq n} \left| \log \binom{n}{k} - nH\left(\frac{k}{n}\right) \right| \leq 2 \log(n+1) \quad 2.5$$

donde definimos $H(p) = -p \log p - (1-p) \log(1-p)$. Probaremos ahora la afirmación anterior. Sustituyendo $|T_n(v)| = \binom{n}{k}$ en el lema 2.1.3 tenemos,

$$\begin{aligned}
 (n+1)^{-2} e^{nH(v)} &\leq \log \binom{n}{k} && \leq e^{nH(v)} \\
 \iff -2 \log(n+1) &\leq \log \binom{n}{k} - nH(v) && \leq 0 \\
 \iff -2 \log(n+1) &\leq \log \binom{n}{k} - nH\left(\frac{k}{n}\right) && \leq 2 \log(n+1) \\
 \iff &|\log \binom{n}{k} - nH\left(\frac{k}{n}\right)| && \leq 2 \log(n+1)
 \end{aligned}$$

y como se cumple para toda $0 \leq k \leq n$, se tiene el resultado.

Las ecuaciones anteriores nos serán de utilidad para acotar la siguiente expresión.

$$\left| \frac{1}{n} \log \mathbb{P}(L_n^Y = v) - \sum_{i=1}^{|\Sigma|} \frac{mL_m^Y(a_i)}{n} H\left(\frac{nv(a_i)}{mL_m^Y(a_i)}\right) + \frac{m}{n} H\left(\frac{n}{m}\right) \right|$$

En 2.5.3 y 2.5.4 tenemos que la ecuación anterior es igual a

$$\begin{aligned}
 & \left| \frac{1}{n} \sum_{i=1}^{|\Sigma|} \log \left(\frac{mL_m^y(a_i)}{nv(a_i)} \right) - \sum_{i=1}^{|\Sigma|} \frac{mL_m^y(a_i)}{n} H \left(\frac{nv(a_i)}{mL_m^y(a_i)} \right) \right. \\
 & \quad \left. + \frac{m}{n} H \left(\frac{n}{m} \right) - \frac{1}{n} \log \left(\frac{m}{n} \right) \right| \\
 &= \frac{1}{n} \left| \sum_{i=1}^{|\Sigma|} \left[\log \left(\frac{mL_m^y(a_i)}{nv(a_i)} \right) - mL_m^y(a_i) H \left(\frac{nv(a_i)}{mL_m^y(a_i)} \right) \right] \right. \\
 & \quad \left. - \left[\log \left(\frac{m}{n} \right) - m H \left(\frac{n}{m} \right) \right] \right| \\
 &\leq \frac{1}{n} \sum_{i=1}^{|\Sigma|} \left| \log \left(\frac{mL_m^y(a_i)}{nv(a_i)} \right) - mL_m^y(a_i) H \left(\frac{nv(a_i)}{mL_m^y(a_i)} \right) \right| \\
 & \quad + \left| \log \left(\frac{m}{n} \right) - m H \left(\frac{n}{m} \right) \right| \\
 &\leq \frac{1}{n} |\Sigma| \max_{0 \leq nv(a_i) \leq mL_m^y a_i} \left| \log \left(\frac{mL_m^y(a_i)}{nv(a_i)} \right) - mL_m^y(a_i) H \left(\frac{nv(a_i)}{mL_m^y(a_i)} \right) \right| \\
 & \quad + \max_{0 \leq n \leq m} \left| \log \left(\frac{m}{n} \right) - m H \left(\frac{n}{m} \right) \right| \\
 &\leq \frac{2}{n} [|\Sigma| \log(mL_m^y(a_i) + 1) + \log(m + 1)] \\
 &\leq \frac{2}{n} [|\Sigma| \log(m + 1) + \log(m + 1)] \\
 &= \frac{2}{n} (|\Sigma| + 1) \log(m + 1).
 \end{aligned}$$

Por lo tanto, hemos demostrado que

$$\left| \frac{1}{n} \log \mathbb{P}(L_n^Y = v) - \sum_{i=1}^{|\Sigma|} \frac{mL_m^Y(a_i)}{n} H\left(\frac{nv(a_i)}{mL_m^Y(a_i)}\right) + \frac{m}{n} H\left(\frac{n}{m}\right) \right| \leq 2(N+1) \left(\frac{\log(m+1)}{n} \right) \quad 2.$$

Sólo falta mostrar que en el lado izquierdo de la desigualdad anterior es cierto que $I(v | \frac{n}{m}, L_m^Y) = -\sum_{i=1}^{|\Sigma|} \frac{mL_m^Y(a_i)}{n} H\left(\frac{nv(a_i)}{mL_m^Y(a_i)}\right) + \frac{m}{n} H\left(\frac{n}{m}\right)$. Para ver esto usamos que $H(p) = -p \log p - (1-p) \log(1-p)$ y desarrollando la parte derecha de la igualdad anterior tenemos:

$$\begin{aligned} & -\sum_{i=1}^{|\Sigma|} \frac{mL_m^Y(a_i)}{n} \left[\frac{-nv(a_i)}{mL_m^Y(a_i)} \log \frac{nv(a_i)}{mL_m^Y(a_i)} - \left(1 - \frac{nv(a_i)}{mL_m^Y(a_i)}\right) \log \left(1 - \frac{nv(a_i)}{mL_m^Y(a_i)}\right) \right. \\ & \quad \left. + \frac{m}{n} \left[\frac{n}{m} \log \frac{n}{m} - \left(1 - \frac{n}{m}\right) \log \frac{m-n}{m} \right] \right] \\ &= \sum_{i=1}^{|\Sigma|} v(a_i) \log \frac{nv(a_i)}{mL_m^Y(a_i)} + \sum_{i=1}^{|\Sigma|} \frac{mL_m^Y(a_i) - nv(a_i)}{n} \log \frac{mL_m^Y(a_i) - nv(a_i)}{mL_m^Y(a_i)} \\ & \quad - \log \frac{n}{m} - \frac{m-n}{n} \log \frac{m-n}{m} \\ &= \sum_{i=1}^{|\Sigma|} v(a_i) (\log nv(a_i) - \log mL_m^Y(a_i)) \\ & \quad + \sum_{i=1}^{|\Sigma|} \frac{mL_m^Y(a_i) - nv(a_i)}{n} (\log mL_m^Y(a_i) - nv(a_i) - \log mL_m^Y(a_i)) \\ & \quad - \log \frac{n}{m} - \frac{m-n}{n} \log \frac{m-n}{m} \\ &= \sum_{i=1}^{|\Sigma|} v(a_i) \log \frac{v(a_i)}{L_m^Y(a_i)} + \sum_{i=1}^{|\Sigma|} v(a_i) \log \frac{n}{m} + \sum_{i=1}^{|\Sigma|} \frac{mL_m^Y(a_i) - nv(a_i)}{n} [\log(mL_m^Y(a_i) \\ & \quad - nv(a_i)) - \log m - \log L_m^Y(a_i) - \log(m-n) + \log(m-n)] \\ & \quad - \log \frac{n}{m} - \frac{m-n}{n} \log \frac{m-n}{m} \end{aligned}$$

$$\begin{aligned}
&= H(v \mid L_m^y) + \sum_{i=1}^{|\Sigma|} \frac{mL_m^y(a_i) - nv(a_i)}{n} \log \frac{mL_m^y(a_i) - nv(a_i)}{(m-n)L_m^y(a_i)} \\
&\quad + \sum_{i=1}^{|\Sigma|} \frac{mL_m^y(a_i) - nv(a_i)}{n} \log \frac{m-n}{m} - \frac{m-n}{n} \log \frac{m-n}{m} \\
&= H(v \mid L_m^y) + \frac{m-n}{n} \sum_{i=1}^{|\Sigma|} \frac{mL_m^y(a_i) - nv(a_i)}{m-n} \log \frac{mL_m^y(a_i) - nv(a_i)}{(m-n)L_m^y(a_i)} \\
&\quad + \left(\frac{\sum_{i=1}^{|\Sigma|} mL_m^y(a_i) - nv(a_i)}{n} - \frac{m-n}{n} \right) \log \frac{m-n}{m} \\
&= H(v \mid L_m^y) + \frac{m-n}{n} H\left(\frac{\mu - \frac{n}{m}v}{1 - \frac{n}{m}} \mid L_m^y\right) = I(v \mid \frac{n}{m}, L_m^y).
\end{aligned}$$

esta manera, queda demostrado el lema 2.5.1. Como en la demostración del teorema de Sanov, las siguientes estimaciones son las análogas de 2.1.7 y 2.1.8.

lema 2.5.2. Con $m = m(n)$ y para todo conjunto de vectores de probabilidad $\Xi \in M_i(\Sigma)$.

$$\overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}(L_n^Y \in \Gamma) = - \underline{\lim}_{n \rightarrow \infty} \left\{ \inf_{v \in \Gamma \cap \mathcal{L}_n} I\left(v \mid \frac{n}{m}, L_m^y\right) \right\} \quad 2.5.6$$

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}(L_n^Y \in \Gamma) = - \overline{\lim}_{n \rightarrow \infty} \left\{ \inf_{v \in \Gamma \cap \mathcal{L}_n} I\left(v \mid \frac{n}{m}, L_m^y\right) \right\} \quad 2.5.7$$

Demostración.

Sea $v \in \mathcal{L}_n$, por el lema 2.3.1 tenemos que,

$$\begin{aligned}
\mathbb{P}(L_n^Y \in \Gamma) &= \sum_{v \in \Gamma \cap \mathcal{L}_n} \mathbb{P}(L_n^Y = v) \\
&\leq \sum_{v \in \Gamma \cap \mathcal{L}_n} \exp\left[2n(N+1) \frac{\log(m+1)}{n} - nI\left(v \mid \frac{n}{m}, L_m^y\right)\right] \\
&\leq |\Gamma \cap \mathcal{L}_n| \exp\left[n(2(|\Sigma|+1)) \frac{\log(m+1)}{n} - \inf_{v \in \Gamma \cap \mathcal{L}_n} I\left(v \mid \frac{n}{m}, L_m^y\right)\right]
\end{aligned}$$

tomando logaritmos de ambos lados y dividiendo entre n tenemos que

$$\log \mathbb{P}(L_n^Y \in \Gamma) \leq \frac{1}{n} \log(n+1)^{|\Sigma|} + 2(|\Sigma|+1) \frac{\log(m+1)}{n} - \inf_{v \in \Gamma \cap \mathcal{L}_n} I\left(v \mid \frac{n}{m}, L_m^y\right)$$

Por otra parte :

$$\begin{aligned} \mathbb{P}(L_n^Y \in \Gamma) &= \sum_{v \in \Gamma \cap \mathcal{L}_n} \mathbb{P}(L_n^Y = v) \\ &\geq \sum_{v \in \Gamma \cap \mathcal{L}_n} \exp[-n(2(|\Sigma| + 1) \frac{\log(m+1)}{n} - I(v \mid \frac{n}{m}, L_m^Y))] \\ &\geq \exp[-n(2(|\Sigma| + 1) \frac{\log(m+1)}{n} - \inf_{v \in \Gamma \cap \mathcal{L}_n} I(v \mid \frac{n}{m}, L_m^Y))] \end{aligned}$$

tomando logaritmos de ambos lados y dividiendo entre n tenemos que

$$\frac{1}{n} \log \mathbb{P}(L_n^Y \in \Gamma) \geq \frac{1}{n} \log(n+1)^{-|\Sigma|} - 2(|\Sigma| + 1) \log \frac{m+1}{n} - \inf_{v \in \Gamma \cap \mathcal{L}_n} I(v \mid \frac{n}{m}, L_m^Y)$$

y finalmente, tomamos limite superior en ambas desigualdades, y usando que $\overline{\lim}_{n \rightarrow \infty}(-A) = -\underline{\lim}_{n \rightarrow \infty}(A)$ para cualquier conjunto A , tenemos demostrado 2.5

Análogamente se prueba la igualdad en el caso del límite inferior.

El siguiente lema nos será de utilidad para la demostración del resultado más importante en ésta sección.

Lema 2.5.3. *Sea $\beta_n \in (0, 1)$, $\mu_n, v_n \in M_1(\Sigma)$ tales que $\beta_n \rightarrow \beta \in (0, 1)$, $\mu_n \rightarrow \mu$ conforme $n \rightarrow \infty$.*

- (a) *Si $v_n \rightarrow v$ e $I(v_n \mid \beta_n, \mu_n) < \infty$ para toda n suficientemente grande, entonces $\lim_{n \rightarrow \infty} I(v_n \mid \beta_n, \mu_n) = I(v \mid \beta, \mu)$.*
- (b) *Si $I(v \mid \beta, \mu) < \infty$, entonces existe una sucesión $v_n \in \mathcal{L}_n$ tal que $v_n \rightarrow v$ y $\lim_{n \rightarrow \infty} I(v_n \mid \beta_n, \mu_n) = I(v \mid \beta, \mu)$.*

Demostración.

- (a) Se puede verificar de la misma manera que se hizo en el lema anterior que

$$I(v_n \mid \beta_n, \mu_n) = \frac{1}{\beta_n} H(\mu_n) - H(v_n) - \frac{1 - \beta_n}{\beta_n} H\left(\frac{\mu_n - \beta_n v_n}{1 - \beta_n}\right).$$

Como la función $H(\cdot \mid \beta, \mu)$ es continua, tomando el límite cuando $n \rightarrow \infty$ y como $\beta \in (0, 1)$, se concluye la demostración.

) Considere primero $v \in M_1(\Sigma)$ para el cual

$$\min_{a_i \in \Sigma} \{ \mu(a_i) - \beta v(a_i) \} > 0. \tag{2.5.8}$$

Ahora, por el inciso (b) del lema 2.1.2. existe $v \in \mathcal{L}_n$ tal que $v_n \rightarrow v$. Entonces, la desigualdad estricta anterior implica que para toda n grande

$$\min_{a_i \in \Sigma} \{ \mu_n(a_i) - \beta_n v_n(a_i) \} \geq 0.$$

Por lo tanto, $I(v_n | \beta_n, \mu_n) \leq \infty$, para toda n suficientemente grande, y por el inciso anterior se obtiene que

$$\lim_{n \rightarrow \infty} I(v_n | \beta_n, \mu_n) = I(v | \beta, \mu) < \infty.$$

Supongamos ahora que $\Sigma_\mu = \Sigma$, pero posiblemente no se satisface 2.5.8. Como $\beta < 1$ e $I(v | \beta, \mu) \leq \infty$, existe algún $a_i \in \Sigma$ tal que $\mu(a_i) - \beta v(a_i) = 0$, entonces existe $v_k \rightarrow v$ tal que $\min_{a_i \in \Sigma} \{ \mu(a_i) - \beta v_k(a_i) \} > 0$ para toda k . Ahora bien, para cada k , usando el argumento anterior, existe una sucesión $\{v_{n,k}\}_{n \geq 1}$ tal que $v_{n,k} \in \mathcal{L}_n$, $v_{n,k} \rightarrow v_k$ y se cumple que

$$\lim_{n \rightarrow \infty} I(v_{n,k} | \beta_n, \mu_n) = I(v_k | \beta, \mu).$$

Por el argumento de la diagonalización de Cantor, existe una sucesión v_n tal que

$$\lim_{n \rightarrow \infty} v_n = \lim_{k \rightarrow \infty} v_k,$$

por lo tanto,

$$\lim_{n \rightarrow \infty} I(v_n | \beta, \mu) = \lim_{k \rightarrow \infty} I(v_k | \beta, \mu)$$

Finalmente, si $\Sigma_\mu \neq \Sigma$, con $\Sigma_v \subset \Sigma_\mu$. Como $I(v | \beta, \mu) < \infty$, se repite el procedimiento con Σ_μ en lugar de Σ , por lo tanto, existe $v_n \in \mathcal{L}_n$ tal que $\Sigma_{v_n} \subset \Sigma_\mu$, $v_n \rightarrow v$ e $I(v_n | \beta_n, \mu_n)$ para n suficientemente grande y aplicando (a) se tiene el resultado.

El siguiente teorema es el análogo al Teorema de Sanov.

Teorema 2.3. *Supóngase que L_m^y converge a μ y $\frac{n}{m} \rightarrow \beta \in (0, 1)$ conforme $n \rightarrow \infty$. Entonces las medidas empíricas aleatorias L_n^Y satisfacen el PGD, con función de tasa buena $I(v \mid \beta, \mu)$. Explícitamente, para todo conjunto Γ de vectores de probabilidad en $M_1(\Sigma) \subset \mathbb{R}^{|\Sigma|}$.*

$$\begin{aligned} -\inf_{v \in \Gamma^\circ} &\leq \overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}(L_n^Y \in \Gamma) \\ &\leq \overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}(L_n^Y \in \Gamma) \\ &\leq -\inf_{v \in \bar{\Gamma}} I(v \mid \beta, \mu) \end{aligned} \quad 2.5$$

hacemos notar que la cota superior es más débil que en el Teorema de Sanov, el sentido de que el ínfimo sobre la función de tasa es tomado sobre la cerradura de Γ .

Demostración.

Primero veamos que la función $I(\cdot \mid \beta, \mu)$ es una función de tasa buena. Por el inciso (a) del lema anterior tenemos que la función $I(\cdot \mid \beta, \mu)$ es continua conjuntamente en $\beta \in (0, 1)$, μ y v por lo que es semicontinua inferiormente. Además es una función no-negativa ya que $H(\cdot \mid \mu)$ lo es y como el conjunto de todos los vectores Σ -dimensionales con entradas reales no negativas que suman 1 es un conjunto compacto, entonces $I(\cdot \mid \beta, \mu)$ es una función de tasa buena.

Demostremos ahora la cota superior. Primero, se deduce de 2.5.6 que para alguna subsucesión infinita n_k , existe una sucesión $\{v_k\} \subset \Gamma$ tal que

$$\overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}(L_n^Y \in \Gamma) = -\lim_{k \rightarrow \infty} I(v_k \mid \frac{n_k}{m_k}, L_{m_k}^Y) := -I^* \quad 2.5$$

donde posiblemente $I^* = -\infty$. La sucesión $\{v_k\}$ tiene un punto límite v^* en el conjunto compacto $\bar{\Gamma}$. Pasando a la subsucesión convergente, la semicontinuidad inferior de I conjuntamente con β, μ y v implica que

$$I^* \geq I(v^* \mid \beta, \mu) \geq \inf_{v \in \bar{\Gamma}} I(v \mid \beta, \mu).$$

La cota superior se sigue por 2.5.10. Finalmente, para probar la cota inferior considere v arbitrario en Γ° tal que $I(v \mid \beta, \mu) < \infty$. Entonces, por la parte del lema 2.5.3 existe $v_n \in \mathcal{L}_n$ tal que $v_n \rightarrow v$ y

$$\lim_{n \rightarrow \infty} I(v_n \mid \frac{n}{m}, L_m^Y) = I(v \mid \beta, \mu)$$

Además, para n suficientemente grande, $v_n \in \Gamma \cap \mathcal{L}_n$ y se sigue que

$$-\overline{\lim}_{n \rightarrow \infty} \left\{ \inf_{v' \in \Gamma \cap \mathcal{L}_n} I(v' \mid \frac{n}{m}, L_m^y) \right\} \geq -I(v \mid \beta, \mu)$$

Combinando la desigualdad anterior con 2.5.7, concluimos que para cada v .

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}(L_n^Y \in \Gamma) \geq -I(v \mid \beta, \mu)$$

la cota se sigue por 1.4.5.

Capítulo 3

El Teorema de Cramér Real.

En la sección 2.3 como una aplicación del método de tipos, se presentó el teorema de Cramér para grandes desviaciones asociadas a la distribución empírica de v.a.i.i.d. que toman valores en un conjunto finito. En este capítulo, el teorema 2 se extenderá al caso de v.a.i.i.d que toman valores en \mathbb{R} .

3.1 Transformada de Cramér.

El teorema de Cramér afirma que la sucesión de medidas de probabilidad μ_n satisface el PGD con la función de tasa convexa $\Lambda^*(\cdot)$, la cuál recibe el nombre de Transformada de Cramér. (También es conocida como transformada de Fenchel-Legendre). Antes de enunciar el teorema, demostraremos propiedades importantes de la transformada de Cramér.

Considerese $(\Omega, \mathbb{F}, \mathbb{P})$ un espacio de probabilidad. Sea $X : \Omega \rightarrow \mathbb{R}$ una variable aleatoria, y μ la probabilidad sobre \mathbb{R} , inducida por X de la siguiente manera: $\mu(A) = \mathbb{P}(X^{-1}(A) \in \mathbb{F}) = \mathbb{P}(X \in A)$ con $A \in \mathbb{R}$.

Definición 3.1.1. La función log-Laplace de μ es la función definida por

$$\begin{aligned} \Lambda : \mathbb{R} &\rightarrow (-\infty, +\infty] \\ \lambda &\mapsto \Lambda(\lambda) = \log[\mathbb{E}(e^{\lambda X})]. \end{aligned}$$

Notemos que la función Λ nunca toma el valor $-\infty$, de ser así, tenemos que el valor esperado $\mathbb{E}(e^{\lambda X}) = 0$, lo cual contradice el hecho de que X toma valores reales.

Tenemos las siguientes proposiciones para la función log-Laplace.

Proposición 3.1.1. *Sea $\mathcal{D}(\Lambda) = \{\lambda : \Lambda(\lambda) < \infty\}$. Entonces tenemos:*

1. Λ es convexa, s.c.i. y $\Lambda(0) = 0$.
2. Si λ está en el interior de $\mathcal{D}(\Lambda)$, entonces Λ es derivable con respecto y además,

$$\Lambda'(\lambda) = \frac{\mathbb{E}[X e^{\lambda X}]}{\mathbb{E}[e^{\lambda X}]}.$$

3. Si $\mu(0, +\infty) > 0$ (resp. si $\mu(-\infty, 0) > 0$), entonces $\lim_{\lambda \rightarrow +\infty} \Lambda(\lambda) = -$ (resp. $\lim_{\lambda \rightarrow -\infty} \Lambda(\lambda) = +\infty$).
4. Si $\mu(-\infty, 0) = 0$ (resp. si $\mu(0, +\infty) = 0$), entonces Λ es creciente (resp. decreciente) y $\lim_{\lambda \rightarrow -\infty} \Lambda(\lambda) = \log \mu(\{0\})$ (resp. $\lim_{\lambda \rightarrow +\infty} \Lambda(\lambda) = \log \mu(\{0\})$).

Demostración.

1. Para mostrar la convexidad vamos a utilizar la desigualdad de Hölder $p = \frac{1}{t}$ y $q = \frac{1}{1-t}$. Si $\lambda_1, \lambda_2 \in \mathcal{D}(\lambda)$ y si $t \in [0, 1]$.

$$\begin{aligned} \Lambda(t\lambda_1 + (1-t)\lambda_2) &= \log[\mathbb{E}(e^{(t\lambda_1 + (1-t)\lambda_2)X})] \\ &= \log[\mathbb{E}(e^{(t\lambda_1)X} e^{((1-t)\lambda_2)X})] \\ &= \log[\mathbb{E}((e^{\lambda_1 X})^t \cdot (e^{\lambda_2 X})^{1-t})] \\ &= \log[\mathbb{E}((e^{\lambda_1 X})^{\frac{1}{1-t}} \cdot (e^{\lambda_2 X})^{\frac{1}{t}})] \\ &\leq \log([\mathbb{E}(e^{\lambda_1 X})]^t \cdot [\mathbb{E}(e^{\lambda_2 X})]^{1-t}) \quad (\text{por Hölder}) \\ &= \log([\mathbb{E}(e^{\lambda_1 X})]^t) + \log([\mathbb{E}(e^{\lambda_2 X})]^{1-t}) \\ &= t \log[\mathbb{E}(e^{\lambda_1 X})] + (1-t) \log[\mathbb{E}(e^{\lambda_2 X})]. \end{aligned}$$

por lo tanto, $\Lambda(t\lambda_1 + (1-t)\lambda_2) \leq t\Lambda(\lambda_1) + (1-t)\Lambda(\lambda_2)$.

Para mostrar que Λ es s.c.i., tomamos $\lambda_n \rightarrow \lambda$.

Por el lema de Fatou sabemos que si (f_n) es una sucesión en $\mu^+(x)$, conjunto de funciones medibles positivas, y λ una medida sobre \mathbb{R} enton

$$\underline{\lim}_{n \rightarrow \infty} \int f_n d\lambda \geq \int \underline{\lim}_{n \rightarrow \infty} f_n d\lambda,$$

y usando este lema tenemos que

$$\begin{aligned} \lim_{n \rightarrow \infty} \mathbb{E}[e^{\lambda_n X}] &= \lim_{n \rightarrow \infty} \int_{\mathbb{R}} e^{\lambda_n x} \mu(dx) \\ &\geq \int_{\mathbb{R}} \lim_{n \rightarrow \infty} e^{\lambda_n x} \mu(dx) \\ &= \int_{\mathbb{R}} e^{\lambda x} \mu(dx) \\ &= \mathbb{E}[e^{\lambda X}], \end{aligned}$$

después tomamos el logaritmo que es continuo y creciente, y entonces

$$\Lambda(\lambda) \leq \lim_{n \rightarrow \infty} \Lambda(\lambda_n),$$

por lo que Λ es semicontinua inferiormente.

2. Sea λ_0 en el interior de $\mathcal{D}(\Lambda)$. Vamos a aplicar el teorema de la derivación bajo la integral, para esto, primero verificaremos que $\int_{\mathbb{R}} e^{\lambda X} \mu(dx) < +\infty$, es decir, integrable. Con ω constante, la función

$$\lambda \mapsto e^{\lambda X(\omega)}$$

es derivable con respecto a λ de derivada $X(\omega)e^{\lambda X(\omega)}$. Como tomamos λ en el interior de $\mathcal{D}(\Lambda)$, existe un $\alpha > 0$ tal que $(\lambda_0 - 2\alpha, \lambda_0 + 2\alpha) \subset \mathcal{D}(\Lambda)$. Por otra parte, existe una constante C_α que sólo depende de α tal que,

$$\text{para todo } x \in \mathbb{R}, \quad |x| \leq C_\alpha e^{\alpha|x|}$$

para demostrar lo anterior, hacemos $f(x) = C_\alpha e^{\alpha x} - x$ y tenemos que ver que $f(x)$ es mayor o igual a cero. Más aún, queremos la desigualdad con valor absoluto, entonces vamos a partir el dominio de las x en $(-\infty, 0]$ y $[0, +\infty)$. Sea $x \in [0, +\infty)$, tomamos la derivada de $f(x)$, y vemos que $f'(x) = \alpha C_\alpha e^{\alpha x} - 1$, para que ésta también sea mayor que cero, se tiene que cumplir que

$$\alpha C_\alpha \geq 1$$

ya que $e^{\alpha x}$ siempre es mayor que 1, y las funciones son estrictamente crecientes, de aquí resulta que debemos escoger $C_\alpha \geq 1/\alpha$, lo cual siempre

puede hacerse. Con lo cual se prueba la desigualdad. Por lo que,

$$\begin{aligned} X e^{\lambda X} &\leq C_{\alpha} e^{\alpha|x|+\lambda X} \\ &\leq C_{\alpha} \{e^{(\lambda-\alpha)X} + e^{(\lambda+\alpha)X}\}, \end{aligned}$$

es entonces claro que si tomamos $\lambda \in (\lambda_0 - \alpha, \lambda_0 + \alpha)$, $\lambda + \alpha$ y $\lambda - \alpha$ estar en el interior del dominio de Λ y por esto, tenemos que el miembro derecho de 3.1.1(2) es integrable, lo que nos permite aplicar el teorema. Deducimos entonces la derivabilidad, y así obtenemos la ecuación requerida.

$$\begin{aligned} \Lambda(\lambda) &= \log[\mathbb{E}(e^{\lambda X})] = \log \left[\int_{\mathbb{R}} e^{\lambda X} \mu(dx) \right] \\ \text{y} \quad \Lambda'(\lambda) &= \frac{1}{\int_{\mathbb{R}} e^{\lambda X} \mu(dx)} \cdot \frac{\partial}{\partial \lambda} \left(\int_{\mathbb{R}} e^{\lambda X} \mu(dx) \right) \\ &= \frac{1}{\mathbb{E}(e^{\lambda X})} \int_{\mathbb{R}} \frac{\partial}{\partial \lambda} (e^{\lambda X}) \mu(dx) \\ &= \frac{1}{\mathbb{E}(e^{\lambda X})} \int_{\mathbb{R}} X e^{\lambda X} \mu(dx) \\ &= \frac{\mathbb{E}(X e^{\lambda X})}{\mathbb{E}(e^{\lambda X})}. \end{aligned}$$

3. Supongamos que $\mu(0, \infty) > 0$, entonces existe $a > 0$ tal que $\mathbb{P}(X \geq a) > 0$.
Entonces

$$\begin{aligned} \mathbb{E}(e^{\lambda X}) &\geq \mathbb{E}(e^{\lambda X} \cdot 1_{\{X \geq a\}}) \\ &\geq \mathbb{E}(e^{\lambda a} \cdot 1_{\{X \geq a\}}) \\ &= e^{\lambda a} \mathbb{E}(1_{\{X \geq a\}}) \\ &= e^{\lambda a} \cdot \mathbb{P}(X \geq a), \end{aligned}$$

así,

$$\begin{aligned} \mathbb{E}(e^{\lambda X}) &\geq e^{\lambda a} \mathbb{P}(X \geq a) \\ \log[\mathbb{E}(e^{\lambda X})] &\geq \lambda a + \log[\mathbb{P}(X \geq a)], \end{aligned}$$

por lo que

$$\lim_{\lambda \rightarrow \infty} \Lambda(\lambda) \geq \lim_{\lambda \rightarrow \infty} (\lambda a + \log[\mathbb{P}(X \geq a)]) = \infty$$

concluyendo que

$$\lim_{\lambda \rightarrow \infty} \Lambda(\lambda) = +\infty.$$

4. Supongamos que $\mu(-\infty, 0) = 0$, entonces

$$\Lambda(\lambda) = \log \left\{ \int_0^{+\infty} e^{\lambda x} \mu(dx) \right\}$$

como $e^{\lambda x}$ es creciente, y \log también, entonces $\Lambda(\lambda)$ es creciente. Por otra parte, si $\lambda < 0$, sobre \mathbb{R}^+ se tiene que $e^{\lambda x} \leq 1$, que es integrable. Cuando λ tiende hacia $-\infty$,

$$e^{\lambda x} \longrightarrow \begin{cases} 0 & \text{si } x > 0 \\ 1 & \text{si } x = 0 \end{cases}$$

Ahora, por el teorema de convergencia dominada,

$$\int_0^{+\infty} e^{\lambda x} \mu(dx) \longrightarrow \mu(\{0\})$$

lo que nos da el resultado.

A partir de la función log-Laplace definiremos la función de tasa, es decir, transformada de Cramér de la distribución de probabilidad μ .

Definición 3.1.2. Se llama **transformada de Cramér** de μ a la función Λ^* (función de x) definida sobre \mathbb{R} que toma valores en $[0, +\infty]$ por

$$\Lambda^*(x) = \sup\{\lambda x - \Lambda(\lambda) : \lambda \in \mathbb{R}\}. \quad 3.1.1$$

Hacemos notar que $\Lambda^*(x)$ es positiva en la medida en que, cuando $\lambda = 0$, la transformada de Cramér es 0.

En todo lo que sigue, X es semi-integrable, es decir, $\mathbb{E}(X^+)$ o $\mathbb{E}(X^-)$ es finito. La siguiente notación se da $\bar{x} = \mathbb{E}[X]$.

Recordemos que en la sección 2.3 usamos que $\Lambda(\cdot)$ es diferenciable, en las siguientes propiedades demostraremos esa afirmación.

Proposición 3.1.2. Recordando que $\mathcal{D}(\lambda) = \{\lambda : \Lambda(\lambda) < \infty\}$ se tiene que,

1. $\Lambda^*(x)$ es cóncava y s.c.i..

2. Si η está en el interior de $\mathcal{D}(\lambda)$ y si $y = \Lambda'(\eta)$, entonces $\Lambda^*(y) = \eta y - \Lambda(\eta)$.

3. Si $\mathcal{D}(\lambda) = \{0\}$ entonces $\Lambda^*(x) = 0$.
4. $\inf\{\Lambda^*(x) : x \in \mathbb{R}\} = 0$ y si $\bar{x} \in \mathbb{R}$, entonces $\Lambda^*(\bar{x}) = 0$.
5. Si existe $\lambda_0 > 0$ tal que $\Lambda(\lambda_0) < \infty$, entonces $\bar{x} < +\infty$ y

$$\text{para todo } x \geq \bar{x}, \quad \Lambda^*(x) = \sup\{\lambda x - \Lambda(\lambda) : \lambda \geq 0\}.$$

Además, $\Lambda^*(x)$ es creciente sobre $[\bar{x}, +\infty)$ (como caso particular tenemos que $\lim_{y \rightarrow +\infty} \Lambda^*(y) = +\infty$).

Demostración.

1. Λ^* se puede ver como $\sup\{ax + b\}$, ya que es una función que depende de x , por lo tanto es convexa, y es s.c.i. como supremo de funciones continuas.
2. Sea η en el interior del dominio de Λ , y sea $y = \Lambda'(\eta)$. Escribimos

$$\Lambda^*(y) = \sup\{\lambda y - \Lambda(\lambda) : \lambda \in \mathbb{R}\}$$

y sea

$$g(\lambda) = \lambda y - \Lambda(\lambda),$$

como $\Lambda(\lambda)$ es convexa, entonces $-\Lambda(\lambda)$ es cóncava y λy es afín, entonces $g(\lambda)$ es cóncava. Además, g es derivable y

$$g'(\lambda) = y - \Lambda'(\lambda),$$

por lo que,

$$g'(\eta) = y - \Lambda'(\eta) = \Lambda'(\eta) - \Lambda'(\eta) = 0$$

lo que produce que $g'(\eta) = 0$. Entonces g es una función cóncava cuya derivada se anula en η , por lo tanto el supremo se alcanza en este punto de donde concluimos que

$$\Lambda^*(y) = \eta y - \Lambda(\eta).$$

3. Si el dominio de Λ se reduce a 0, entonces $\Lambda(\lambda) \equiv +\infty$, lo que produce $\lambda x - \Lambda(\lambda)$ valga $-\infty$ salvo en 0, donde vale 0.

4. Si $\bar{x} \in \mathbb{R}$, se sabe que $\Lambda^*(\bar{x}) \geq 0$. Por lo que nos falta mostrar que $\Lambda^*(\bar{x}) \leq 0$. Para esto, emplearemos la desigualdad de Jensen en el caso de tener funciones cóncavas y es la siguiente: si X es una v.a., y $H : \mathbb{R} \rightarrow \mathbb{R}$ una función cóncava, entonces

$$\mathbb{E}(H(X)) = \mathbb{E}(-U(X)) \leq -U(\mathbb{E}(X)) = H(\mathbb{E}(X)).$$

Como el logaritmo es una función cóncava, entonces,

$$\lambda \bar{x} = \lambda \mathbb{E}(X) = \mathbb{E}(\lambda X) = \mathbb{E}(\log(e^{\lambda X})) \leq \log(\mathbb{E}(e^{\lambda X})) = \Lambda(\lambda)$$

de aquí que

$$\begin{aligned} \lambda \bar{x} &\leq \Lambda(\lambda) \\ \Leftrightarrow \lambda \bar{x} - \Lambda(\lambda) &\leq 0 \\ \Leftrightarrow \sup\{\lambda \bar{x} - \Lambda(\lambda)\} &\leq 0 \end{aligned}$$

por lo que

$$\Lambda^*(\bar{x}) = \sup\{\lambda \bar{x} - \Lambda(\lambda) : \lambda \in \mathbb{R}\} \leq 0.$$

Así, tenemos que $\Lambda^*(\bar{x}) = 0$.

5. Sea $\lambda_0 \geq 0$ tal que $\Lambda(\lambda_0) < \infty$. Como $e^{\lambda_0 X^+} \geq 1 + \lambda_0 X^+$, tenemos que

$$\begin{aligned} \lambda_0 X^+ &\leq e^{\lambda_0 X^+} - 1 \\ \Leftrightarrow \mathbb{E}(\lambda_0 X^+) &\leq \mathbb{E}(e^{\lambda_0 X^+} - 1) \\ \Leftrightarrow \mathbb{E}(X^+) &\leq \frac{\mathbb{E}(e^{\lambda_0 X^+} - 1)}{\lambda_0} \end{aligned}$$

lo que significa que $\bar{x} \leq +\infty$.

Supongamos ahora que $\bar{x} \in \mathbb{R}$. Sea $\lambda < 0$, para $x \geq \bar{x}$ tenemos que $\lambda x \leq \lambda \bar{x}$ debido a que $\lambda < 0$, entonces $\lambda x - \Lambda(\lambda) \leq \lambda \bar{x} - \Lambda(\lambda)$. Tomando supremos de ambos lados obtenemos

$$\sup\{\lambda x - \Lambda(\lambda) : \lambda < 0\} \leq \sup\{\lambda \bar{x} - \Lambda(\lambda) : \lambda < 0\} = \Lambda^*(\bar{x}) = 0$$

lo que prueba que la contribución de las $\lambda < 0$ no cuenta. Finalmente, verificar el crecimiento de $\Lambda^*(x)$ es fácil. Para $x > y > \bar{x}$ tenemos que $\lambda y - \Lambda(\lambda) < \lambda x - \Lambda(\lambda)$ $\lambda \geq 0$, entonces $\Lambda^*(y) \leq \Lambda^*(x)$.

Ahora, daremos el cálculo explícito de Λ y de Λ^* para $\mu = N(0, 1)$, más adelante se mostrarán otros ejemplos con otras distribuciones.

$$\begin{aligned}\mathbb{E}[e^{\lambda X}] &= \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} \exp\left(\lambda x - \frac{x^2}{2}\right) dx \\ &= \frac{1}{\sqrt{2\pi}} \left[\int_{\mathbb{R}} \exp\left(-\frac{1}{2}(x - \lambda)^2\right) dx \right] e^{\lambda^2/2} \\ &= e^{\lambda^2/2}.\end{aligned}$$

Entonces $\Lambda(\lambda) = \lambda^2/2$, ya que $\Lambda(\lambda) = \log(\mathbb{E}[e^{\lambda X}])$. Como la parte negativa no cuenta

$$\begin{aligned}\Lambda^*(x) &= \sup\{\lambda x - \lambda^2/2 : \lambda \in \mathbb{R}\} \\ &= \sup\{-\frac{1}{2}(\lambda - x)^2 + x^2/2 : \lambda \in \mathbb{R}\} \\ &= x^2/2\end{aligned}$$

Podemos ver que teníamos, en el ejemplo de las Colas de la distribución normal, un PGD con función de tasa $\Lambda^*(x)$.

3.2 El Teorema de Cramér.

Teorema 3.1. *Sea X_n una sucesión de v.a. reales independientes y con la misma distribución de probabilidad μ . Sea $\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$ y μ_n la distribución de probabilidad empírica de \bar{X}_n . Entonces la sucesión μ_n satisface un PGD con función de tasa, la función Λ^* , transformada de Cramér de μ , es decir,*

$$\text{para todo } O \text{ abierto } \varliminf_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(O) \geq -\inf\{\Lambda^*(x) : x \in O\}$$

$$\text{para todo } F \text{ cerrado } \varlimsup_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(F) \leq -\inf\{\Lambda^*(x) : x \in F\}$$

Por otra parte, se tiene la siguiente estimación que resulta ser más fina

$$\mu_n(F) \leq 2 \exp(-n \inf\{\Lambda^*(x) : x \in F\}). \quad 3.3$$

Demostración.

Para simplificar supongamos que μ cumple las hipótesis siguientes: μ es de soporte compacto y $\mu(-\infty, 0) > 0$, $\mu(0, +\infty) > 0$.

1. **Minoración.**

La minoración consiste en demostrar que para todo O abierto

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(O) \geq -\inf\{\Lambda^*(x) : x \in O\}.$$

La idea principal en la demostración será hacer un cambio de probabilidad. Sea entonces O un abierto no vacío. Para probar el resultado basta con demostrar que para toda $x \in O$

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(O) \geq -\Lambda^*(x), \quad 3.2.2$$

esto es,

$$\begin{aligned} \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(O) &\geq -\Lambda^*(x) \\ \iff \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(O) &\geq \sup\{-\Lambda^*(x) : x \in O\} \\ \iff \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(O) &\geq -\inf\{\Lambda^*(x) : x \in O\}. \end{aligned}$$

Demostrar 3.2.2 equivale a demostrar que para toda $x \in O$ y $\delta > 0$

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(x - \delta, x + \delta) \geq -\Lambda^*(x), \quad 3.2.3$$

pues entonces para toda $x \in O$ existe δ tal que

$$(x - \delta, x + \delta) \subset O,$$

por lo que,

$$\mu_n(x - \delta, x + \delta) \leq \mu_n(O)$$

y

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(O) \geq \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(x - \delta, x + \delta) \geq -\Lambda^*(x),$$

de donde se concluye 3.2.2.

Para demostrar 3.2.3, vamos a suponer que hemos demostrado que para toda $\delta > 0$

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(-\delta, \delta) \geq -\Lambda^*(0). \quad 3.2.4$$

Partiendo de esto, definimos una nueva v.a. Y_n que sigue una distribución de probabilidad μ_n de la siguiente manera

$$Y_n = (X_n - x).$$

Y por 3.2.4 tenemos para toda $\delta > 0$ que

$$\lim_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}(Y_n \in (-\delta, \delta)) \geq -\Lambda_Y^*(0).$$

Como

$$\begin{aligned} \Lambda_Y(\lambda) &= \log(\mathbb{E}[e^{\lambda Y}]) \\ &= \log(\mathbb{E}[e^{\lambda(X_n - x)}]) \\ &= \log(e^{-\lambda x} \cdot \mathbb{E}[e^{\lambda(X_n)}]) \\ &= -\lambda x + \Lambda(\lambda) \end{aligned}$$

y

$$\begin{aligned} \Lambda_Y^*(z) &= \sup\{\lambda z - \Lambda_Y(\lambda)\} \\ &= \sup\{\lambda z + \lambda x - \Lambda(\lambda)\} \\ &= \sup\{\lambda(z + x) - \Lambda(\lambda)\} \\ &= \Lambda^*(z + x) \end{aligned}$$

entonces para toda $\delta > 0$

$$\begin{aligned} &\lim_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}((X_n - x) \in (-\delta, \delta)) \geq -\Lambda_Y^*(0) = \Lambda^*(x) \\ \iff &\lim_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}(X_n \in (x - \delta, x + \delta)) \geq \Lambda^*(x) \\ \iff &\lim_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(x - \delta, x + \delta) \geq \Lambda^*(x) \end{aligned}$$

que es 3.2.3.

Demostraremos ahora 3.2.4. Por hipótesis μ es de soporte compacto, que implica que $\mathcal{D}(\Lambda) = \mathbb{R}$. Daremos una expresión explícita de $\Lambda^*(0)$, acuerdo con la proposición 3.1.1 (3), basta encontrar η tal que $\Lambda'(\eta) = 0$. Pero como μ toma valores en \mathbb{R}^+ y \mathbb{R}^- , se tiene, según la proposición 3.1.1 (3), que $\Lambda(\lambda)$ tiende hacia $+\infty$ cuando $|\lambda| \rightarrow +\infty$. Ahora, como Λ es convexa, se deduce la existencia de un mínimo, es decir, un punto η tal que $\Lambda'(\eta) = 0$, por lo que

$$\Lambda^*(0) = 0\eta - \Lambda(\eta) = -\Lambda(\eta).$$

Hacemos ahora el cambio de probabilidad, definimos ν como,

$$\frac{d\nu}{d\mu}(x) = \frac{\exp(\eta x)}{\int_{\mathbb{R}} \exp(\eta x) \mu dx} = \exp(\eta x - \Lambda(\eta)),$$

observamos que si $\varepsilon \in (0, \delta)$, entonces $\mu_n(-\delta, \delta) \geq \mu_n(-\varepsilon, \varepsilon)$ y empleando el Teorema de Cambio de Variable

$$\begin{aligned} \mu_n(-\varepsilon, \varepsilon) &= \int_{\Omega} \mathbf{1}_{\{-\varepsilon, \varepsilon\}}(X) \mu(dx) \\ &= \int_{\Omega} (\mathbf{1}_{\{-\varepsilon, \varepsilon\}} \circ \bar{X}_n)(\omega) d\mathbb{P}(\omega) \\ &= \int_{\Omega} \mathbf{1}_{\{\bar{X}_n \in (-\varepsilon, \varepsilon)\}}(\omega) d\mathbb{P}(\omega) \\ &= \int_{\Omega} \mathbf{1}_{\{\sum_{i=1}^n X_i \in (-n\varepsilon, n\varepsilon)\}}(\omega) d\mathbb{P}(\omega) \\ &= \int_{\mathbb{R}^n} \mathbf{1}_{\{\sum_{i=1}^n x_i \in (-n\varepsilon, n\varepsilon)\}}(x_1 \dots x_n) d(\mu_1 \dots \mu_n)(x_1 \dots x_n) \\ &= \int_{\mathbb{R}^n} \mathbf{1}_{\{\sum_{i=1}^n x_i \in (-n\varepsilon, n\varepsilon)\}}(x_1 \dots x_n) \mu(dx_1) \dots \mu(dx_n) \\ &= \int_{\{|\frac{1}{n} \sum_{k=1}^n x_k| < \varepsilon\}} \mu(dx_1) \mu(dx_2) \dots \mu(dx_n), \end{aligned}$$

donde la penúltima desigualdad se sigue por independencia. Sobre el conjunto $\{|\frac{1}{n} \sum_{k=1}^n x_k| < \varepsilon\}$, se tiene que

$$\begin{aligned} &\frac{1}{n} \sum_{k=1}^n x_k \leq \left| \frac{1}{n} \sum_{k=1}^n x_k \right| < \varepsilon \\ \iff &\eta \sum_{k=1}^n x_k \leq n\varepsilon|\eta| \\ \iff &\eta \sum_{k=1}^n x_k - n\varepsilon|\eta| \leq 0 \\ \iff &\exp(\eta \sum_{k=1}^n x_k - n\varepsilon|\eta|) \leq 1, \end{aligned}$$

por lo tanto,

$$\mu_n(-\varepsilon, \varepsilon) \geq \int_{\{|\frac{1}{n} \sum_{k=1}^n x_k| < \varepsilon\}} \exp\left(\eta \sum_{k=1}^n x_k - n\varepsilon|\eta|\right) \mu(dx_1) \mu(dx_2) \dots \mu(dx_n)$$

y desarrollando el integrando de la desigualdad anterior se tiene

$$\exp\left(\eta \sum_{k=1}^n x_k - n\varepsilon|\eta|\right) = \exp\left(\sum_{k=1}^n (\eta x_k - \varepsilon|\eta|)\right) = \prod_{k=1}^n (\exp(\eta x_k - \varepsilon|\eta|))$$

por lo que

$$\begin{aligned} \mu_n(-\varepsilon, \varepsilon) &\geq \int_{A_1 \times \dots \times A_n} \prod_{k=1}^n (\exp(\eta x_k - \varepsilon|\eta|)) \mu(dx_1) \mu(dx_2) \dots \mu(dx_n) \\ &= \int_{A_1} \exp(\eta x_1 - \varepsilon|\eta|) \mu(dx_1) \dots \int_{A_n} \exp(\eta x_n - \varepsilon|\eta|) \mu(dx_n) \\ &= \int_{A_1} \exp(\eta x_1 - \Lambda(\eta) + \Lambda(\eta) - \varepsilon|\eta|) \mu(dx_1) \dots \\ &\quad \int_{A_n} \exp(\eta x_n - \Lambda(\eta) + \Lambda(\eta) - \varepsilon|\eta|) \mu(dx_n) \\ &= \exp(\Lambda(\eta) - \varepsilon|\eta|) \int_{A_1} \exp(\eta x_1 - \Lambda(\eta)) \mu(dx_1) \dots \\ &\quad \exp(\Lambda(\eta) - \varepsilon|\eta|) \int_{A_n} \exp(\eta x_n - \Lambda(\eta)) \mu(dx_n) \\ &= \exp(n\Lambda(\eta) - n\varepsilon|\eta|) \\ &\quad \left(\int_{A_1 \times \dots \times A_n} \prod_{k=1}^n \exp(\eta x_k - \Lambda(\eta)) \mu(dx_1) \mu(dx_2) \dots \mu(dx_n) \right) \\ &= \exp(n\Lambda(\eta) - n\varepsilon|\eta|) \left(\int_{A_1 \times \dots \times A_n} v(dx_1) \dots v(dx_n) \right) \quad 3.2. \end{aligned}$$

Así, obtenemos la desigualdad 3.2.5. Por la proposición 3.1.1(2), sabemos que existe η tal que

$$0 = \Lambda'(\eta) = \frac{\mathbb{E}[X e^{\eta X}]}{\mathbb{E}[e^{\eta X}]},$$

esto nos lleva inmediatamente a decir que $\mathbb{E}[X e^{\eta X}] = 0$ de donde tenemos

que

$$\begin{aligned}\mathbb{E}[Xe^{\eta X}] &= \int_{\mathbb{R}} xe^{\eta x} \mu(dx) \\ &= \int_{\mathbb{R}} xe^{\eta x} \frac{v(dx)}{\exp(\eta x - \Lambda(\eta))} \\ &= \int_{\mathbb{R}} \frac{xe^{\eta x} v(dx)}{e^{\eta x} \cdot \exp(-\Lambda(\eta))} \\ &= \exp(\Lambda(\eta)) \int_{\mathbb{R}} xv(dx) = 0\end{aligned}$$

por lo tanto

$$\int_{\mathbb{R}} xv(dx) = 0. \quad 3.2.6$$

Observamos ahora lo que se obtiene asintóticamente

$$\begin{aligned}\mu_n(-\delta, \delta) &\geq \mu_n(-\varepsilon, \varepsilon) \\ \iff \log \mu_n(-\delta, \delta) &\geq \log \mu_n(-\varepsilon, \varepsilon) \\ \iff \frac{1}{n} \log \mu_n(-\delta, \delta) &\geq \frac{1}{n} \log \mu_n(-\varepsilon, \varepsilon) \\ \iff \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(-\delta, \delta) &\geq \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(-\varepsilon, \varepsilon)\end{aligned}$$

$$\begin{aligned}&\geq \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \left[\left(\int_{\{\frac{1}{n} \sum_{k=1}^n x_k < \varepsilon\}} v(dx_1) v(dx_2) \dots v(dx_n) \right) \exp(n\Lambda(\eta) - n\varepsilon|\eta|) \right] \\ &= \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log [v_n(-\varepsilon, \varepsilon) \cdot \exp(n\Lambda(\eta) - n\varepsilon|\eta|)] \\ &= \underline{\lim}_{n \rightarrow \infty} \left[\frac{1}{n} \log v_n(\varepsilon, \varepsilon) + \Lambda(\eta) - \varepsilon|\eta| \right]\end{aligned}$$

Por otra parte, la ley de los grandes números nos dice que: *Dadas X_1, X_2, \dots v.a. independientes (no necesariamente con la misma distribución) con media y varianza finita. Supongamos que las varianzas están acotadas uniformemente por $M < \infty$. Sea $S_n = (X_1 + \dots + X_n)/n$, entonces $[S_n - \mathbb{E}(S_n)]/n$ converge en probabilidad a 0, esto es,*

$$\mathbb{P} \left[\left| \frac{S_n - \mathbb{E}(S_n)}{n} \right| \geq \varepsilon \right] \xrightarrow{n \rightarrow \infty} 0$$

o, lo que es lo mismo

$$\mathbb{P} \left[\left| \frac{S_n - \mathbb{E}(S_n)}{n} \right| < \varepsilon \right] \xrightarrow{n \rightarrow \infty} 1$$

Ahora, por la ecuación 3.2.6 tenemos que $\mathbb{E}_v[X] = 0$, y por la ley débil de los grandes números,

$$\mathbb{P} \left[\left| \frac{\overline{X}_n - 0}{n} \right| < \varepsilon \right] \xrightarrow{n \rightarrow \infty} 1 \iff \mathbb{P} \left[\left| \frac{\overline{X}_n}{n} \right| < \varepsilon \right] \xrightarrow{n \rightarrow \infty} 1$$

lo que es igual a

$$v_n(-\varepsilon, \varepsilon) \xrightarrow{n \rightarrow \infty} 1$$

por lo que

$$\varliminf_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(-\delta, \delta) \geq \Lambda(\eta) - \varepsilon|\eta|,$$

si $\varepsilon \xrightarrow{n \rightarrow \infty} 0$ y viendo que el factor $1/n$ no tiene ninguna utilidad, obtenemos

$$\varliminf_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(-\delta, \delta) \geq \Lambda(\eta) = -\Lambda^*(0)$$

como se quería demostrar.

2. Mayoración.

La prueba que se dará no podrá generalizarse en \mathbb{R}^d ya que utilizaremos la propiedad de \mathbb{R} de poseer orden.

Sea F un cerrado en \mathbb{R} . La mayoración es trivial si tenemos que

$$\inf\{\Lambda^*(x) : x \in F\} = 0,$$

pues entonces equivale a demostrar que $\mu_n(F) \leq 1$, lo que es claro. Primeramente notemos que

$$\inf\{\Lambda^*(x) : x \in F\} = 0 \iff 0 = -\inf\{\Lambda^*(x) : x \in F\}$$

entonces

$$\begin{aligned} & \mu_n(F) \leq 1 \\ \iff & \log \mu_n(F) \leq \log 1 = 0 \\ \iff & \frac{1}{n} \log \mu_n(F) \leq 0 \\ \iff & \varliminf_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(F) \leq 0 = -\inf\{\Lambda^*(x) : x \in F\} \\ \iff & \varliminf_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(F) \leq -\inf\{\Lambda^*(x) : x \in F\} \end{aligned}$$

Supongamos entonces que $\inf\{\Lambda^*(x) : x \in F\} > 0$. En la proposición 3.1.2 (3) vimos que si $\mathcal{D}(\Lambda) = 0$, entonces $\Lambda^*(x) = 0$, por lo que $\inf\{\Lambda^*\} = 0$, ahora, como estamos negando esta afirmación, tenemos que $\mathcal{D}(\Lambda) \neq \{0\}$.

Supongamos primero que 0 está en el interior de $\mathcal{D}(\Lambda)$. Esto significa que X_1 tiene momentos exponenciales a derecha y a izquierda de 0, ya que podemos dar una vecindad alrededor del 0 completamente contenida en $\mathcal{D}(\Lambda)$ en la que existan $(\lambda_i)_{i \in \mathbb{R}}$ tales que $\Lambda(\lambda_i) < \infty$, por lo que podemos aplicar la proposición 3.1.2 (5) para deducir que $\bar{x} \in \mathbb{R}$ (recordamos que $\bar{x} = \mathbb{E}(X_1)$) y por la afirmación 3.1.2 (4) también que $\Lambda^*(\bar{x}) = 0$. Utilizaremos ahora la desigualdad de Chebychev que nos dice : Si $\alpha > 0$, $t \in \mathbb{R}$, Y v. a. r. y f una función continua entonces

$$\mathbb{P}(f(Y) \geq t) \leq \frac{1}{t^\alpha} \mathbb{E}(f(Y)^\alpha)$$

y si f es la función identidad,

$$\begin{aligned} \mathbb{P}(Y \geq t) &= \mathbb{P}(e^Y \geq e^t) \\ &= \mathbb{P}(e^Y \cdot e^{-t} \geq 1) \\ &\leq \mathbb{E}[e^{\alpha(Y-t)}]. \end{aligned} \tag{3.2.7}$$

Sea entonces $\lambda > 0$ tal que $\Lambda(\lambda) < \infty$, tenemos, según la desigualdad 3.2.7 con $\alpha = n\lambda > 0$ y $Y = \bar{X}$ que

$$\begin{aligned} \mu_n(t, +\infty) &= \mathbb{P}(\bar{X}_n \geq t) \\ &\leq \mathbb{E}[e^{n\lambda(\bar{X}_n - t)}] \\ &= \mathbb{E}\left[e^{n\lambda\left(\frac{\sum X_i}{n}\right)} e^{(-n\lambda t)}\right] \\ &= e^{-n\lambda t} \mathbb{E}[e^{\lambda \sum X_i}] \\ &= e^{-n\lambda t} (\mathbb{E}[e^{\lambda X_1}])^n \\ &\stackrel{\text{indep}}{=} e^{-n\lambda t} (\exp(n \log \mathbb{E}[e^{\lambda X_1}])) \\ &= e^{-n\lambda t} \cdot \exp[n \Lambda(\lambda)] \\ &= \exp[n(\Lambda(\lambda) - \lambda t)] \end{aligned}$$

por lo tanto

$$\mu_n(t, +\infty) \leq \exp[-n(\lambda t - \Lambda(\lambda))] \tag{3.2.8}$$

lo cual también se cumple para $\lambda = 0$.

Según la proposición 3.1.2 (5), si tomamos $t \geq \bar{x}$, entonces

$$\Lambda^*(t) = \sup\{\lambda t - \Lambda(\lambda) : \lambda \geq 0\},$$

de donde, tomando el supremo en la desigualdad 3.2.8, encontramos:

$$\begin{aligned} \mu_n(t, +\infty) &= \sup\{\mu_n(t, +\infty)\} \\ &\leq \sup\{\exp[-n(\lambda t - \Lambda(\lambda))]\} \\ &= \exp[-n \sup\{\lambda t - \Lambda(\lambda)\}] \end{aligned}$$

por lo que

$$\mu_n[t, +\infty] \leq \exp[-n\Lambda^*(t)] \quad t \geq \bar{x}. \quad 3.2.9$$

de manera análoga mostraremos que

$$\mu_n[-\infty, t] \leq \exp[-n\Lambda^*(t)] \quad t \leq \bar{x} \quad 3.2.10$$

para esto, aplicaremos la desigualdad de Chebychev con $\alpha > 0$, $t \in \mathbb{R}$ y Y una v.a. $\mathbb{P}(Y \leq t)$, equivalente a que:

$$\mathbb{P}(e^Y \leq e^t) = \mathbb{P}(e^{(t-Y)} \geq 1) \leq \mathbb{E}(e^{\alpha(Y-t)}).$$

Por la desigualdad anterior con $\alpha = n\lambda$ y $Y = \bar{X}$ y haciendo unos cálculos similares para obtener 3.2.8 se tiene que

$$\mu_n(-\infty, t) \leq \exp[-n(\lambda t - \Lambda(\lambda))],$$

donde, tomando el supremo en la desigualdad anterior se tiene el resultado 3.2.9.

Utilicemos ahora que $\Lambda^*(\bar{x}) = 0$. Como hicimos el supuesto de que el ínfimo de las $\Lambda^*(x)$ es estrictamente positivo, deducimos necesariamente que $\bar{x} \notin F$, por lo que \bar{x} está en el complemento de F , el cual es un abierto en \mathbb{R} , entonces la componente conexa de F^c que contiene a \bar{x} es un intervalo (a, b) . De donde,

$$\begin{aligned} F &\subset (-\infty, a] \cup [b, +\infty) & a < \bar{x} < b \\ \mu_n(F) &\leq \mu_n(-\infty, a] + \mu_n[b, +\infty) & a < \bar{x} < b \end{aligned}$$

de ahí que, utilizando 3.2.9 y 3.2.10 se tenga

$$\mu_n(F) \leq \exp[-n\Lambda^*(a)] + \exp[-n\Lambda^*(b)].$$

Si, por ejemplo $\Lambda^*(a) \geq \inf\{\Lambda^*(x) : x \in F\}$, como $a < b$ entonces:

$$\begin{aligned} \lambda a &< \lambda b \\ \lambda a - \Lambda(\lambda) &< \lambda b - \Lambda(\lambda) \\ \sup\{\lambda a - \Lambda(\lambda)\} &< \sup\{\lambda b - \Lambda(\lambda)\} \\ \Lambda^*(a) &< \Lambda^*(b) \end{aligned}$$

por lo que se deduce que $\Lambda^*(b) \geq \inf\{\Lambda^*(x) : x \in F\}$, de lo que obtenemos

$$\begin{aligned} \mu_n(F) &\leq \exp[-n\Lambda^*(a)] + \exp[-n\Lambda^*(b)] \\ &\leq \exp[-n \inf\{\Lambda^*(x) : x \in F\}] + \exp[-n \inf\{\Lambda^*(x) : x \in F\}] \\ &= 2 \exp[-n \inf\{\Lambda^*(x) : x \in F\}] \end{aligned}$$

que es exactamente 3.2.1.

Supongamos ahora que 0 no está en el interior de $\mathcal{D}(\Lambda)$, por ejemplo, tenemos para toda $\lambda < 0$, $\Lambda(\lambda) = +\infty$. Entonces el $\lim_{x \rightarrow \infty} \Lambda^*(x) = +\infty$, Λ^* creciente sobre $[\bar{x}, +\infty)$. Por la proposición 3.1.2 (5) sabemos que $\bar{x} \in \mathbb{R}^+$, y que $\Lambda^*(\bar{x}) = 0$, si usamos la desigualdad de Chebychev exponencial aplicada a $t > 0$, y la proposición 3.1.2 (5), obtenemos nuevamente que

$$\mu_n(t, \infty) \leq \exp[-n\Lambda^*(t)] \quad t \geq \bar{x},$$

como por hipótesis, el ínfimo de las $\Lambda^*(x)$ es estrictamente positivo, también en este caso $\bar{x} \notin F$, por lo que \bar{x} está contenido en el abierto $(0, b)$, entonces,

$$F \subset [b, \infty) \quad 0 < \bar{x} \leq b$$

de donde

$$\mu_n(F) \leq \exp[-n \inf\{\Lambda^*(x) : x \in F\}]$$

dando el resultado más fino que 3.2.1.

El problema que podemos plantearnos es saber cuando hay convergencia y no simplemente las mayoraciones y minoraciones. El corolario siguiente responde parcialmente al problema.

Corolario 3.2.1. *Bajo las hipótesis del teorema 3.1, tenemos*

$$\lim_{n \rightarrow \infty} \frac{1}{n} \log \mu_n[t, +\infty) = - \inf\{\Lambda^*(x) : x \geq t\}$$

Demostración.

Refinaremos la demostración de la minoración. Utilizando que, para toda $x \geq t$ y toda $\delta > 0$

$$\begin{aligned} & [x, x + \delta) \subset [t, +\infty) \\ \implies & \mu_n[x, x + \delta) \leq \mu_n[t, +\infty) \\ \implies & \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n[t, +\infty) \geq \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(x, x + \delta) \end{aligned}$$

análogo a la prueba de la minoración, sólo hay que demostrar

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(x, x + \delta) \geq -\Lambda^*(x) \quad 3.2.11$$

esto implica que

$$\lim_{n \rightarrow \infty} \frac{1}{n} \log \mu_n([t, +\infty)) \leq -\inf\{\Lambda^*(x) : x \geq t\}$$

para demostrar 3.2.11 se rehace el cambio de variable $Y = X_n - x$ hecho en la prueba de la minoración, y con la suposición que

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n[0, \delta) \geq -\Lambda^*(0)$$

se tiene el resultado. Para mostrar la desigualdad anterior se utiliza el cambio de probabilidad que se hizo en la minoración, entonces, para un η tal que $\Lambda^*(0) = -\Lambda(\eta)$ y para $\varepsilon < \delta$

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n[0, \delta) \geq \underline{\lim}_{n \rightarrow \infty} \left[\Lambda(\eta) - \varepsilon|\eta| + \frac{1}{n} \log v_n[0, \varepsilon) \right]$$

y

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n[0, \delta) \geq \left[\Lambda(\eta) - \varepsilon|\eta| + \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log v_n[0, \varepsilon) \right].$$

En este caso, para hallar la convergencia de $v_n[0, \varepsilon)$, no se puede utilizar ley débil de los grandes números, pues el intervalo a estimar no es simétrico. Utilizamos entonces el teorema del límite central, para decir que $v_n[0, \varepsilon)$ tiende hacia un límite finito estrictamente positivo, lo que permite controlar este último término.

3.3 Cálculo de $\Lambda(\lambda)$ y $\Lambda^*(\lambda)$ para algunas variables aleatorias

Daremos ahora el cálculo explícito de la función log-Laplace y la transformada de Cramér para distintas distribuciones de probabilidad. También obtendremos la gráfica de la función de tasa correspondiente.

Ejemplo 3.3.1. Considerar X v.a. bernoulli con parámetro (p) .

Como sabemos, la función generadora de momentos de esta variable aleatoria

$$M(\lambda) = 1 + p(e^\lambda - 1)$$

por lo que

$$\log M(\lambda) = \log(1 + p(e^\lambda - 1)).$$

Vamos ahora a calcular el punto λ^* donde se maximiza la función

$$g(\lambda) = \lambda x - \log(1 + p(e^\lambda - 1)).$$

Entonces, se obtiene su derivada y se iguala a cero, así tenemos que

$$g'(\lambda) = x - \frac{pe^\lambda}{1 + p(e^\lambda - 1)} = 0$$

de donde

$$\begin{aligned} x + pxe^\lambda - px &= pe^\lambda \\ \Rightarrow x(1-p) &= pe^\lambda(1-x) \\ \Rightarrow \frac{x(1-p)}{p(1-x)} &= e^\lambda \end{aligned}$$

se tiene que $\lambda^* = \log\left(\frac{x(1-p)}{p(1-x)}\right)$ y si calculamos $g(\lambda^*)$ obtenemos

$$\begin{aligned} \lambda^* x - \log M(\lambda^*) &= x \log\left(\frac{x(1-p)}{p(1-x)}\right) - \log\left(1 + p\left(\frac{x(1-p)}{p(1-x)} - 1\right)\right) \\ &= x \log\left(\frac{x(1-p)}{p(1-x)}\right) - \log\left(\frac{1-p}{1-x}\right) \\ &= x \log\left(\frac{x}{p}\right) + x \log\left(\frac{1-p}{1-x}\right) - \log\left(\frac{1-p}{1-x}\right) \\ &= x \log\left(\frac{x}{p}\right) + (1-x) \log\left(\frac{1-x}{1-p}\right) \end{aligned}$$

por lo que $\Lambda^*(x) = x \log \left(\frac{x}{p} \right) + (1-x) \log \left(\frac{1-x}{1-p} \right)$ para $x \in [0, 1]$ y notemos que $\mathcal{D}_\Lambda = \mathbb{R}$, pero $\Lambda^*(x)$ es discontinua.

Consideremos el caso particular de $p = \frac{1}{2}$, entonces tenemos que

$$\Lambda^*(x) = x \log x + (1-x) \log(1-x) + \log 2 \quad \text{para } x \in [0, 1]$$

y la gráfica de la función de tasa es

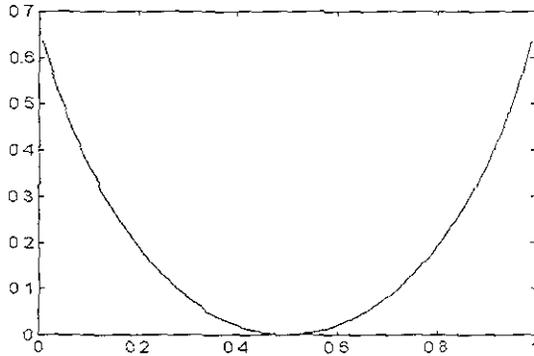


Figura 10. Función de tasa para una v.a. Bernoulli con parámetro $p = 1/2$.

Observación: La función de tasa que aquí obtuvimos corresponde al ejemplo de las colas de la distribución binomial que se presentó al inicio.

Ejemplo 3.3.2. Si X es una v.a. Exponencial con parámetro (θ) .

Como sabemos, la función generadora de momentos para una v.a. con esta distribución es $M(\lambda) = \frac{\theta}{\theta - \lambda}$, por lo que $\log M(\lambda) = \log \left(\frac{\theta}{\theta - \lambda} \right)$ y por lo tanto

$$g(\lambda) = \lambda x - \log \left(\frac{\theta}{\theta - \lambda} \right) = \lambda x - \log \theta + \log(\theta - \lambda).$$

Se obtiene su derivada y se iguala a cero

$$g'(\lambda) = x - \frac{1}{\theta - \lambda} = 0$$

de donde

$$\begin{aligned} x &= \frac{1}{\theta - \lambda} \\ \Rightarrow \theta - \lambda &= \frac{1}{x} \\ \Rightarrow \theta - \frac{1}{x} &= \lambda^* \end{aligned}$$

con lo que $\lambda^* = \frac{\theta x - 1}{x}$ y si calculamos $g(\lambda^*)$ obtenemos

$$\begin{aligned} \lambda^* x - \log \theta + \log(\theta - \lambda^*) &= x \left(\frac{\theta x - 1}{x} \right) - \log \theta + \log \left(\theta - \left(\frac{\theta x - 1}{x} \right) \right) \\ &= \theta x - 1 - \log \theta + \log \left(\frac{1}{x} \right) \\ &= \theta x - 1 - \log \theta - \log x \end{aligned}$$

por lo que

$$\Lambda^*(x) = \theta x - 1 - \log(\theta x) \quad \text{para } x > 0.$$

En el caso de que el parámetro $\theta = 1$ tenemos que la función de tasa es

$$\Lambda^*(x) = x - 1 - \log x \quad \text{para } x > 0.$$

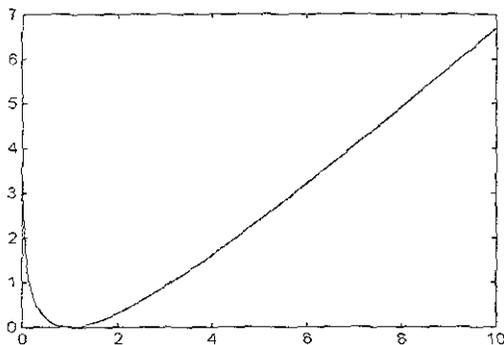


Figura 11. Función de tasa para una v.a. Exponencial con parámetro $\theta = 1$.

jemplo 3.3.3. Para X v.a. Poisson con parámetro (θ) .

Como sabemos, la función generadora de momentos en este caso es

$$M(\lambda) = e^{\theta(e^\lambda - 1)}$$

por lo que

$$\log M(\lambda) = \theta(e^\lambda - 1),$$

de esta forma,

$$g(\lambda) = \lambda x - \theta(e^\lambda - 1).$$

Se obtiene su derivada y se iguala a cero

$$g'(\lambda) = x - \theta e^\lambda = 0$$

de donde

$$\begin{aligned} x &= \theta e^\lambda \\ \Rightarrow \frac{x}{\theta} &= e^\lambda \\ \Rightarrow \lambda^* &= \log\left(\frac{x}{\theta}\right) \end{aligned}$$

así, tenemos que $\lambda^* = \log(x/\theta)$ y se calcula $g(\lambda^*)$ con lo que se obtiene

$$\begin{aligned} \lambda^* x - \theta(e^{\lambda^*} - 1) &= x \log\left(\frac{x}{\theta}\right) - \theta\left(\frac{x}{\theta} - 1\right) \\ &= x \log\left(\frac{x}{\theta}\right) - x + \theta \end{aligned}$$

por lo que $\Lambda^*(x) = \theta - x + x \log\left(\frac{x}{\theta}\right)$ para $x \geq 0$.

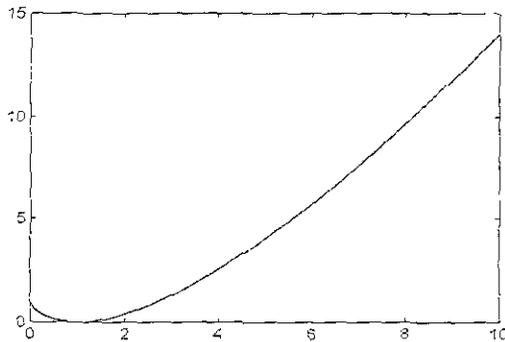


Figura 12. Función de tasa para una v.a. Poisson.

Ejemplo 3.3.4. Si X es una v.a. Binomial con parámetros (n, p) .

En este caso, con la convención $q = (1 - p)$, la función generadora de momentos es

$$M(\lambda) = (e^\lambda p + q)^n$$

por lo que $\log M(\lambda) = n \log(e^\lambda p + q)$, así, tenemos que

$$g(\lambda) = \lambda x - n \log(e^\lambda p + q).$$

se obtiene su derivada y se iguala a cero, así tenemos que

$$g'(\lambda) = x - \frac{npe^\lambda}{pe^\lambda + q}$$

de donde

$$\begin{aligned} xe^\lambda p + x - px &= npe^\lambda \\ \Rightarrow x(1-p) &= pe^\lambda(n-x) \\ \Rightarrow \frac{x(1-p)}{p(n-x)} &= e^\lambda \end{aligned}$$

de lo que $\lambda^* = \log\left(\frac{x(1-p)}{p(n-x)}\right)$ y se calcula $g(\lambda^*)$:

$$\begin{aligned} g(\lambda^*) &= x \log\left(\frac{x(1-p)}{p(n-x)}\right) - n \log\left(\frac{x(1-p)}{p(n-x)}p + (1-p)\right) \\ &= x \log\left(\frac{x}{p}\right) + x \log\left(\frac{1-p}{n-x}\right) - n \log\left(\frac{x(1-p)}{n-x} + (1-p)\right) \\ &= x \log\left(\frac{x}{p}\right) + x \log\left(\frac{1-p}{n-x}\right) - n \log n - n \log\left(\frac{1-p}{n-x}\right) \\ &= x \log\left(\frac{x}{p}\right) + (x-n) \log\left(\frac{1-p}{n-x}\right) - n \log n \\ &= x \log\left(\frac{x}{p}\right) + (n-x) \log\left(\frac{n-x}{1-p}\right) - n \log n \end{aligned}$$

$$\text{lo que } \Lambda^*(x) = x \log\left(\frac{x}{p}\right) + (n-x) \log\left(\frac{n-x}{1-p}\right) - n \log n \quad x = 0, \dots, n.$$

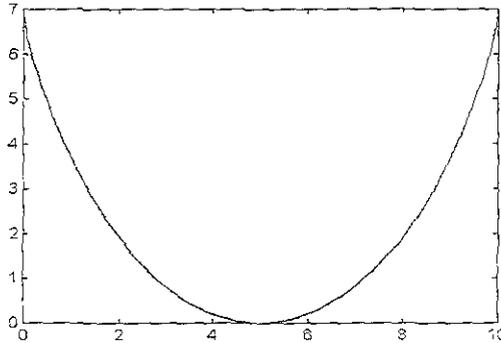


Figura 13. Función de tasa para una v.a. Binomial

Ejemplo 3.3.5. Ahora, si X es una v.a. Geométrica con parámetro (p).

La función generadora de momentos es

$$M(\lambda) = \frac{p}{1 - qe^\lambda}$$

por lo que $\log M(\lambda) = \log p - \log(1 - qe^\lambda)$ y por lo tanto

$$g(\lambda) = \lambda x - \log p + \log(1 - qe^\lambda).$$

Obteniendo su derivada e igualándola a cero tenemos que

$$g'(\lambda) = x - \frac{qe^\lambda}{1 - qe^\lambda} = 0$$

de donde

$$\begin{aligned} x - qxe^\lambda &= qe^\lambda \\ \Leftrightarrow x &= qe^\lambda(1 + x) \\ \Leftrightarrow \frac{x}{q(1 + x)} &= e^\lambda \end{aligned}$$

así, se tiene que $\lambda^* = \log\left(\frac{x}{q(1+x)}\right)$ y si calculamos $g(\lambda^*)$ tenemos que

$$\begin{aligned} g(\lambda^*) &= x \log\left(\frac{x}{q(1+x)}\right) + \log\left(1 - q\left(\frac{x}{q(1+x)}\right)\right) - \log p \\ &= x \log\left(\frac{x}{q(1+x)}\right) + \log\left(1 - \frac{x}{1+x}\right) - \log p \\ &= x \log\left(\frac{x}{q}\right) + x \log\left(\frac{1}{1+x}\right) + \log\left(\frac{1}{1+x}\right) - \log p \\ &= x \log\left(\frac{x}{q}\right) - x \log(1+x) - \log(1+x) - \log p \\ &= x \log\left(\frac{x}{q}\right) - (1+x) \log(1+x) - \log p \end{aligned}$$

por lo que $\Lambda^*(x) = x \log\left(\frac{x}{q}\right) - (1+x) \log(1+x) - \log p \quad x = 1, 2, \dots$

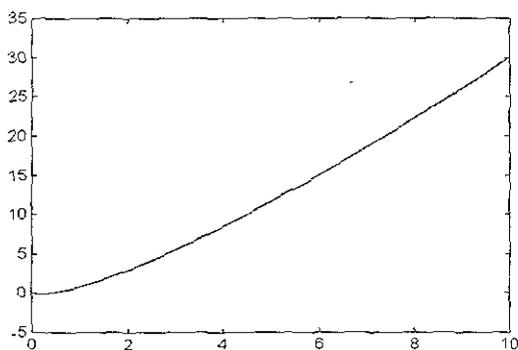


Figura 14. Función de tasa para una v.a. Geométrica

Capítulo 4

El Teorema de Cramér \mathbb{R}^d Dimensional.

4.1 Tensión exponencial.

Comenzamos por un lema que será fundamental en todo el capítulo.

Lema 4.1.1. *Sea $N \in \mathbb{N}^+$ y $(a_i^\varepsilon)_{1 \leq i \leq N}$ una familia de reales estrictamente positivos. Tenemos:*

$$\overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log \left(\sum_{i=1}^N a_i^\varepsilon \right) = \sup_{1 \leq i \leq N} \left\{ \overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log a_i^\varepsilon \right\}$$

Demostración.

La minoración es evidente, pues una suma de números positivos es siempre más grande que cada término de la suma, por lo que queda solamente demostrar la mayoración. Empezamos por escribir que

$$\log \left(\sum_{i=1}^N a_i^\varepsilon \right) \leq \log \left(N \sup_i a_i^\varepsilon \right) = \log N + \log \left(\sup_i a_i^\varepsilon \right)$$

que nos da

$$\overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log \left(\sum_{i=1}^N a_i^\varepsilon \right) \leq \overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log \left(\sup_i a_i^\varepsilon \right),$$

esta con probar que,

$$\overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log \left(\sup_i a_i^\varepsilon \right) = \sup_i \left\{ \overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log a_i^\varepsilon \right\} \quad 4.1.1$$

Probaremos la desigualdad anterior para $N=2$.

Sean entonces a_1^ε y a_2^ε estrictamente positivos. La minoración es inmediata debido a que

$$\begin{aligned} \sup_{1 \leq i \leq 2} \{a_i^\varepsilon\} &\geq a_i^\varepsilon && \text{para toda } i = 1, 2 \\ \overline{\lim}_{\varepsilon \rightarrow \infty} \varepsilon \log \sup_{1 \leq i \leq 2} \{a_i^\varepsilon\} &\geq \overline{\lim}_{n \rightarrow \infty} \varepsilon \log a_i^\varepsilon && \text{para toda } i = 1, 2 \\ \overline{\lim}_{\varepsilon \rightarrow \infty} \varepsilon \log \sup_{1 \leq i \leq 2} \{a_i^\varepsilon\} &\geq \sup_{1 \leq i \leq 2} \{\overline{\lim}_{n \rightarrow \infty} \varepsilon \log a_i^\varepsilon\} \end{aligned}$$

Para la mayoración suponemos, por ejemplo, que

$$\overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log (a_1^\varepsilon) \leq \overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log (a_2^\varepsilon) = S$$

y por la definición de límite superior, para a_1 y a_2 tenemos que para toda $\delta > 0$ existe $\varepsilon_0 > 0$ tal que

$$0 < \varepsilon < \varepsilon_0 \implies \varepsilon \log a^\varepsilon \leq S + \delta,$$

así mismo, para toda $\delta > 0$ existe $\varepsilon_1 > 0$ tal que

$$0 < \varepsilon < \varepsilon_1 \implies \varepsilon \log b^\varepsilon \leq S + \delta$$

y como el máximo es uno de estos dos, tenemos claramente el resultado final

Vamos ahora a dar una definición que será fundamental en lo que resta.

Definición 4.1.1. Sea F un σ -álgebra sobre (X, Γ) , espacio topológico, que contiene al σ -álgebra de los borelianos de X . A la familia $\{\mu_\varepsilon\}, \varepsilon > 0$ de probabilidades sobre (X, F) se le llama **exponencialmente tensa** si para todo $M > 0$ existe un compacto K_M tal que

$$\overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(K_M^c) \leq -M.$$

Recordemos, por la definición 1.4.2, que una función $I : X \rightarrow [0, +\infty]$ s.c.i. una función de tasa buena, si para todo $a > 0$ el conjunto de nivel $\{x : I(x) \leq a\}$ es compacto.

Definiremos ahora la noción de PGD débil.

Definición 4.1.2. Sea F un σ -álgebra sobre X que contiene al σ -álgebra de los abiertos de X . La familia $\{\mu_\varepsilon\}, \varepsilon > 0$ de probabilidades sobre (X, F) satisface PGD débil con función de tasa I si I es una función de X en $[0, +\infty]$ s.c.i. cumple:

$$\text{Para todo } O \text{ abierto} \quad \varliminf_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(O) \geq -\inf\{I(x) : x \in O\}.$$

$$\text{Para todo } K \text{ compacto} \quad \varlimsup_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(K) \leq -\inf\{I(x) : x \in K\}.$$

Es importante hacer notar que la familia de probabilidades puede satisfacer PGD débil sin satisfacer un PGD fuerte. Basta considerar $\mu_\varepsilon = \delta_{1/\varepsilon}$, que satisface un PGD débil con $I \equiv +\infty$, y no satisface un PGD fuerte, pues $\mu_\varepsilon(\mathbb{R}) = 1$. Disponemos de la proposición siguiente.

Proposición 4.1.1. Sea F un σ -álgebra de X que contenga al σ -álgebra de los abiertos de X , y $\{\mu_\varepsilon\}, \varepsilon > 0$ una familia exponencialmente tensa de probabilidades sobre (X, F) , entonces:

1. Si tenemos que para todo K compacto $\varlimsup_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(K) \geq -\inf\{I(x) : x \in K\}$. Entonces esta mayoración sigue siendo cierta sobre los cerrados.
2. Si tenemos que para todo O abierto $\varliminf_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(O) \geq -\inf\{J(x) : x \in O\}$. Entonces J es una función de tasa buena.

Demostración.

Sea F cerrado. El primer caso evidente es cuando $\inf\{I(x) : x \in F\} = 0$. Si no estamos en este caso, pongamos $M = \inf\{I(x) : x \in F\}$. Como la familia de medidas es exponencialmente tensa, existe entonces un compacto K_M tal que

$$\varlimsup_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(K_M^c) \leq -M.$$

Hacemos entonces la separación siguiente

$$\begin{aligned} \mu_\varepsilon(F) &= \mu_\varepsilon(F \cap \Omega) \\ &= \mu_\varepsilon(F \cap (K_M \cup K_M^c)) \\ &= \mu_\varepsilon(F \cap K_M) + \mu_\varepsilon(F \cap K_M^c) \\ &\leq \mu_\varepsilon(F \cap K_M) + \mu_\varepsilon(K_M^c) \end{aligned}$$

De acuerdo con la ecuación 4.3.1 tenemos que

$$\begin{aligned} \overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(F) &\leq \overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log(\mu_\varepsilon(F \cap K_M) + \mu_\varepsilon(K_M^c)) \\ &= \sup \left\{ \overline{\lim}_{\varepsilon \rightarrow 0} (\varepsilon \log \mu_\varepsilon(F \cap K_M) + \varepsilon \log \mu_\varepsilon(K_M^c)) \right\} \end{aligned}$$

por lo que

$$\overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(F) \leq \sup \left\{ \overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(F \cap K_M) + \overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(K_M^c) \right\}$$

y como $F \cap K_M$ es compacto, podemos aplicarle la mayoración, quedando

$$\overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(F) \leq \sup \{ -\inf \{ I(x) : x \in F \cap K_M \}; -M \}.$$

Como $-\inf \{ I(x) : x \in F \cap K_M \} \leq -\inf \{ I(x) : x \in F \} = -M$ tenemos el resultado.

2. Aquí sólo tenemos que verificar que $I(x)$ es una función de tasa buena. Sea $a > 0$, queremos demostrar que el conjunto de nivel $\{x : I(x) \leq -a\}$ es compacto. Comencemos por decir que, ya que la familia de medidas es exponencialmente tensa, existe un compacto K_a tal que

$$\overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(K_a^c) \leq -a.$$

Como, por otra parte, K_a^c es un abierto, le aplicamos la minoración

$$-a \geq \overline{\lim}_{\varepsilon \rightarrow 0} \varepsilon \log \mu_\varepsilon(K_a^c) \geq -\inf \{ I(x) : x \in K_a^c \},$$

reuniendo los dos resultados obtenemos

$$\inf \{ I(x) : x \in K_a^c \} > a.$$

Lo que produce que $\{x : I(x) \leq a\} \subset K_a$, entonces, tenemos un conjunto cerrado contenido en un compacto, lo que nos dice que es un compacto que termina la prueba.

4.2 Transformada de Cramér en \mathbb{R}^d .

Definición 4.2.1. Sea X una v.a. con valores en \mathbb{R}^d de ley μ . La función log-Laplace de μ es la función de \mathbb{R}^d en $(-\infty, \infty]$, definida como

$$\Lambda(\lambda) = \log \mathbb{E}[e^{\langle \lambda, X \rangle}]$$

y $\mathcal{D}(\lambda) = \{\lambda \in \mathbb{R}^d : \Lambda(\lambda) < \infty\}$.

En lo que resta del capítulo, supondremos que 0 está en el interior de $\mathcal{D}(\lambda)$, que, al pasar por las marginales implica en particular que $\mathbb{E}(X)$ está definida como un vector de \mathbb{R}^d . Tenemos la siguiente proposición, análoga a la proposición 3.1.1.

Proposición 4.2.1. *Λ es convexa, diferenciable en el interior de $\mathcal{D}(\lambda)$ y tenemos que*

$$\text{grad}_K \Lambda(\lambda) = \frac{\mathbb{E}[X^K \cdot e^{\langle \lambda, X \rangle}]}{\mathbb{E}[e^{\langle \lambda, X \rangle}]}$$

particular, $\text{grad}_K \Lambda(0) = \mathbb{E}(X)$.

Demostración.

$$\begin{aligned} \Lambda(t\lambda_1 + (1-t)\lambda_2) &= \log[\mathbb{E}(e^{\langle (t\lambda_1 + (1-t)\lambda_2), X \rangle})] \\ &= \log[\mathbb{E}(e^{t\langle \lambda_1, X \rangle} e^{(1-t)\langle \lambda_2, X \rangle})] \\ &= \log[\mathbb{E}((e^{\langle \lambda_1, X \rangle})^t \cdot (e^{\langle \lambda_2, X \rangle})^{1-t})] \\ &= \log[\mathbb{E}((e^{\langle \lambda_1, X \rangle})^{\frac{1}{1-t}} \cdot (e^{\langle \lambda_2, X \rangle})^{\frac{1}{t}})] \\ &\leq \log([\mathbb{E}(e^{\langle \lambda_1, X \rangle})]^t \cdot [\mathbb{E}(e^{\langle \lambda_2, X \rangle})]^{1-t}) \quad (\text{por Hölder}) \\ &= \log([\mathbb{E}(e^{\langle \lambda_1, X \rangle})]^t) + \log([\mathbb{E}(e^{\langle \lambda_2, X \rangle})]^{1-t}) \\ &= t \log[\mathbb{E}(e^{\langle \lambda_1, X \rangle})] + (1-t) \log[\mathbb{E}(e^{\langle \lambda_2, X \rangle})]. \end{aligned}$$

Definición 4.2.2. La transformada de Cramér de la ley μ es la función

$$\Lambda^*(x) = \sup\{\langle \lambda, x \rangle - \Lambda(\lambda) : \lambda \in \mathbb{R}^d\}.$$

Tenemos las siguientes propiedades, análogas a las de la proposición 3.1.2.

Proposición 4.2.2. *Propiedades de la transformada de Cramér en \mathbb{R}^d :*

1. $\Lambda^*(x)$ es convexa, positiva, s.c.i. y aún más, es una función de tasa buena.

2. Si $y = \text{grad} \Lambda(\eta)$, entonces,

$$\Lambda^*(y) = \langle \eta, y \rangle - \Lambda(\eta).$$

Demostración.

1. Para verificar la convexidad y la s.c.i. se usa el mismo argumento para el caso univariado. Sea un conjunto de nivel $\{x : \Lambda^*(x) \leq a\}$. Como sabemos que se trata de un cerrado, basta mostrar que está acotado y afirmamos que $\Lambda^*(x)$ es una función de tasa buena. Hemos supuesto que está en el interior de $\mathcal{D}(\Lambda)$, entonces $\mathcal{D}(\Lambda)$ contiene en particular una esfera $S(0, r)$ para un $r > 0$ contenida totalmente en su interior. Sea entonces $x \in \mathbb{R}^d$ perteneciente al conjunto de nivel $\{\Lambda^* \leq a\}$, entonces, como Λ^* es un supremo, es mayor o igual que $\lambda x - \Lambda(\lambda)$, en particular si hacemos $\lambda = rx/\|x\|$ tenemos

$$\begin{aligned} a \geq \Lambda^*(x) &\geq \langle r \frac{x}{\|x\|}, x \rangle - \Lambda\left(r \frac{x}{\|x\|}\right) \\ &= \frac{r}{\|x\|} \langle x, x \rangle - \Lambda\left(r \frac{x}{\|x\|}\right) \\ &= \frac{r}{\|x\|} \|x\|^2 - \Lambda\left(r \frac{x}{\|x\|}\right) \\ &= r\|x\| - \Lambda\left(r \frac{x}{\|x\|}\right) \\ &\geq r\|x\| - \sup\{\Lambda(\lambda) : \lambda \in S(0; r)\} \end{aligned}$$

(pues $\Lambda^*(x)$ es un supremo y $r \frac{x}{\|x\|} \in (0; r)$). De donde

$$\|x\| \leq \frac{1}{r}(a + \sup\{\Lambda(\lambda) : \lambda \in S(0; r)\}).$$

Ahora, como Λ es diferenciable en el interior de su dominio, en particular es continuo sobre $S(0, r)$, entonces el supremo del miembro de la derecha es finito, lo que da el resultado.

2. Sea $y = \text{grad}(\eta)$ y sea $\lambda \in \mathbb{R}^d$. El principio va a ser demostrar que tener

$$\langle \lambda, y \rangle - \Lambda(\lambda) \geq \langle \eta, y \rangle - \Lambda(\eta)$$

para esto, definimos una función g de $[0, 1]$ en \mathbb{R} de la manera siguiente $\alpha \in \mathbb{R}^d$,

$$g(\alpha) = \langle \eta, y \rangle + \alpha \langle \lambda - \eta, y \rangle - \Lambda(\eta + \alpha(\lambda - \eta)),$$

g es la suma de una función afín y de una función cóncava, por lo que es cóncava. Por otra parte $g(0) = \langle \eta, y \rangle - \Lambda(\eta)$ y $g(1) = \langle \lambda, y \rangle - \Lambda(\lambda)$. El

es entonces demostrar que $g(1) \leq g(0)$. Como g es cóncava, tenemos:

$$g(1) - g(0) \leq g'(0) \cdot (1 - 0)$$

y

$$g'(0) = \langle \lambda - \eta, y \rangle - \langle \lambda - \eta, \text{grad} \Lambda(\eta) \rangle = 0$$

por lo tanto $(\langle \lambda, y \rangle - \Lambda(\lambda)) - (\langle \eta, y \rangle - \Lambda(\eta)) \leq 0$ lo que nos dá el resultado.

3 El Teorema de Cramér Multidimensional.

Teorema 4.1. *Sea $(X_n)_n$ una sucesión de v.a. con valores en \mathbb{R}^d independientes y equidistribuidos de la ley μ tal que 0 esté en el interior de $\mathcal{D}(\Lambda)$. Entonces la sucesión μ_n , la distribución de probabilidad de las medias empíricas $\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$ sigue un PGD con función de tasa buena, la función Λ^* , transformada de Cramér en \mathbb{R}^d .*

Demostración.

La prueba se hará en tres etapas: tensión exponencial, mayoración sobre los compactos y minoración sobre los abiertos.

1. Tensión Exponencial.

Como primer paso, demostraremos que la familia $\{\mu_n\}$ de probabilidades que corresponden a la distribución de la media empírica \bar{X}_n , es una familia exponencialmente tensa y luego la idea será utilizar el teorema de Cramér en \mathbb{R} . Sea $M > 0$, vamos a mostrar que

$$\lim_{n \rightarrow +\infty} \left[\overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n \left([-M, M]^d \right)^c \right] = -\infty. \quad 4.3.1$$

Pongamos $K^M = [-M, M]^d$. Razonemos sobre las leyes marginales

$$\mu_n(K_M^c) \leq \sum_{i=1}^d \{ \mu_n^i[M, +\infty) + \mu_n^i(-\infty, -M] \}.$$

Donde μ_n^j es la j -ésima marginal de μ_n , es decir, la ley de $\bar{X}_n^i = \frac{1}{n} \sum_{k=1}^n X_k^i$. Según el teorema 3.1, μ_n^i satisface un PGD de función de tasa Λ_i^* , la transformada de Cramér de X_k^i . Como 0 está en el interior del dominio de μ , es

claro que 0 está a su vez en el interior del dominio de Λ_i para todo i . ahí que, por una parte

$$\lim_{|y| \rightarrow +\infty} \Lambda^*(y) = +\infty$$

y, por otra parte, según 3.2.1

$$\mu_n^i[M, +\infty) \leq 2 \exp[-n \inf\{\Lambda^*(x) : x \geq M\}]$$

y una desigualdad análoga del otro lado, lo que dá finalmente el resultado cuando hacemos tender M hacia el infinito.

2. Mayoración sobre los compactos.

Comenzaremos haciendo mayoraciones sobre las bolas. Sea $\delta > 0$, pongamos

$$I^\delta(x) = \inf \left\{ \Lambda^*(x) - \delta, \frac{1}{\delta} \right\}$$

Notemos que si $\Lambda^*(X) < \infty$, entonces, para δ suficientemente pequeño $I^\delta(x) = \Lambda^*(x) - \delta$. Si, por el contrario, $\Lambda^*(x)$ es infinito, el ínfimo es 1. Además, en ambos casos, $I^\delta(x)$ crece hacia $\Lambda^*(x)$ cuando δ decrece hacia 0. Sea entonces K un compacto de \mathbb{R}^d y $X \in K$. Tenemos $I^\delta(x) < \Lambda^*(x)$ entonces, como éste último es un supremo, tenemos que existe un vector $\lambda_x \in \mathbb{R}^d$ tal que

$$\langle \lambda_x, x \rangle - \Lambda(\lambda_x) \geq I^\delta(x). \quad 4.$$

Por otra parte, existe $\rho_x > 0$ tal que $\rho_x \cdot \|\lambda_x\| \leq \delta$. Hacemos $B_x = B(x, \rho_x)$. Entonces, si $\overline{X_n} \in B_x$

$$\langle \lambda_x, \overline{X_n} \rangle \leq \inf\{\langle \lambda_x, y \rangle : y \in B_x\}$$

y, por la desigualdad de Schwartz

$$|\langle \lambda_x, y - x \rangle| \leq \|\lambda_x\| \cdot \|y - x\| \leq \|\lambda_x\| \cdot \rho_x$$

cambiando y por $\overline{X_n}$ tenemos

$$\langle \lambda_x, \overline{X_n} \rangle \geq \langle \lambda_x, x \rangle - \rho_x \cdot \|\lambda_x\| \geq \langle \lambda_x, x \rangle - \delta$$

según 3.2.7

$$\begin{aligned} \mu_n(B_x) &\leq \mathbb{E}[\exp\{n(\langle \lambda_x, \overline{X_n} \rangle - \langle \lambda_x, x \rangle + \delta)\}] \\ &= \exp(-n\langle \lambda_x, x \rangle + n\delta) \cdot (\mathbb{E}[e^{\langle \lambda_x, X_1 \rangle}])^n \\ &= \exp[n(\Lambda(\lambda_x) - \langle \lambda_x, x \rangle + \delta)]. \end{aligned}$$

De ahí, por 4.3.2

$$\frac{1}{n} \log \mu_n(B_x) \leq \Lambda(\lambda_x) - \langle \lambda_x, x \rangle + \delta \leq \delta - I^\delta(x).$$

Ahora, como K es compacto, existen puntos x_k , en un número finito N tales que $K \subset \bigcup_{k=1}^N B_{x_k}$ lo que nos dá

$$\frac{1}{n} \log \mu_n(K) \leq \frac{1}{n} \log \left(\sum_{k=1}^N \mu_n(B_{x_k}) \right).$$

Según el lema 4.1.1

$$\begin{aligned} \overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(K) &\leq \sup_{1 \leq k \leq N} \left\{ \overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(B_{x_k}) \right\} \\ &\leq \sup_{1 \leq k \leq N} \{-I^\delta(x_k) + \delta\} \\ &= - \inf_{1 \leq k \leq N} \{-I^\delta(x_k) + \delta\} \\ &\leq - \inf_{x \in K} \{I^\delta(x) + \delta\}. \end{aligned}$$

Para concluir basta con hacer tender δ hacia 0.

3. Minoración sobre los abiertos.

Supongamos que $\mathcal{D}(\Lambda) = \mathbb{R}^d$. Análogo a \mathbb{R} , mostraremos el siguiente resultado. Para todo $x \in \mathbb{R}^d$ y para todo $\delta > 0$

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(B(x, \delta)) \geq -\Lambda^*(x). \tag{4.3.3}$$

Tenemos dos casos: existe η tal que $x = \text{grad} \Lambda(\eta)$. En este caso la demostración de 4.3.3 es similar a la del caso real. Si no estamos en el caso anterior, el método será perturbar las X_k con Gaussianas $N(0, \epsilon^2 \cdot Id)$.

Supongamos entonces que para todo η , X no es igual a $\text{grad}\Lambda(\eta)$, y hagamos $Y_n = X_n + \varepsilon Z_n$ donde las Z_n son v.a.i.i.d. con distribución $N(0, Id)$ si entonces la log-Laplace de las Y_n ,

$$\begin{aligned}\Lambda_Y(\lambda) &= \log \mathbb{E}[\exp(\langle \lambda, X_1 + \varepsilon Z_1 \rangle)] \\ &= \log \mathbb{E}[\exp(\langle \lambda, X_1 \rangle) \exp(\langle \varepsilon \lambda, Z_1 \rangle)] \\ &= \Lambda(\lambda) + \Lambda_{Z_1}(\varepsilon \lambda).\end{aligned}$$

Además Z_1 es un vector Normal centrado de componentes independientes por lo que su log-Laplace es obtenida como una suma de log-Laplaces de sus componentes, y la log-Laplace de una $N(0, 1)$ fué calculada anteriormente. Entonces

$$\Lambda_{Z_1}(\varepsilon \lambda) = \sum_{j=1}^d \Lambda_{Z_1}^j(\varepsilon \lambda_j) = \sum_{j=1}^d \frac{\varepsilon^2}{2} \lambda_j^2$$

de ahí que

$$\Lambda_Y(\lambda) = \Lambda(\lambda) + \frac{\varepsilon}{2} \|\lambda\|^2 \geq \Lambda(\lambda),$$

entonces

$$\Lambda_Y^*(x) = \sup\{\langle \lambda, x \rangle - \Lambda_Y(\lambda); \lambda \in \mathbb{R}^d\} \leq \Lambda^*(x).$$

Mostraremos que para Y_n existe η tal que $X = \text{grad}\Lambda(\eta)$. Sea $g(\lambda) = \langle \lambda, x \rangle - \Lambda_Y(\lambda)$, ésta función es cóncava (ya que $\Lambda_Y(\lambda)$ es convexa) mostramos que $g(\lambda) \rightarrow -\infty$ cuando $\|\lambda\| \rightarrow \infty$, esto prueba que g pasa por un máximo, lo que garantiza la existencia de un η tal que $\text{grad} g(\eta) = x$. Sea $x = \text{grad}\Lambda_Y(\eta)$, de aquí que

$$g(\lambda) = \langle \lambda, x \rangle - \Lambda(\lambda) - \frac{\varepsilon}{2} \|\lambda\|^2 \leq \Lambda^*(x) - \frac{\varepsilon}{2} \|\lambda\|^2$$

entonces

$$\lim_{\|\lambda\| \rightarrow \infty} g(\lambda) = C - \frac{\varepsilon}{2} \lim_{\|\lambda\| \rightarrow \infty} \|\lambda\|^2$$

que tiende a $-\infty$.

Podemos ahora aplicar lo que se demostró en 4.3.3, es decir, para todo δ .

$$\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}(\bar{Y}_n \in B(x, \delta)) \geq -\Lambda_Y^*(x) \geq -\Lambda^*(x)$$

y la última desigualdad se sigue por 4.3.4.

Vamos ahora a mayorar la probabilidad que aparece aquí arriba.

$$\begin{aligned}
 \{\|\overline{Y}_n - x\| < \delta\} &\subset \{\|\overline{Y}_n - x\| < \delta\} \cap \{\|\varepsilon\overline{Z}_n\| \geq \delta/2\} \\
 &\subset \{\|\overline{Y}_n - x\| < \delta\} \cap \{\|\varepsilon\overline{Z}_n\| \geq \delta/2\} \cap \Omega \\
 &\subset \{\|\overline{Y}_n - x\| < \delta\} \cap \{\|\varepsilon\overline{Z}_n\| \geq \delta/2\} \cap \{\|\varepsilon\overline{Z}_n\| < \delta/2\} \\
 &\quad \cup \{\|\varepsilon\overline{Z}_n\| \geq \delta/2\} \\
 &\subset \{\|\overline{Y}_n - x\| < \delta\} \cap \{\|\varepsilon\overline{Z}_n\| < \delta/2\} \cup \{\|\varepsilon\overline{Z}_n\| \geq \delta/2\}
 \end{aligned}$$

y

$$\begin{aligned}
 \{\|\overline{Y}_n - x\| < \delta\} \cap \{\|\varepsilon\overline{Z}_n\| < \delta/2\} &\subset \{\|\overline{X}_n - x\| + \|\varepsilon\overline{Z}_n\| \leq 2\delta\} \\
 &\subset \{\|\overline{X}_n - x\| \leq 3\delta/2\}
 \end{aligned}$$

y \overline{Z}_n se distribuye con la misma ley que $\frac{Z_j}{\sqrt{n}}$, así,

$$\begin{aligned}
 \lim_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}(\|\varepsilon\overline{Z}_n\| \geq \delta/2) &= \lim_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}\left(\varepsilon^2 \frac{\|Z_1\|^2}{\sqrt{n}} \geq \left(\frac{\delta}{2}\right)^2\right) \\
 &\leq \lim_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}\left(\exists j \leq d, \left|\frac{1}{\sqrt{n}} Z_1^j\right|^2 \geq \frac{\delta^2}{4\varepsilon^2 d}\right) \\
 &\leq \lim_{n \rightarrow \infty} \frac{1}{n} \log \left[\sum_{j=1}^d \mathbb{P}\left(\left|\frac{1}{\sqrt{n}} Z_1^j\right|^2 \geq \frac{\delta^2}{4\varepsilon^2 d}\right) \right] \\
 &= \lim_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}\left(\left|\frac{1}{\sqrt{n}} N(0, 1)\right| \geq \frac{\delta}{2\varepsilon\sqrt{d}}\right) = -\frac{\delta^2}{8\varepsilon^2 d}
 \end{aligned}$$

lo que implica en particular que para toda $M > 0$ existe ε_0 tal que para todo $\varepsilon < \varepsilon_0$,

$$\lim_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{P}(\|\varepsilon\overline{Z}_n\| \geq \delta/2) \leq -M \tag{4.3.6}$$

por lo que

$$\mathbb{P}(\|\varepsilon\overline{Z}_n\| \geq \delta/2) \leq \exp(-nM)$$

entonces

$$\mathbb{P}(\|\overline{X}_n - x\| < 3\delta/2) \geq \mathbb{P}(\|\overline{Y}_n - x\| < \delta) - \mathbb{P}(\|\varepsilon\overline{Z}_n\| \geq \delta).$$

Sea α constante y M tal que $M \leq \Lambda^*(x) + \alpha$. Como $\Lambda^*(x)$ es un límite inferior, y por 4.3.5 se tiene que existe n_0 tal que para toda $n \geq n_0$

$$\frac{1}{n} \log \mathbb{P}(\|\overline{Y}_n - x\| < \delta) \geq -\Lambda^*(x) - \alpha$$

por lo que

$$\mathbb{P}(\|\overline{Y}_n - x\| < \delta) \geq \exp[-n(\Lambda^*(x) + \alpha)]$$

y sustituyendo en 4.3.6

$$\mathbb{P}(\|\overline{X}_n - x\| < 3\delta/2) \geq \exp[-n(\Lambda^*(x) + \alpha)] - \exp(-nM)$$

como $M \geq \Lambda^*(x) + \alpha$ entonces $-\exp[-nM] \geq -\exp[-n(\Lambda^*(x) + \alpha)]$,
lo que

$$\mathbb{P}(\|\overline{X}_n - x\| < \frac{3\delta}{2}) \geq 2 \exp[-n(\Lambda^*(x) + \alpha)].$$

Como resultado de este teorema se tiene el siguiente corolario.

Corolario 4.3.1. *Si A es un abierto convexo y si $\mathcal{D}(\Lambda) = \mathbb{R}^d$ entonces*

$$\lim_{n \rightarrow +\infty} \frac{1}{n} \log \mu_n(A) = -\inf\{\Lambda^*(x) : x \in A\}.$$

Capítulo 5

PGD en los casos dependientes.

En los capítulos anteriores, nos interesamos exclusivamente en el caso de v.a. independientes. Sin embargo, numerosas situaciones relativamente naturales en teoría de probabilidades hacen intervenir v.a. que no son independientes (basta considerar las cadenas de Markov). Entonces, si queremos estudiar dichas situaciones bajo el ángulo de las grandes desviaciones, es necesario encontrar nuevas herramientas para extender las nociones que acabamos de ver. Esa es la finalidad de este capítulo.

5.1 Descripción del teorema.

Sea $(Z_n)_n$ una sucesión de v.a., $Z_n : \Omega \rightarrow \mathbb{R}^d$, y sea Λ_n la sucesión de funciones log-Laplace asociadas. En lo siguiente, Z_n jugará el mismo papel que \bar{X}_n en los capítulos anteriores, conviene entonces observar qué propiedades, implícitas o no, hemos utilizado hasta ahora. Sea Ξ la log-Laplace de X_1 y Ξ_n la log-Laplace de \bar{X}_n , entonces

$$\begin{aligned}\Xi_n(\lambda) &= \log \mathbb{E} \left[\exp \left(\left\langle \lambda, \frac{1}{n} \sum_{j=1}^n X_j \right\rangle \right) \right] \\ &= \log \mathbb{E} \left[\exp \left(\sum_{j=1}^n \left\langle \frac{\lambda}{n}, X_j \right\rangle \right) \right] \\ &= n \Xi \left(\frac{\lambda}{n} \right)\end{aligned}$$

por lo que

$$\frac{1}{n}\Xi_n(n\lambda) = \Xi(\lambda)$$

y es este cálculo el que motiva la hipótesis siguiente

$$(H.1) \quad \text{para toda } \lambda \in \mathbb{R}^d, \frac{1}{n}\Lambda_n(n\lambda) \longrightarrow \Lambda(\lambda) \in [-\infty, +\infty]$$

donde Λ ya no designa necesariamente la log-Laplace de una medida.

La segunda hipótesis también resalta a la vista de lo que vimos en los capítulos anteriores:

$$(H.2) \quad 0 \in \text{Int}(\mathcal{D}(\Lambda))$$

donde $\mathcal{D}(\Lambda)$ es el conjunto de vectores $\lambda \in \mathbb{R}^d$ tales que $\Lambda(\lambda) \in \mathbb{R}$ por lo que definimos

$$\Lambda^*(x) := \sup\{\langle \lambda, x \rangle - \Lambda(\lambda); \lambda \in \mathbb{R}^d\}.$$

Hacemos notar que, como $\Lambda_n(0) = 0$, la hipótesis (H.1) nos lleva a $\Lambda(0) = 0$, que implica en particular, que $\Lambda^*(x) \geq 0$.

La definición siguiente no aparecerá inmediatamente de forma evidente, sin embargo, juega un papel muy importante para lo que sigue.

Definición 5.1.1. Un punto x de \mathbb{R}^d es llamado punto expuesto de Λ^* , con respecto a un hiperplano exponente si

$$\text{para toda } y \neq x, \Lambda^*(y) > \Lambda^*(x) + \langle \eta, y - x \rangle.$$

Llamaremos \mathcal{E} al conjunto de puntos expuestos de Λ^* cuyo uno de los hiperplanos exponentes está en $\text{Int}(\mathcal{D}(\Lambda))$.

Teorema 5.1 (Gartner-Ellis). Si las hipótesis (H.1) y (H.2) se satisfacen entonces, si llamamos μ_n a la ley de Z_n :

$$\begin{aligned} \text{Para todo } F \text{ cerrado,} \quad & \overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(F) \leq -\inf\{\Lambda^*(x); x \in F\} \quad y \\ \text{para todo } O \text{ abierto,} \quad & \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(O) \geq -\inf\{\Lambda^*(x); x \in O \cap \mathcal{E}\} \end{aligned}$$

Además, si $\mathcal{D}(\Lambda) = \mathbb{R}^d$ y si Λ es diferenciable sobre \mathbb{R}^d , entonces μ_n satisfacen un PGD con función de tasa buena Λ^* .

Observación. Podemos deshechar la hipótesis de la última parte del teorema si suponemos simplemente que Λ es esencialmente regular, es decir,

- i) Λ es diferenciable en el interior de su dominio, y 0 está en el interior.
- ii) Si $\lambda_n \rightarrow \lambda$, con $\lambda_n \in (\mathcal{D}(\Lambda))^o$, entonces $|\text{grad}\Lambda(\lambda_n)| \rightarrow +\infty$.

Antes de demostrar el teorema 5.1, comenzaremos por dar algunas propiedades útiles de Λ y Λ^* .

5.2 Propiedades de Λ y Λ^* .

Proposición 5.2.1. *Propiedades:*

- (1) Λ y Λ^* son funciones convexas, y si $0 \in (\mathcal{D}(\Lambda))^o$, entonces $\Lambda(\lambda) \neq -\infty$.
- (2) Si $0 \in (\mathcal{D}(\Lambda))^o$, entonces Λ^* es una función de tasa buena.
- (3) Si $y = \text{grad}\Lambda(\eta)$, entonces $\Lambda^*(y) = \langle \eta, y \rangle - \Lambda(\eta)$. Por otra parte, $y \in \mathcal{E}$ y η es uno de sus hiperplanos exponentes.

Demostración.

- (1) Λ es convexa, como límite de funciones convexas, por la hipótesis (H.1), $\Lambda^*(x)$ es convexa, por ser el supremo de funciones afines. Para la segunda parte negaremos la proposición, entonces suponemos que existe $\lambda \in \mathbb{R}^d$ tal que $\Lambda(\lambda) = -\infty$, y sea $\alpha \in (0, 1)$, como Λ es convexa, tenemos

$$\Lambda(\alpha\lambda) = \Lambda(\alpha\lambda + (1 - \alpha)0) \leq \alpha\Lambda(\lambda) + (1 - \alpha)\Lambda(0) = \alpha\Lambda(\lambda) = -\infty,$$

entonces el segmento $[0, \lambda]$ no está en $\mathcal{D}(\Lambda)$, lo que prueba que $0 \notin (\mathcal{D}(\Lambda))^o$ (pues entonces podríamos encontrar una bola centrada en 0 y contenida totalmente en $(\mathcal{D}(\Lambda))^o$, bola que intersectaría forzosamente este segmento).

- (2) $\Lambda^*(x)$ es s.c.i. por ser el supremo de funciones continuas (por ser afines). entonces, los conjuntos de nivel $\{\Lambda^*(x) \leq a\}$ son cerrados, sólo basta demostrar que están acotados, lo que ya hicimos en la proposición 3.1.1 (1) (Notando que Λ es continua en el interior de su dominio, por ser convexa).
- (3) Aplicando el método de la proposición 3.1.1 (2), obtenemos fácilmente que $\Lambda^*(y) = \langle y, \eta \rangle - \Lambda(\eta)$. Lo que es menos evidente es la exposición de y . Sea entonces $x \in \mathbb{R}^d$ tal que $\Lambda^*(x) \leq \Lambda^*(y) + \langle \eta, x - y \rangle$, vamos a mostrar que

$x = y$, lo que dará el resultado pasando a la contrapropuesta. Para hacerlo vamos a mostrar que $\langle y - x, z \rangle = 0$ para todo $z \in \mathbb{R}^d$. Sea entonces $z \in \mathbb{R}^d$

$$\begin{aligned} \langle z + \eta, x - \Lambda(z + \eta) \rangle &\leq \Lambda^*(x) \leq \underbrace{\Lambda^*(y)}_{=\langle y, \eta \rangle - \Lambda(\eta)} + \langle \eta, x - y \rangle \\ &\leq \langle \eta, x \rangle - \Lambda(\eta) \end{aligned}$$

de ahí

$$\langle z, x \rangle - \Lambda(z + \eta) \leq -\Lambda(\eta)$$

es decir

$$\langle z, x \rangle \leq \Lambda(z + \eta) - \Lambda(\eta)$$

de donde para todo $z \in \mathbb{R}^d$

$$\langle z, x \rangle \leq \frac{\Lambda(\varepsilon z + \eta) - \Lambda(\eta)}{\varepsilon}$$

haciendo tender $\varepsilon \rightarrow 0$, encontramos $\forall z, \langle z, x \rangle \leq \underbrace{\langle \text{grad} \Lambda(\eta), z \rangle}_{=y}$, y cambiando z por $-z$ el resultado está probado.

5.3 Teorema de Gartner-Ellis.

Demostración.

1. Tensión exponencial.

Sea $B = \{e_1, \dots, e_d\}$ la base canónica de \mathbb{R}^d . Como 0 está en el interior de $\mathcal{D}(\Lambda)$, existe, para todo j un α_j tal que $-\alpha_j e_j$ y $\alpha_j e_j$ estén en el interior de $\mathcal{D}(\Lambda)$. Sea μ_n^j la j -ésima marginal de μ_n . Utilizando 3.2.7 y el método de cálculo de la mayoración en el teorema 3.2, tenemos

$$\begin{aligned} \mu_n^j([t, +\infty)) &\leq \mathbb{E}(\exp[n\alpha_j(\langle e_j, \sum \frac{\Xi_i}{n} \rangle - t)]) \\ &= \mathbb{E}(\exp[\langle n\alpha_j e_j, \frac{1}{n} \sum \Xi_i \rangle - n\alpha_j t]) \\ &= \exp(-n\alpha_j t) \mathbb{E}(\exp[\langle n\alpha_j e_j, \frac{1}{n} \sum \Xi_i \rangle]) \\ &= \exp(-n\alpha_j t - \Lambda_n(n\alpha_j e_j)) \\ &= \exp(-n(\alpha_j t - \frac{\Lambda_n(n\alpha_j e_j)}{n})) \\ &\rightarrow \exp[-n(\alpha_j t - \Lambda_n(\alpha_j e_j))] \end{aligned}$$

y una desigualdad análoga del otro lado. Terminamos entonces como en la primera parte del Teorema 4.1.

2. Mayoración sobre los compactos.

Aplicaremos el mismo razonamiento que en el teorema 4.1. Sea $\delta > 0$, y hagamos:

$$I^\delta(x) = \inf \left\{ \Lambda^*(x) - \delta; \frac{1}{\delta} \right\} < \Lambda^*(x).$$

Si fijamos x , existe $\lambda_x \in \mathbb{R}^d$ tal que

$$\langle \lambda_x, x \rangle - \Lambda(\lambda_x) \geq I^\delta(x).$$

Sea $\rho_x > 0$ tal que $\rho_x \|\lambda_x\| < \delta$. Si hacemos $B_x = B(x; \rho_x)$, y procedemos como en la parte B del teorema 3.1, tenemos que

$$\begin{aligned} \mu_n(B_x) &\leq \mathbb{E}(\exp(n(\langle \lambda_x, \Xi_n \rangle - \langle \lambda_x, x \rangle + \delta))) \\ &= \mathbb{E}(\exp(\langle n\lambda_x, \Xi_n \rangle - \langle n\lambda_x, x \rangle + n\delta)) \\ &= \exp(n\delta - n\langle \lambda_x, x \rangle) \mathbb{E}(\exp(\langle n\lambda_x, \Xi_n \rangle)) \\ &= \exp(n\delta - n\langle \lambda_x, x \rangle) \exp(\Lambda_n(n\lambda_x)) \\ &\leq \exp[\Lambda_n(\lambda_x) - n\langle \lambda_x, x \rangle + n\delta] \end{aligned}$$

entonces

$$\frac{1}{n} \log \mu_n(B_x) \leq \frac{1}{n} \Lambda_n(n\lambda_x) - \langle \lambda_x, x \rangle + \delta$$

y como $\frac{1}{n} \Lambda_n(n\lambda_x) \rightarrow \Lambda(\lambda_x)$, tenemos, para n suficientemente grande que

$$\frac{1}{n} \log \mu_n(B_x) \leq \Lambda(\lambda_x) - \langle \lambda_x, x \rangle + 2\delta \leq -I^\delta(x) + 2\delta$$

con lo que el final de la prueba es el mismo que la segunda parte del teorema 4.1.

3. Minoración sobre los abiertos.

Sea $y \in \mathcal{E}$ de hiperplano expuesto $\eta \in \mathcal{D}(\Lambda(\lambda))$, vamos a mostrar que

$$\text{para toda } \delta > 0, \quad \frac{1}{n} \log \mu_n(B(y, \delta)) \geq -\Lambda^*(y). \quad 5.1.1$$

Supongamos 5.1.1 demostrado, entonces, si O es un abierto de \mathbb{R}^d , tendremos que para toda $y \in \mathbb{R} \cap \mathcal{E}$ existe $\delta > 0$ tal que

$$B(y, \delta) \subset O$$

y entonces

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \mu_n(O) \geq \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \mu_n(B(y, \delta)) \geq -\Lambda^*(y)$$

así

$$\underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \mu_n(O) \geq -\inf\{\Lambda^*(y) : y \in O \cap \mathcal{E}\}$$

que es exactamente lo que queremos.

Demostremos entonces 5.1.1 utilizando de nuevo un cambio de medida. Definimos así v_n por

$$\frac{dv_n}{d\mu_n}(x) = \exp[n\langle \eta, x \rangle - \Lambda_n(n\eta)]$$

Notamos el hecho que $\frac{1}{n}\Lambda_n(n\eta) \rightarrow \Lambda(\eta) \in \mathbb{R}$ implica que, al menos para $n \geq n_0$ suficientemente grande, $\frac{1}{n}\Lambda_n(n\eta)$ es finito. En el resto del párrafo supondremos que $n \geq n_0$. Como anteriormente, tenemos, para todo $\varepsilon <$

$$\begin{aligned} \mu_n(B(y, \delta)) &\geq \int_{B(y, \varepsilon)} \exp[-n\langle \eta, z \rangle - \Lambda_n(n\eta)] v_n(dz) \\ &= \int_{B(y, \varepsilon)} \exp[-n\langle \eta, z - y \rangle - n\langle \eta, y \rangle + \Lambda_n(n\eta)] v_n(dz). \end{aligned}$$

Pero, según la desigualdad de Schwartz tenemos

$$|\langle \eta, z - y \rangle| \leq \|\eta\| \cdot \|z - y\| \leq \varepsilon \cdot \|\eta\|$$

entonces

$$\begin{aligned} \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(B(y, \varepsilon)) &\geq \overbrace{\underline{\lim}_{n \rightarrow \infty} \left(\frac{1}{n} \Lambda_n(n\eta) \right)}{=\Lambda(\eta)} - \varepsilon \cdot \|\eta\| - \langle \eta, y \rangle \\ &\quad + \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log v_n(B(y, \varepsilon)) \\ &\geq -\Lambda^*(y) - \varepsilon \cdot \|\eta\| + \underline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log v_n(B(y, \varepsilon)). \end{aligned}$$

En esta etapa no es posible aplicar los métodos de los teoremas 3.2 y 4.1, ya que en este caso, las variables no son independientes, por lo que tendremos que demostrar el resultado auxiliar siguiente.

Leema 5.3.1.

$$v_n(B(y, \varepsilon)) \rightarrow 1$$

Demostración.

Mostraremos que $v_n(B(y; \varepsilon)^c) \rightarrow 0$, para lo cual definimos la log-Laplace asociada a las v_n , sea

$$\Xi_n(\lambda) = \log \left(\int_{\mathbb{R}^d} e^{\langle \lambda, x \rangle} v_n(dx) \right),$$

entonces

$$\begin{aligned} \Xi_n(n\lambda) &= \log \left(\int_{\mathbb{R}^d} e^{\langle n\lambda, x \rangle} \cdot e^{n\langle \eta, x \rangle} \cdot e^{-\Lambda_n(n\eta)} \mu_n(dx) \right) \\ &= \log \left(e^{-\Lambda_n(n\eta)} \int_{\mathbb{R}^d} e^{\langle n(\lambda+\eta), x \rangle} \mu_n(dx) \right) \\ &= \Lambda_n(n(\lambda + \eta)) - \Lambda_n(n\eta) \end{aligned}$$

de ahí

$$\begin{aligned} \frac{1}{n} \Xi_n(n\lambda) &\longrightarrow \Lambda(\lambda + \eta) - \Lambda(\eta) \\ &= \log \mathbb{E}(e^{\langle \lambda+\eta, x \rangle}) - \log \mathbb{E}(e^{\langle \eta, x \rangle}) \\ &= \log \mathbb{E}(e^{\langle \lambda+\eta, x \rangle - \langle \eta, x \rangle}) \\ &= \log \mathbb{E}(e^{\langle \lambda, x \rangle}) \\ &= \Xi(\lambda). \end{aligned}$$

Por lo que Ξ cumple exactamente las hipótesis del teorema 5.1. De este hecho, según las primeras partes que ya han sido probadas y de la proposición 4.1, disponemos de mayoraciones sobre los cerrados, es decir, sobre $B(y; \varepsilon)^c$, por lo que

$$\overline{\lim}_{n \rightarrow \infty} \frac{1}{n} \log v_n(B(y, \varepsilon)^c) \leq -\inf\{\Xi^*(x) : x \in B(y, \varepsilon)^c\}. \quad 5.1.2$$

Basta con demostrar que

$$\inf\{\Xi^*(x) : x \in B(y, \varepsilon)^c\} = \alpha > 0. \quad 5.1.3$$

En efecto, si tenemos 5.1.3, entonces existirá $n_1 \geq n_0$ tal que para todo $n \geq n_1$

$$\frac{1}{n} \log v_n(B(y, \varepsilon)^c) \leq -\frac{\alpha}{2}$$

entonces

$$v_n(B(y, \varepsilon)^c) \leq \exp \left[-\frac{n\alpha}{2} \right]$$

lo que dará el resultado.

Para mostrar 5.1.3 probamos anteriormente que la cota inferior se alcanza es decir, existe $x_\infty \notin B(y, \varepsilon)$ tal que

$$\inf\{\Xi^*(x) : x \in B(y, \varepsilon)^c\} = \Xi^*(x_\infty).$$

Hacemos notar que podemos suponer que $\Lambda^*(y) < +\infty$ pues, si no fuera así, la desigualdad 5.1.1 es trivial. Por otra parte

$$\begin{aligned} \Xi^*(x) &= \sup\{\langle \lambda, x \rangle - \Lambda(\eta + \lambda) + \Lambda(\eta) : \lambda \in \mathbb{R}\} \\ &= \sup\{\langle \lambda + \eta, x \rangle - \Lambda(\eta + \lambda) - \langle \eta, x \rangle + \Lambda(\eta) : \lambda \in \mathbb{R}\} \\ &= \Lambda^*(x) + \Lambda(\eta) - \langle \eta, x \rangle \end{aligned}$$

lo que prueba que $\Xi^*(y) < \infty$ y que Ξ^* es una función de tasa buena. De este hecho, si $\alpha = +\infty$, no hay nada más que decir, ya que tenemos lo que queremos. Si ahora $\alpha < +\infty$, entonces el conjunto de nivel $\{\Xi^*(x) \leq \alpha + 1\}$ es compacto. Como α es una cota inferior (límite inferior), si tomamos una sucesión x_n de puntos $B(y, \varepsilon)^c$ tal que $\Xi^*(x_n)$ converge hacia α , entonces podemos suponer que la sucesión x_n toma valores dentro del conjunto de nivel $\{\Xi^*(x) \leq \alpha + 1\}$. Esto que implica que podemos extraer de ahí una sub-sucesión convergente, de límite $x_\infty \in B(y, \varepsilon)^c$ (porque $B(y, \varepsilon)^c$ es cerrado), y finalmente la s.c.i. de Ξ^* da

$$\alpha \leq \Xi^*(x_\infty) \leq \liminf_{n \rightarrow \infty} \Xi^*(x_n) \leq \alpha$$

lo que muestra que α es alcanzada en x_∞ . Probemos ahora que $\alpha > 0$. Como $x_\infty \notin B(y, \varepsilon)$ tenemos, en particular $x_\infty \neq y$. Pero y es un punto expuesto a Λ^* , de hiperplano exponente η , entonces

$$\Lambda^*(x_\infty) > \Lambda^*(y) + \langle \eta, x_\infty - y \rangle$$

de ahí

$$\Lambda^*(y) < \Lambda^*(x_\infty) + \langle \eta, y - x_\infty \rangle$$

y

$$\Lambda^*(y) \geq \langle \eta, y \rangle - \Lambda(\eta)$$

donde

$$\langle \eta, y \rangle - \Lambda(\eta) < \Lambda^*(x_\infty) + \langle \eta, y - x_\infty \rangle$$

que, simplificando y teniendo en cuenta que $\Xi^*(x_\infty) = \Lambda^*(x_\infty) + \Lambda(\eta) - \langle \eta, x_\infty \rangle$,
el resultado buscado, lo que explica el lema y la minoración.

Bibliografía

- ash72] R. Ash. *Real Analysis and Probability*. Academic Press.Inc., 1972.
- bil79] Patrick Billingsley. *Probability and Measure*. New York :J.Wiley, 1979.
- re75] L. Breimer. *Probability*. Addison, 1975.
- or94] Refugio Trujillo Cortes. *Series Aleatorias.Tesis de Licenciatura.UNAM*, 1994.
- em98] O. Dembo, A. & Zeitouni. *Large Deviations Techniques and Applications*, volume 1. Springer Verlag, second edition, 1998.
- el71] W. Feller. *An Introduction to Probability Theory and Applications*. Wiley & Sons, 2nd. edition, 1971.
- ac98] Annie Jacquet. *Grandes deviations et aplicaciones*, 1998.
- ew96] John T. & Russell Raymond Lewis. *An Introduction to Large Deviations for Teletraffic Engineers*. Dublin Institute for Advanced Studies (DIAS), 10 Burlington Road, Dublin 4, Ireland, October 1996. lewis@stp.dias.ie, russell@stp.dias.ie.
- ic71] Durret Richard. *Probability: Theory and Examples*. Pacific Grove,California:Wadsworth, 1971.
- os88] Sheldon Ross. *A first course in probability*. Mc.millan, 1988.