

20321  
10



# UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

ESCUELA NACIONAL DE ESTUDIOS PROFESIONALES  
"ACATLÁN"

"LA PROBABILIDAD EN LA  
PROGRAMACION MATEMÁTICA"



**T E S I S**

QUE PARA OBTENER EL TÍTULO DE:

**A C T U A R I O**

**P R E S E N T A :**

**ALAN EVARISTO HERNANDEZ ESTRADA**

ASESOR: FIS. MAT. JORGE LUIS SUAREZ MADARIAGA



TESIS CON  
FALLA DE ORIGEN

MEXICO, D.F.

OCTUBRE 2003

A



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.

οτε ημην νηπιου, ελαλουν ωθ νηπιου ,  
εφρουουν ωθ νηπιου, ελογιζομην ωθ  
νηπιου; οτε γεφουα αβρ, κατηγορηκα τα  
του νηπιου. βλεπομεν γαρ αρτι δι  
εσοπτρου εν αινιγματι, τοτε δε προσωπον  
προθ προσωπον αρτι γνωσκω εκ μερουθ,  
τοτε δε επιγνωσομαι καθωθ και  
επεγνωσθην. νυνι δε μενει πιστιθ, ελπιθ,  
αγαπη, τα τρια ταυτα μειζων δε τουτων  
η αγαπη.

*"Cuando (yo) era niño pequeño, hablaba como niño, pensaba como niño, razonaba como niño; ahora que me he hecho hombre, he abolido las cosas del niño. Porque veo (aún) ahora mediante espejo en enigma, pero entonces cara a cara; ahora conozco en parte, pero entonces conoceré perfectamente conforme también fui conocido perfectamente. Pero ahora permanecen la fe, la esperanza y el amor; pero el mayor de ellos es el amor."*

1ª Corintios 13: 9-13

13

TESIS CON  
FALLA DE ORIGEN

## AGRADECIMIENTOS

*A mi Dios, ya que siempre me ha escuchado cuando lo he llamado, me ha ayudado cuando lo he necesitado y siempre ha estado cerca de mí cuando lo he buscado, además de que me ha dado grandes y abundantes bendiciones todos los días, sin importarle que muchas veces he metido la pata y reconociendo que todo lo que soy se lo debo a Él.*

*No escogí un orden especial para los agradecimientos de mi familia, los escogí aleatoriamente. (para que ninguno se sienta)*

*A mi hermano (Flavio), quien con su amor y comprensión me ha ayudado tanto... que nunca terminaría de pagarle las cosas que me ha dado y tampoco podría enumerar los momentos bellos que hemos compartido desde nuestra infancia y recordando que para nuestros padres seguimos siendo unos niños.*

*A mi Pa. Desde que comencé mis estudios (en preescolar) recuerdo que ya soñabas con este momento y siempre te has esforzado para darnos lo mejor, para que podamos seguir adelante, gracias por tu amor, tus desvelos y mal pasadas en el trabajo, ya que me inculcaste el deseo de estudiar y es por eso que puedo terminar un ciclo en mi vida y porque me sigues apoyando en el nuevo ciclo que he comenzado.*

*A mi Mami. Pues a ti te provoqué preocupación desde que estaba en tu vientre y se que aún sigo haciendo que te preocupes. Gracias por tu compañía y tu amor que siempre me has mostrado, gracias por tus oraciones durante mis exámenes (han sido de gran bendición) y por todas las cosas que sacrificaste por amor a mi hermano y a mí. Yo sé que este también es uno de tus sueños y quiero que sepas este trabajo también es tuyo.*

*A la memoria de dos grandes mujeres que influyeron de manera positiva a mi vida: mi abuelita ANA y mi mamá CONCHITA a quienes les hubiera dado mucho gusto leer estas líneas. (yo se que ellas están en los brazos más cálidos en los que podrían estar)*

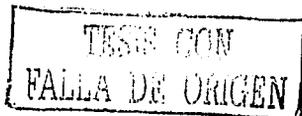
*A dos hombres importantes para mi vida: mi papá Flavio (grande) de quien siempre he recibido su apoyo y su amor en todo momento y mi abuelito Raül que me inculcó un camino y una gran herencia que espero seguir compartiendo.*

*A mis tios Raül, René, Tomy, Juan, José, Alejandro, Andrés y mis tias Ruth, Orallia, Yola, Laura, Lupita, Mayra, Lety y Amelia que siempre han sabido darme consejos de los cuales he aprendido muchas cosas.*

*A mis tios Fausto, Flavio(mi tercer papá), Daniel, Jesús, Enrique y mis tias Fill, Sandra, Fátima, Faby, Verónica y Silvia porque a pesar de la distancia siempre están conmigo y se que puedo confiar en ustedes.*

*A mis primos Pepe, Chuchln, César, Cocoy, Alex, Fausto, Fabián, Iván, Raül, Omar, Vico, Flavio, René, Lalo, Miguel, Josué y Jesús porque en mis ratos de diversión puedo contar con ustedes y los que me faltaron se darán por aludidos, porque si escribo los nombres de todos tal vez me alcanzaria para escribir un libro.*

C



*A mis primas Sandra, Ana, Wendy, Carol, Paty, Brenda, Cinthia, Ivonne, Jazmin, Fifi, Jenny, Alma, Mérida, Belem, Hlusion..... ya que también puedo contar con ustedes y me han ayudado a sonreír en los momentos en los que más ocupado he estado.*

*A la Señora Geo, Alma y Mary quienes me brindaron una familia que siempre me apoyó para lograr esta meta, así como a toda su familia a la cual quiero mucho.*

*A mi familia restante (es mucha) quiero decirles que este trabajo también es parte de ustedes.*

*A mis compadres: Fifi y Mike ya que somos como aquellos tres(aunque somos cuatro) de Babilonia que prefirieron ser quemados a ceder.*

*A mis grandes amigos y gran banda: Marcos, Saúl y Daniel ya que compartimos un sueño importante que nos une y nos convierte casi en hermanos.*

*A mis amigos Isaac, Cheo, Gerardo, David, Erik, Christian, Erik, Monti, Roy, César, Oscar, Uziel, Ray y todos aquellos con los que comparto una esperanza.....*

*A mis amigas Brenda X., Brenda H, Sarai, Noelia, Idalia, Raquel, Linda, Laura, Mayra, Magali, Edith, Elsa, Sarai U, Ale, Keila, Yoli, Keren..... y las que me faltaron, quiero que sepan que las quiero mucho.*

*A mis grandes e inseparables amigos Alain, Carole, Margot Cristian, Bere, Horacio, Isaac, Oswaldo y Mike (la familia exponencial) ya que compartimos muchas alegrías y preocupaciones(por los exámenes) así como los momentos de ficha y de convivencia.*

*A mis no mas ni menos importantes amigos Lupita T, Alfredo, Mahil, Julio, Dario, Carlos, Ricardo, Ricardo P, Iris, Jaz y su amigo, Pamela, Judith, Diana, Gloria, Iliana, Linda, Yadis, Tony, Tere, Marinné, Kika, Nancy, Adriana, Conde, Robert, René, Victor, Paquito, Mayrita.....gracias por su apoyo.*

*A mi amiguita más cercana Yssel (creo que ahora si lo escribí bien), ya que tu me das tu amistad como un bonito regalo y porque se que puedo confiar en ti, gracias por estar en los momentos en los que necesitaba comprensión, en las buenas y malas.*

*A quienes me regalaron su amistad desde el principio Israel, Gaby, Aarón, Angie, Jacobo, Emanuel, Ivette, Denise, Paty, Bruno, Lupita, Gerardo, Julius, Demian..... en fin gracias a todos ustedes porque siempre creyeron en mí.*

*A todos mis maestros y en especial a quienes se convirtieron en mis amigos Pepe, Madariaga, Valadez, Iván, Tavera, Pablo, Arriaga, Lavin, Pérez Ortiz, Ramón, Andrés..... ya que ellos me dieron mi formación como universitario, gracias.*

*En especial a todo el grupo de cálculo II al cual tuve el placer de darles clase, espero que muy pronto pueda leer sus trabajos de titulación.*

*A mis nuevos amigos Luis, Gerardo, Nelson, Juan Pablo, José Luis, Dalia, Mayra y Sofía con quienes se que puedo contar para lo que sea y en especial a Yesenia ya que me ha dado su ayuda en todo momento... a los que me faltaron..... que Dios los bendiga.*

D

TESIS CON  
FALLA DE ORIGEN

## Indice

Introducción	ii
Capítulo 1. Conceptos Básicos.	
1.1 Variables Aleatorias.	1
1.2 Función de Densidad.	4
1.3 Esperanza Matemática.	8
1.4 Función Generadora de Momentos.	11
1.5 Ejemplos de Teoría de la Distribución.	13
Capítulo 2. Programación Lineal y no- Lineal.	
2.1 Definiciones.	15
2.2 Algoritmo SIMPLEX.	17
2.3 Algoritmo DUAL-SIMPLEX.	20
2.4 (programación no-lineal) Método de los multiplicadores de Lagrange.	22
Capítulo 3. Programación Estocástica.	
3.1 Definición.	33
3.2 Programación estocástica de doble etapa.	33
3.3 Programación estocástica restringida.	44
3.4 Caso 1. Coeficientes $a_j$ con distribución Normal.	50
3.5 Caso 2. Coeficientes $b_i$ con distribución Normal.	53
3.6 Caso 3. Todos los coeficientes $a_j$ y $b_i$ distribución Normal.	54
Apéndice I: Funciones Indicadoras	57
Apéndice II. Tabla de la Distribución Normal Estándar.	58
Conclusiones.	61
Bibliografía	62

TESIS CON  
FALLA DE ORIGEN

---

## Introducción

Una de las formas de resolver problemas de maximización o minimización de funciones, las cuales se encuentran restringidas por algunas otras funciones, es por medio de la programación lineal o la no-lineal, las cuales están diseñadas para la solución de programas determinísticos. Pero ¿Qué es lo que pasa cuando los coeficientes de las restricciones son variables aleatorias?, ¿Acaso los métodos mencionados antes pueden dar solución a este tipo de programas?. La respuesta es que no, al menos de una forma directa, ya que es necesario transformar la parte estocástica del programa a resolver a un equivalente determinístico, para lo que se utiliza la teoría de la probabilidad y ahora sí, se puede resolver por medio de los métodos para la solución de los programas que no son estocásticos. Otro de los métodos consiste en esperar a que ocurran algunos de los valores de las variables aleatorias para poder anticipar los valores desconocidos y así darle respuesta al problema deseado.

Los métodos que se exponen en este trabajo no son todos lo que existen, ya que se sigue haciendo investigación para mejorar los métodos y hacerlos menos complicados, pero son muy representativos de la programación estocástica.

En el capítulo uno se revisaran los conceptos básicos de la teoría probabilística para poder sustentar los procedimientos que se realizarán en el tercer capítulo, además se verificarán como se distribuyen sumas de variables aleatorias las cuales serán de utilidad en el tercer capítulo.

En el segundo capítulo se pondrá interés en conocer lo que es un problema de programación lineal (PPL) y uno no-lineal, además de conocer algunos métodos para resolverlos.

En el último capítulo se resolverán problemas de programación matemática, aplicando los conceptos vistos en los capítulos anteriores como: Programación lineal y no-lineal, maximización por el método de los multiplicadores de Lagrange y la teoría de la distribución.

TESIS CON  
FALLA DE ORIGEN

## 1. Conceptos Básicos

### 1.1 Variables Aleatorias.

Una variable aleatoria puede ser definida informalmente como un valor real de una observación, ó una función de observaciones realizadas, para interpretar un experimento en el cual, el valor (en general) puede cambiar de interpretación a interpretación ó por el experimento.

Una definición un poco más formal dice que, una variable aleatoria es un número real valuado en una función con dominio  $\Omega$  ( $X: \Omega \rightarrow \mathfrak{R}$ ), donde  $(\Omega, \mathcal{A}, P)$  es un espacio de probabilidad.

**Definición 1. Variable Aleatoria:** Para un espacio de probabilidad  $(\Omega, \mathcal{A}, P)$ , una "variable aleatoria", denotada por  $X$  ó  $X(\cdot)$ , es una función con dominio  $\Omega$  y la recta real como contradominio. La función  $X(\cdot)$  debe ser tal que al conjunto  $A_r$ , definido de la siguiente forma  $A_r = \{w: X(w) \leq r\}$  pertenece a  $\mathcal{A}$  para cualquier número real  $r$ .

Si pensamos en un experimento aleatorio,  $\Omega$  es el total de resultados del experimento aleatorio, y la función, ó variable aleatoria,  $X(\cdot)$  con dominio  $\Omega$  convierte cada resultado del experimento en su correspondiente número real. Esto es la parte importante de nuestra definición. El hecho de que requerimos una colección de  $w$  para las cuales  $X(w) \leq r$  para ser un evento (i.e. un elemento de  $\mathcal{A}$ ) para cada número  $r$  no es una restricción muy fuerte para nuestro propósito debido a que nuestra intención es usar la noción de variable aleatoria para describir eventos.

Ejemplo 1:

Consideremos el experimento de lanzar una moneda. Sea  $X$  la variable aleatoria que denota el número de caras.  $\Omega = \{\text{cara}, \text{cruz}\}$ , y  $X(w) = 1$  si  $w = \text{cara}$ , y  $X(w) = 0$  si  $w = \text{cruz}$ ; esto es, la variable aleatoria  $X$  asocia un número real a cada resultado del experimento. Nosotros llamamos a  $X$  variable aleatoria y matemáticamente podemos demostrar que satisface la definición 1: Podemos demostrar que  $\{w: X(w) \leq r\}$  pertenece a  $\mathcal{A}$  para cada número real  $r$ .  $\mathcal{A}$  está compuesto de cuatro eventos:  $\emptyset$ ,  $\{\text{cara}\}$ ,  $\{\text{cruz}\}$ ,  $\Omega$ . Ahora, si  $r \leq 0$ , entonces  $\{w: X(w) \leq r\} = \emptyset$ , y si  $0 \leq r < 1$ ,  $\{w: X(w) \leq r\} = \{\text{cara}\}$ , y si  $r \geq 1$ ,  $\{w: X(w) \leq r\} = \Omega$ . Además, para cada  $r$  el conjunto  $\{w: X(w) \leq r\}$  pertenece a  $\mathcal{A}$ . Entonces  $X$  es una variable aleatoria.

**Definición 2. Función de distribución acumulativa.** La función acumulativa de distribución de una variable aleatoria  $X$ , denotada como  $F_X(\cdot)$ , se define como una función real y contradominio en el intervalo  $[0, 1]$ , y satisface  $F(x) = P[\{w: X(w) \leq x\}]$  para cualquier número real  $x$ .

TESIS CON  
FALLA DE ORIGEN

Para cada variable aleatoria se puede construir una función de distribución acumulativa, si ésta es conocida, podemos usarla para encontrar probabilidades de eventos definidos por su variable aleatoria correspondiente. (se puede ver que en ésta definición usamos el hecho de que  $\{\omega: X(\omega) \leq x\}$  pertenece a  $\mathcal{A}$  para todo número real  $r$ , lo cual aparece en nuestra definición de variable aleatoria) Nótese que para diferentes variables aleatorias podemos tener la misma función de distribución acumulativa.

Como una convención, en adelante, a la función de distribución acumulativa, la llamaremos sólo función de distribución.

Ejemplo 2:

Consideremos, de nuevo, el experimento de lanzar una moneda que no está cargada (legal). Sea  $X$  la variable aleatoria que denota el número de caras que salen. Entonces:

$$F_X(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1/2 & \text{si } 0 \leq x < 1 \\ 1 & \text{si } 1 \leq x \end{cases}$$

ó  $F_X(x) = 1/2 I_{[0,1)}(x) + I_{[1,\infty)}$  en notación de funciones indicadoras. (ver el apéndice I)

**Teorema 1.** Sea  $X$  una variable aleatoria, y sea  $F$  la función de distribución de  $X$ . Entonces

- (i)  $F$  es no-decreciente sobre  $\mathcal{R}$ ;
- (ii)  $F$  es continua por la derecha;
- (iii)  $F(x) \rightarrow 0$  cuando  $x \rightarrow -\infty$  y  $F(x) \rightarrow 1$  cuando  $x \rightarrow \infty$ .

**Demostración:**

- (i) Sean  $a$  y  $b$  números reales tales que  $a < b$ . Entonces

$$F(b) - F(a) = P(X \leq b) - P(X \leq a) = P(a < X \leq b) \geq 0.$$

Por lo que  $F$  es no-decreciente en  $\mathcal{R}$ .

- (ii) En vista de lo que se ha establecido, basta con demostrar que

$$F\left(a + \frac{1}{n}\right) \rightarrow F(a) \text{ cuando } n \rightarrow \infty$$

TESIS CON  
FALLA DE ORIGEN

Para todo número real a. Ahora

$$F\left(a + \frac{1}{n}\right) - F(a) = P\left(a < X \leq a + \frac{1}{n}\right) = P(A_n),$$

donde

$$A_n = \left\{ a < X \leq a + \frac{1}{n} \right\} \quad (\in \mathcal{J}) \quad (n = 1, 2, \dots).$$

como

$$A_1 \supseteq A_2 \supseteq \dots \text{ y } \bigcap_1^\infty A_n = \emptyset.$$

Y se sigue que

$$P(A_n) \rightarrow P(\emptyset) = 0 \quad \text{cuando } n \rightarrow \infty.$$

Con esto se concluye la demostración para (ii).

(iii) Necesitamos verificar que  $F(-n) \rightarrow 0$  y  $F(n) \rightarrow 1$  cuando  $n \rightarrow \infty$ . Sea

$$B_n = \{ X \leq n \} \quad (n = 0, \pm 1, \pm 2, \dots).$$

Entonces  $B_{-1} \supseteq B_{-2} \supseteq \dots$  y  $\bigcap_1^\infty B_{-n} = \emptyset$ , y como

$$F(-n) = P(B_{-n}) \rightarrow P(\emptyset) = 0 \text{ cuando } n \rightarrow \infty.$$

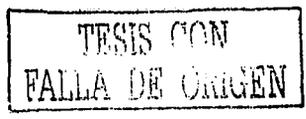
Además

$$B_1 \subseteq B_2 \subseteq \dots \text{ y } \bigcup_1^\infty B_n = \Omega \text{ y}$$

$$F(n) = P(B_n) \rightarrow P(\Omega) = 1 \text{ cuando } n \rightarrow \infty.$$

lo cual completa la demostración. □

Para el ejemplo 2, se pueden verificar fácilmente las condiciones del teorema anterior.



## 1.2 Función de Densidad.

La función de distribución acumulativa describe la distribución de los valores de la variable aleatoria. Para dos clases distintas de variables aleatorias, la distribución de los valores puede ser descrita con mayor facilidad usando la "función de densidad".

**Definición 3. Variables aleatorias discretas.** Una variable aleatoria  $X$  se define como discreta si el rango de  $X$  es contable. Si una variable aleatoria es discreta, entonces su función de distribución correspondiente  $F_X(\cdot)$  se definirá como función de distribución discreta.

**Definición 4. Función de densidad de probabilidad una variable aleatoria discreta.** Si  $X$  es una variable aleatoria discreta con valores distintos  $x_1, x_2, \dots, x_n, \dots$ , entonces la función, denotada por  $f_X(\cdot)$  y definida como:

$$f_X(x) = \begin{cases} P\{X = x\} & x = x_j, j = 1, 2, \dots, n, \dots \\ 0, & \text{si } x \neq x_j \end{cases}$$

es definida como la función de densidad discreta de  $X$ .

Los valores de una variable aleatoria discreta son llamados puntos masa; y  $f_X(x_j)$  denota la masa asociada al punto masa  $x_j$ . Podemos usar la siguiente notación de funciones indicadoras:

$$f_X(x) = \sum_{n=1}^{\infty} P\{X = x_n\} I_{(x_n)}(x)$$

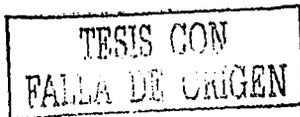
de donde  $I_{(x_n)}(x) = 1$  si  $x = x_n$  e  $I_{(x_n)}(x) = 0$  si  $x \neq x_n$

**Teorema 2.** Sea  $X$  una variable aleatoria discreta.  $F(x)$  puede obtenerse a partir de  $f(x)$  y viceversa.

**Demostración:**

Denotemos los puntos masa de  $X$  por  $x_1, x_2, \dots, x_n, \dots$ . Supongamos que  $f_X(\cdot)$  está dada y entonces  $F(x) = \sum_{\{x_j \leq x\}} f(x_j)$ , entonces  $f(x_j) = F(x_j) - \lim_{0 < h \rightarrow 0} F(x_j - h)$ ; donde  $f(x_j)$  puede encontrarse para cada punto masa  $x_j$ ; de cualquier forma,  $f(x_j) = 0$ , para  $x \neq x_j$ ,  $j = 1, 2, \dots$  y  $f(x)$  está determinada para todos los números reales.

□



## Ejemplo 3:

Consideremos el experimento de lanzar dos dados. Sea  $X$  la variable aleatoria que denota la suma de los valores de los dos dados, por lo que los puntos masa son: 2, 3, ..., 12.  $f_X(\cdot)$  tiene la siguiente forma

$X$	2	3	4	5	6	7	8	9	10	11	12
$f(x)$	1/36	2/36	3/36	4/36	5/36	6/36	5/36	4/36	3/36	2/36	1/36

Acorde con el teorema anterior, como tenemos  $f_X(\cdot)$ , entonces podemos encontrar  $F(\cdot)$ , para cualquier valor de  $X$ ; por ejemplo, si  $x = 3.5$

$$F(X \leq 3.5) = F(3.5) = \sum_{\{x_j \leq 3.5\}} f(x_j) = f(2) + f(3) = \frac{1}{36} + \frac{2}{36} = \frac{3}{36}$$

y si  $F(\cdot)$  está dada, podemos encontrar  $f_X(\cdot)$  para cualquier  $x$ . Por ejemplo para  $x = 5$

$$f(5) = F(5) - \lim_{h \rightarrow 0} F(5-h) = \frac{10}{36} - \frac{6}{36} = \frac{4}{36}$$

**Definición 5. Función de densidad discreta.** Una función  $f(\cdot)$  con la recta real como dominio y el intervalo  $[0, 1]$  como contradominio, es definida como "función de densidad discreta" y para algún conjunto contable  $x_1, x_2, \dots, x_n, \dots$

- (i)  $f(x_j) > 0$  para  $j = 1, 2, \dots$
- (ii)  $f(x) = x \neq x_j; j = 1, 2, \dots$
- (iii)  $\sum f(x_j) = 1$ , donde la suma es sobre los puntos  $x_1, x_2, \dots, x_n, \dots$

**Definición 6. Variables aleatorias continuas.** Una variable aleatoria  $X$  se llama "continua" si existe una función  $f_X(\cdot)$  tal que  $F(x) = \int_{-\infty}^x f(u) du$  para todo número real  $x$ .

**Definición 7. Función de densidad de probabilidad de una variable aleatoria continua.** Si  $X$  es una variable aleatoria continua, la función  $f_X(\cdot)$  en  $F(x) = \int_{-\infty}^x f(u) du$  se conoce como la "función de densidad de probabilidad" de  $X$ .

TESIS CON  
 FALLA DE ORIGEN

**Teorema 3.** Sea  $X$  una variable aleatoria continua. Entonces  $f_X(\cdot)$  se puede obtener a partir de  $F_X(\cdot)$  y viceversa.

Demostración:

Si  $X$  es variable aleatoria continua y  $f_X(\cdot)$  está dada, entonces  $F_X(\cdot)$  se obtiene por integración, esto es  $F_X(x) = \int_{-\infty}^x f(u) du$ . Por otra parte, si  $F_X(\cdot)$  está dada, entonces  $f_X(\cdot)$  se obtiene por medio de diferenciación:  $f(x) = \frac{dF_X(x)}{dx}$  en los puntos en los que  $F_X(\cdot)$  es diferenciable.

□

Como una convención, en lo subsecuente nos referiremos a la función de densidad de una variable aleatoria sin importarnos si es variable aleatoria discreta ó continua.

Ejemplo 4:

Sea  $X$  la variable aleatoria que denota el tiempo que una persona tarda en contestar una encuesta. Podemos modelar el experimento anterior asumiendo que la distribución de éste es:  $F_X(x) = (1 - e^{-\lambda x}) I_{[0, \infty)}(x)$ , donde  $\lambda$  es un número positivo. Por el teorema anterior se puede ver claramente que la función de densidad del fenómeno está dada por  $f(x) = \lambda e^{-\lambda x} I_{[0, \infty)}(x)$ . Si asumimos que el tiempo que tarda una persona en contestar la encuesta se mide en minutos,  $P[5 < x \leq 10] = \int_5^{10} \lambda e^{-\lambda x} dx = e^{-5\lambda} - e^{-10\lambda} \approx .23$  para  $\lambda = \frac{1}{5}$ .

**Definición 8. Función de densidad de probabilidad.** Una función  $f(\cdot)$  con dominio en la recta real y contradominio en el intervalo  $[0, \infty)$  se dice que es función de densidad de probabilidad si y sólo si:

(i)  $f(x) \geq 0$  para todo  $x$

(ii)  $\int_{-\infty}^{\infty} f(x) dx = 1$

Ahora tomaremos en cuenta sólo algunos de los resultados de las funciones de probabilidad multivariadas, ya que serán de gran utilidad un poco más adelante en el desarrollo del trabajo. Sólo trabajaremos en el caso bivariado, aunque éstos conceptos se pueden generalizar a más de dos variables aleatorias.

**Definición 9. Función de distribución conjunta.** Sean  $X_1, X_2$  variables aleatorias definidas en el espacio de probabilidad  $(\Omega, \mathcal{A}, P)$ . La "función de distribución conjunta"

TESIS CON  
FALLA DE ORIGEN

de  $X_1, X_2$  denotada por  $F'_{X_1, X_2}(\cdot, \cdot)$ , se define como  $P[X_1 < x_1, X_2 < x_2]$  para todo  $x_1, x_2$ . Y cumple con las siguientes propiedades:

$$(i) \quad F'(-\infty, y) = \lim_{x \rightarrow -\infty} F'(x, y) = 0 \text{ para todo } y, \quad F'(-\infty, x) = \lim_{y \rightarrow -\infty} F'(x, y) = 0, \text{ para todo } x, \\ F'(-\infty, \infty) = \lim_{x \rightarrow -\infty} F'(x, y) = 1.$$

(ii) si

$$x_1 < x_2, y_1 < y_2 \Rightarrow P[x_1 < X < x_2, y_1 < Y \leq y_2] = F'(x_2, y_2) - F'(x_2, y_1) - F'(x_1, y_2) + F'(x_1, y_1) \geq 0$$

$$(iii) \quad F'(x, y) \text{ es continua por la derecha, esto es } \lim_{h \rightarrow 0^+} F'(x+h, y) = \lim_{h \rightarrow 0^+} F'(x, y+h) = F'(x, y).$$

**Definición 10. Función de densidad conjunta.** Si  $X = (X_1, X_2)$ , es un vector aleatorio, entonces la "función de densidad conjunta" de  $X$ , denotada como  $f_{X_1, X_2}(\cdot, \cdot)$  se define como:

$$f_{X_1, X_2}(x_1, x_2) = P[X_1 = x_1, X_2 = x_2]$$

para  $(x_1, x_2)$  un valor de  $(X_1, X_2)$  y cero en otro caso, y además:

$$\sum f_{X_1, X_2}(x_1, x_2) = 1$$

donde la suma toma los valores posibles de  $(X_1, X_2)$ , si  $X$  es vector aleatorio discreto y

Si existe una función  $f_{X_1, X_2}(\cdot, \cdot)$ , tal que  $f_{X_1, X_2}(\cdot, \cdot) \geq 0$  y

$$F'_{X_1, X_2}(x_1, x_2) = \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} f_{X_1, X_2}(u_1, u_2) du_1 du_2$$

para todo  $(x_1, x_2)$ ,  $f_{X_1, X_2}(\cdot, \cdot)$  se define como función de densidad conjunta de una variable aleatoria continua.

**Teorema 4.** Sean  $X$  y  $Y$  son variables aleatorias conjuntas, entonces si conocemos  $F'_{X, Y}(\cdot, \cdot)$  podemos conocer  $f_{X_1, X_2}(\cdot, \cdot)$  y viceversa.

**Demostración:**

Similar a la hecha para una sola variable.

TESIS CON  
FALLA DE ORIGEN

**Definición 11. Función marginal de densidad.** Sean  $X$  y  $Y$  variables aleatorias conjuntas, entonces  $f_X(\cdot), f_Y(\cdot)$  se llaman "funciones marginales de densidad, y se obtienen como sigue:

$$f_X(x_i) = \sum_j f_{X,Y}(x_i, y_j) \quad \text{y} \quad f_Y(y_i) = \sum_j f_{X,Y}(x_j, y_i)$$

para  $X$  y  $Y$  variables aleatorias discretas, y cuando son continuas, las distribuciones marginales se obtienen como:

$$f_X(x) = \int_{-\infty}^{\infty} f_{X,Y}(x, y) dy \quad \text{y} \quad f_Y(y) = \int_{-\infty}^{\infty} f_{X,Y}(x, y) dx.$$

**Definición 12. Independencia.** Sea  $X$  un vector aleatorio bi-dimensional con función de densidad conjunta  $f_{X_1, X_2}(\cdot, \cdot)$ .  $X_1$  y  $X_2$  son independientes si y sólo si:

$$f_{X_1, X_2}(x_1, x_2) = \prod_{i=1}^2 f_{X_i}(x_i).$$

### 1.3 Esperanza Matemática

**Definición 13. Esperanza.** Sea  $X$  una variable aleatoria, la "esperanza" de  $X$ , denotada como  $E[X]$  ó  $\mu_x$ , se define como:

$$E[X] = \sum x_j f(x_j)$$

si  $X$  es discreta con los puntos masa  $x_1, x_2, \dots, x_n, \dots$  ó

$$E(X) = \int_{-\infty}^{\infty} xf(x) dx$$

si  $X$  es continua.

Ejemplo 5:

Consideremos el experimento de lanzar dos dados. Sea  $X$  la variable aleatoria que denota la suma de los dos, entonces el valor esperado de  $x$  es:

$$E(X) = \sum_{i=2}^{12} if(i) = 7$$

TESIS CON  
FALLA DE ORIGEN

Ejemplo 6:

Sea  $X$  una variable aleatoria continua con función de densidad de probabilidad  $f(x) = \lambda e^{-\lambda x} I_{(0, \infty)}(x)$ , entonces el valor esperado de  $X$  es:

$$E(x) = \int_{-\infty}^{\infty} x f(x) dx = \int_0^{\infty} x \lambda e^{-\lambda x} dx = \frac{1}{\lambda}$$

**Definición 14. Varianza.** Sea  $X$  una variable aleatoria con  $f(x)$  conocida. La "varianza" de  $X$ , denotada por  $\sigma_x^2$  ó  $\text{var}[x]$ , se define como sigue:

$$\text{var}[x] = \sum_i (x_i - \mu_x)^2 f(x_i)$$

si  $X$  es variable aleatoria discreta, y

$$\text{var}[x] = \int_{-\infty}^{\infty} (x - \mu_x)^2 f(x) dx$$

si  $X$  es variable aleatoria continua.

**Definición 15. Desviación estándar.** Si  $X$  es variable aleatoria, la "desviación estándar" de  $X$ , denotada por  $\sigma_x$ , se define como  $+\sqrt{\text{var}[x]}$ .

Ejemplo 7:

Sea  $X$  el mismo experimento del ejemplo 5 y calculemos la varianza de  $X$ .

$$\begin{aligned} \text{var}[X] &= \sum_i (x_i - \mu_x)^2 f(x_i) = (2-7)^2 \frac{1}{36} + (3-7)^2 \frac{2}{36} + (4-7)^2 \frac{3}{36} + (5-7)^2 \frac{4}{36} + (6-7)^2 \frac{5}{36} \\ &+ (7-7)^2 \frac{6}{36} + (8-7)^2 \frac{5}{36} + (9-7)^2 \frac{4}{36} + (10-7)^2 \frac{3}{36} + (11-7)^2 \frac{2}{36} + (12-7)^2 \frac{1}{36} = \frac{210}{36} \end{aligned}$$

y la desviación estándar es:

$$\sigma_x = \sqrt{\frac{210}{36}} = 2.4152$$

TESIS CON  
FALLA DE ORIGEN

Ejemplo 8:

Sea  $X$  la variable aleatoria con función de densidad de probabilidad  $f(x) = \lambda e^{-\lambda x} I_{(0, \infty)}(x)$ ; entonces la varianza de  $X$  es:

$$\text{var}[X] = \int_{-\infty}^{\infty} (x - \mu_x)^2 f(x) dx = \int_0^{\infty} \left(x - \frac{1}{\lambda}\right)^2 \lambda e^{-\lambda x} dx = \frac{1}{\lambda^2}$$

y su desviación estándar es:

$$\sigma_x = \sqrt{\frac{1}{\lambda^2}} = \frac{1}{\lambda}$$

**Definición 16. Esperanza de una función de una variable aleatoria.** Sea  $X$  una variable aleatoria y  $g(\cdot)$  una función con dominio en la recta real. La esperanza de la función  $g(\cdot)$  de la variable aleatoria  $X$ , denotada como  $E[g(X)]$  se define como:

$$E[g(X)] = \sum_i g(x_i) f(x_i)$$

si  $X$  es variable aleatoria discreta, y

$$E[g(X)] = \int_{-\infty}^{\infty} g(x) f(x) dx$$

si  $X$  es variable aleatoria continua.

**Teorema 5. Propiedades del valor esperado.**

- (i)  $E[c] = c$ , para un valor constante  $c$
- (ii)  $E[cg(X)] = cE[g(X)]$ , para una constante  $c$
- (iii)  $E[c_1g_1(X) + c_2g_2(X)] = c_1E[g_1(X)] + c_2E[g_2(X)]$  para las constantes  $c_1, c_2 \in \mathbb{R}$
- (iv)  $E[g_1(X)] \leq E[g_2(X)]$  si  $g_1(X) \leq g_2(X)$  para todo  $x$

Demostración:

Supongamos que  $X$  es continua.

(i) sea  $g(x) = c$ , entonces

$$E[g(X)] = E[c] = \int_{-\infty}^{\infty} cf(x) dx = c \int_{-\infty}^{\infty} f(x) dx = c.$$

TESIS CON  
FALLA DE ORIGEN

$$(ii) E[cg(X)] = \int c g(x) f(x) dx = c \int g(x) f(x) dx = c E[g(X)].$$

(iii)

$$E[c_1 g_1(X) + c_2 g_2(X)] = \int c_1 g_1(x) f(x) dx + c_2 \int g_2(x) f(x) dx = \int c_1 g_1(x) f(x) dx + \int c_2 g_2(x) f(x) dx = c_1 E[g_1(X)] + c_2 E[g_2(X)]$$

$$(iv) 0 \leq E[g_2(X) - g_1(X)] = E[g_2(X)] - E[g_1(X)]$$

□

#### 1.4 Función Generadora de Momentos

Los "momentos" de una variable aleatoria ó de una distribución son las esperanzas de las potencias de la variable aleatoria de la cual tenemos su distribución.

**Definición 17. Momentos.** Si  $X$  es variable aleatoria, el  $r$ -ésimo momento de  $X$ , denotado como  $\mu^r$ , se define como:

$$\mu^r = E[X^r]$$

si la esperanza existe.

**Definición 18. Momentos centrales.** Si  $X$  es variable aleatoria, el  $r$ -ésimo momento central de  $X$  con respecto a  $a$  se define como  $E[(X - a)^r]$ . Si  $a = \mu_X$ , tenemos el  $r$ -ésimo momento central de  $X$  con respecto de su media, denotado por  $\mu_r$ ,

$$\mu_r = E[(X - \mu_X)^r]$$

**Definición 19. Función generadora de momentos.** Sea  $X$  una variable aleatoria con función de densidad  $f(\cdot)$ . El valor esperado de  $e^{tx}$  se define como la "función generadora de momentos" de  $X$ , si es que el valor esperado de ésta existe para cada  $t$  en el intervalo  $-h < t < h; h > 0$ . Se denota por  $m_X(t)$  ó  $m(t)$ . Entonces:

$$m(t) = E[e^{tx}] = \sum_x e^{tx} f(x), \text{ si } X \text{ es discreta, y}$$

$$m(t) = E[e^{tx}] = \int e^{tx} f(x) dx, \text{ si } X \text{ es continua.}$$

TESIS CON  
FALLA DE ORIGEN

Si la función generadora de momentos existe y si  $m(t)$  es continuamente diferenciable en una vecindad del origen, entonces podemos diferenciar a la función  $r$ -veces con respecto de  $t$  y tenemos:

$$\frac{d^r}{dt^r} m(t) = \int_{-\infty}^{\infty} x^r e^{tx} f(x) dx,$$

y si  $t \rightarrow 0$ , entonces

$$\frac{d^r}{dt^r} m(0) = E[X^r]$$

Ejemplo 9:

Encontrar la función generadora de momentos para la distribución Normal  $(\mu, \sigma^2)$ . Sea  $X$  una variable aleatoria con función de densidad:

$$f(x) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left[-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right], \sigma > 0.$$

Consideremos la función generadora de momentos siguiente:

$$\begin{aligned} m_{X, \mu}(t) &= E[e^{t(X-\mu)}] = \frac{1}{\sqrt{2\pi\sigma}} \int_{-\infty}^{\infty} \exp\{t(x-\mu)\} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] dx \\ &= \frac{1}{\sqrt{2\pi\sigma}} \int_{-\infty}^{\infty} \exp\left\{-\frac{1}{2\sigma^2}[(x-\mu)^2 - 2\sigma^2 t(x-\mu)]\right\} dx \end{aligned}$$

Si completamos el cuadrado en el interior del paréntesis rectangular, se tiene:

$$(x-\mu)^2 - 2\sigma^2 t(x-\mu) = (x-\mu)^2 - 2\sigma^2 t(x-\mu) + \sigma^4 t^2 - \sigma^4 t^2 = (x-\mu - \sigma^2 t)^2 - \sigma^4 t^2$$

Entonces:

$$\begin{aligned} m_{X, \mu}(t) &= \frac{1}{\sqrt{2\pi\sigma}} \int_{-\infty}^{\infty} \exp\left(\frac{\sigma^2 t^2}{2}\right) \exp\left\{-\frac{[x - (\mu + \sigma^2 t)]^2}{2\sigma^2}\right\} dx \\ &= \exp\left(\frac{\sigma^2 t^2}{2}\right) \frac{1}{\sqrt{2\pi\sigma}} \int_{-\infty}^{\infty} \exp\left\{-\frac{[x - (\mu + \sigma^2 t)]^2}{2\sigma^2}\right\} dx = \exp\left(\frac{\sigma^2 t^2}{2}\right) \end{aligned}$$

como:

TESIS CON  
FALLA DE ORIGEN

$$m_{X, \mu}(t) = t \cdot [e^{tX - \mu}] = \exp(-\mu)t \cdot [\exp(tX)] = \exp(-\mu)m_X(t)$$

tenemos que:

$$\exp(-\mu)m_X(t) = \exp(\sigma^2 t^2 / 2)$$

lo que significa que:

$$m_X(t) = \exp\left(\mu t + \frac{\sigma^2 t^2}{2}\right)$$

### 1.5 Ejemplos de Teoría de la Distribución.

Para los requerimientos de este trabajo, basta con sólo ver una de las técnicas para encontrar la distribución de una función de variables aleatorias. La técnica que se verá en esta sección es la de la función generadora de momentos, la cual recibe ese nombre porque está basada en dicha función y será de gran utilidad en el capítulo tres.

Ejemplo 10:

Supongamos que X tiene distribución Normal con media 0 y varianza 1 (estándar). Sea  $Y = X^2$ , y queremos encontrar la distribución de Y.

$$\begin{aligned} m_Y(t) &= t \cdot [e^{tY}] = \int_{-\infty}^{\infty} e^{tx^2} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx \\ &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{1}{2}x^2(1-2t)} dx \\ &= \frac{1}{\sqrt{2\pi}} \frac{(1-2t)^{1/2}}{(1-2t)^{1/2}} \int_{-\infty}^{\infty} e^{-\frac{1}{2}x^2(1-2t)} dx \\ &= (1-2t)^{1/2} \left( \frac{1}{1-2t} \right)^{1/2} \quad \text{para } t < 1/2 \end{aligned}$$

Podemos ver que este resultado corresponde a una función de distribución Gamma con parámetros  $r = \frac{1}{2}$  y  $\lambda = \frac{1}{2}$  ó lo que es lo mismo, una ji-cuadrada con un grado de libertad.

TESIS CON  
FALLA DE ORIGEN

**Teorema 6.** Distribución de sumas de variables aleatorias independientes.

Sean  $X_1, X_2$  variables aleatorias independientes y la función generadora de momentos asociada a cada variable aleatoria. Sea  $Y = \sum_{i=1}^2 X_i$ , entonces:

$$m_Y(t) = E\left[\exp\left(\sum_{i=1}^2 X_i t\right)\right] = \prod_{i=1}^2 m_{X_i}(t)$$

Demostración:

$$\begin{aligned} m_Y(t) &= E\left[\exp\left(\sum_{i=1}^2 X_i t\right)\right] = E\left[\prod_{i=1}^2 \exp(X_i t)\right] = \\ &= \prod_{i=1}^2 E[\exp(X_i t)] = \prod_{i=1}^2 m_{X_i}(t) \end{aligned}$$

□

Ejemplo 11:

Sean  $X_1, X_2$  variables aleatorias independientes y:

$$X_i \sim N(\mu_i, \sigma_i^2);$$

entonces

$$a_i X_i \sim N(a_i \mu_i, a_i^2 \sigma_i^2)$$

y

$$m_{a_i X_i}(t) = \exp\left(a_i \mu_i t + \frac{1}{2} a_i^2 \sigma_i^2 t^2\right)$$

además

$$m_{\sum_{i=1}^2 a_i X_i}(t) = \prod_{i=1}^2 m_{a_i X_i}(t) = \exp\left[\left(\sum_{i=1}^2 a_i \mu_i\right) t + \frac{1}{2} \left(\sum_{i=1}^2 a_i^2 \sigma_i^2\right) t^2\right]$$

por lo que podemos ver que ésta es la función generadora de momentos de una variable aleatoria normal

$$\sum_{i=1}^2 a_i X_i \sim N\left(\sum_{i=1}^2 a_i \mu_i, \sum_{i=1}^2 a_i^2 \sigma_i^2\right).$$

TESIS CON  
FALLA DE ORIGEN

## 2. Programación Lineal y no-Lineal

### 2.1 Definiciones

**Definición 2.1 PPL.** Un problema de programación lineal (PPL) es una estructura de la siguiente forma: (s.a. es sujeto a, Min y Max significan minimizar y maximizar respectivamente)

$$\left\{ \begin{array}{l} \text{Min} \quad c_1x_1 + \dots + c_nx_n \text{ (la función objetivo)} \\ \text{s.a.} \quad a_{11}x_1 + \dots + a_{1n}x_n + a_{1n+1}x_{n+1} = b_1 \\ \quad \quad a_{m1}x_1 + \dots + a_{mn}x_n + a_{mn+1}x_{n+1} = b_m \\ \quad \quad x_1, \dots, x_n, x_{n+1}, \dots, x_{n+m} \geq 0 \end{array} \right.$$

Este problema es equivalente a maximizar:

$$-c_1x_1 - \dots - c_nx_n$$

Sujeto a las mismas restricciones.

Desde un punto de vista práctico, podemos distinguir los siguientes casos:

$$(1) a_{1n+1} = \dots = a_{mn+1} = 1.$$

Este caso se obtiene cuando las restricciones son formuladas como :

$$\sum_{j=1}^n a_{ij}x_j \leq b_i$$

( $i = 1, \dots, m$ ), y las "variables de holgura"  $x_{n+1}, \dots, x_{n+m}$  son introducidas para transformar las restricciones de desigualdad en restricciones de igualdad.

$$(2) a_{1n+1} = \dots = a_{mn+1} = -1.$$

Cuando las restricciones son de la forma  $\sum_{j=1}^n a_{ij}x_j \geq b_i$  ( $i = 1, \dots, m$ ), entonces se introducen las mismas variables de holgura del caso 1.

$$(3) a_{1n+1} = \dots = a_{mn+1} = 0.$$

Las restricciones aparecen en forma de igualdad en las variables  $x_1, \dots, x_n$ .

Cuando no todas las restricciones son de la misma categoría, entonces se realiza una combinación de los tres casos.

TESIS CON  
FALLA DE ORIGEN

**Definición 2.2.** Consideremos el caso 1, donde, además,  $b_i \geq 0$  ( $i = 1, \dots, m$ ), la forma estándar.

Podemos escribir éste problema en forma de "tabla restringida" como sigue:

	$x_1$	$\dots$	$x_{j_0}$	$\dots$	$x_n$	
$x_{n+1}$	$a_{11}$	$\dots$	$a_{1j_0}$	$\dots$	$a_{1n}$	$b_1$
$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$
$x_{n+i_0}$	$a_{i_0 1}$	$\dots$	$a_{i_0 j_0}$	$\dots$	$a_{i_0 n}$	$b_{i_0}$
$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$
$x_{n+m}$	$a_{m1}$	$\dots$	$a_{mj_0}$	$\dots$	$a_{mn}$	$b_m$
	$-c_1$	$\dots$	$-c_{j_0}$	$\dots$	$-c_n$	0

En ésta tabla las variables que están etiquetadas en la parte superior, se denominan "variables no-básicas" y las que se localizan en la parte izquierda se denominan "variables básicas". La última columna contiene los valores de las variables básicas, i. e.  $x_{n+i} = b_i$  ( $i = 1, \dots, m$ ). Los valores de las variables no-básicas son cero.

En cada tabla las variables básicas son siempre tales que, poniendo las otras igual a cero, el sistema de restricciones puede ser resuelto para éste. Decimos que el conjunto de variables básicas forma una "base" ( ésta base no es en el mismo sentido que la que se usa en álgebra lineal). Existen muchas variables básicas en las restricciones, y el conjunto de los valores de todas las variables se llama "solución básica".

Ejemplo 2.1:

Como un ejemplo en el cual no hay variables no-negativas en las restricciones, pero éstas variables no forman una base, es el siguiente con  $x_1 = 1$ ,  $x_2 = 1$ , donde se satisfacen las restricciones

$$x_1 + x_2 + x_3 = 2, \quad 2x_1 + 2x_2 + x_4 = 4$$

Como sea, si ponemos  $x_3$  y  $x_4$  igual a cero, obtenemos un sistema con una matriz singular de coeficientes

$$\begin{bmatrix} 2 & 2 \\ 1 & 1 \end{bmatrix}$$

Si  $c_1 \geq 0, \dots, c_n \geq 0$ , entonces la tabla anterior es óptima. El valor más pequeño posible de  $c_1 x_1 + \dots + c_n x_n$  es cero, lo que significaría que  $x_1 = \dots = x_n = 0$ .

Si eso no sucede entonces procedemos a realizar la transformación de la tabla por medio de una secuencia de operaciones, hasta que todos los elementos de la última fila sean no-

TESIS CON  
FALLA DE ORIGEN

positivos y los de la última columna sean no-negativos, aparte del valor de la esquina superior derecha que puede ser positivo, negativo ó cero. El último valor es eventualmente, el mejor valor de la función objetivo que puede ser obtenido, tomando todas las restricciones en cuenta.

## 2.2 Algoritmo SIMPLEX

El algoritmo conocido como el Simplex funciona de la siguiente forma:

Sea  $-c_j$  positivo. Considerar para todos los  $a_{ij}$  positivos los cocientes  $b_i / a_{ij}$ , y tomar el más pequeño. Si esto pasa para  $i_0$ , entonces a  $a_{i_0 j_0}$  lo llamaremos "pivote" (marcado por un asterisco), y colocar la tabla original en la forma siguiente:

$$\begin{array}{ccccccc}
 & x_1 & \dots & x_{j_0} & \dots & x_n & \\
 x_{n+1} & & & -a_{1j_0}/p & & & \\
 \dots & & & & & & \\
 x_{n+i_0} & & & 1/p & & & a_{i_0 n}/p \\
 \dots & & & & & & \\
 x_{n+m} & & & -a_{mj_0}/p & & & \\
 & & & c_{j_0}/p & & & 
 \end{array}$$

donde  $p = a_{i_0 j_0}$

los lugares que quedaron en blanco se llenan de la manera siguiente:  $a_{ij}$  es reemplazado por  $a'_{ij} - a_{i_0 i} a_{j_0 n} / p$ , y similarmente  $c_j$  por  $c_j - c_{j_0} c_{i_0 n} / p$

Veamos el ejemplo siguiente.

Ejemplo 2.2:

$$\left\{ \begin{array}{l}
 \text{Min} \quad 2x_1 + 7x_2 - 2x_3 \\
 \text{s.a.} \quad x_1 + 2x_2 + x_3 \leq 1 \\
 \quad \quad -4x_1 - 2x_2 + 3x_3 \leq 2 \\
 \quad \quad x_1, x_2, x_3 \geq 0.
 \end{array} \right.$$

TESIS CON  
 FALLA DE ORIGEN

La primera tabla es

	$x_1$	$x_2$	$x_3$	
$x_4$	1	2	1	1
$x_5$	-4	-2	3*	2
	-2	-7	2	0

La tabla siguiente queda de la forma siguiente:

	$x_1$	$x_2$	$x_5$	
$x_4$	$7/3$ *	$8/3$	$-1/3$	$1/3$
$x_3$	$-4/3$	$-2/3$	$1/3$	$2/3$
	$2/3$	$-17/3$	$-2/3$	$-4/3$

Como todavía hay valores positivos en el último renglón, repetimos el procedimiento anterior y obtenemos:

	$x_4$	$x_2$	$x_5$	
$x_1$	$3/7$	$8/7$	$-1/7$	$1/7$
$x_3$	$4/7$	$6/7$	$1/7$	$6/7$
	$-2/7$	$-45/7$	$-4/7$	$-10/7$

Lo que la tabla nos dice, es que el valor más pequeño que puede tomar la función objetivo es  $-10/7$ , y los valores de las variables es  $x_1 = 1/7$ ,  $x_3 = 6/7$  y  $x_2 = x_4 = x_5 = 0$ .

Si deseamos maximizar la función objetivo, debemos usar el mismo procedimiento, excepto que ahora debemos obtener valores no-negativos en el último renglón. Esto es:

$$\left\{ \begin{array}{l} \text{Max } 2x_1 + 7x_2 - 2x_3 \\ \text{s.a. } x_1 + 2x_2 + x_3 \leq 1 \\ \quad \quad \quad -4x_1 - 2x_2 + 3x_3 \leq 2 \\ \quad \quad \quad x_1, x_2, x_3 \geq 0. \end{array} \right.$$

Procedemos como sigue ( $x_4$  y  $x_5$  ahora son variables de holgura):

TESIS CON  
 FALLA DE ORIGEN

	$x_1$	$x_2$	$x_3$	
$x_4$	1	2*	1	1
$x_5$	-4	-2	3	2
	-2	-7	2	0

Y al final obtenemos la tabla

	$x_1$	$x_4$	$x_3$	
$x_2$	$\frac{1}{2}$	$\frac{1}{2}$	$\frac{1}{2}$	$\frac{1}{2}$
$x_5$	-3	1	4	3
	$\frac{3}{2}$	$\frac{7}{2}$	$11\frac{1}{2}$	$7\frac{1}{2}$

El valor más grande posible que puede tomar la función objetivo es  $7\frac{1}{2}$ , que se obtiene cuando  $x_1 = x_3 = 0$  y  $x_2 = \frac{1}{2}$ .

Una característica de todas las tablas es usada en muchas circunstancias con los valores de cada variable. Si colocamos dichos números arriba de cada variable (con el valor que tienen en la función objetivo), la tabla queda como sigue:

	(2)	(0)	(-2)	
	$x_1$	$x_4$	$x_3$	
(7) $x_2$	$\frac{1}{2}$	$\frac{1}{2}$	$\frac{1}{2}$	$\frac{1}{2}$
(0) $x_5$	-3	1	4	3
	$\frac{3}{2}$	$\frac{7}{2}$	$11\frac{1}{2}$	$7\frac{1}{2}$

Multiplicando cada valor de la columna de la izquierda con los valores correspondientes del renglón en la columna de la tabla sumando y restando el valor correspondiente de la columna en la parte superior:

$$7(1/2) + 0(-3) - 2 = 3/2, \quad 7(1/2) + 0(1) - 0 = 7/2$$

$$7(1/2) + 0(4) - (-2) = 11/2, \quad 7(1/2) + 0(3) = 7/2$$

Esta relación funciona para todas las tablas. Podemos decir que verificamos la regla. Algunas veces es conveniente verificar los cálculos rápidamente, para ver si es que se cometió algún error aritmético y de ser así corregirlo.

TESIS CON  
FALLA DE ORIGEN

Regresemos al caso (2). En este caso podemos asumir que cada  $c_j$  ( $j = 1, \dots, n$ ) son no-negativas, esto es que los valores de la primera tabla, en la parte superior son ahora no-positivos, y como queremos llegar a la tabla final para resolverlo (si queremos minimizar), podemos llamarla como una tabla "dual-factible". Si todos los  $b_i$  son no-negativos, entonces habremos terminado. En otro caso, aplicaremos el "Método Dual Simplex".

### 2.3 Algoritmo DUAL-SIMPLEX

El algoritmo funciona de la forma siguiente.

Sea  $b_{i_0}$  uno de los valores negativos. Consideramos, para todo  $a_{rj} < 0$ ,  $|c_j / a_{rj}|$ , y tomar el más pequeño. Si esto sucede para  $j_0$ , entonces  $a_{rj_0}$  será el pivote, y podemos transformar la tabla, usando las mismas reglas del caso.

Ejemplo 2.3:

$$\left\{ \begin{array}{l} \text{Max.} \quad x_1 + 2x_2 \\ \text{s.a.} \quad x_1 - 2x_2 \geq 1 \\ \quad \quad 2x_1 - 2x_2 \geq 7 \\ \quad \quad x_1 + 3x_2 \geq -2 \\ \quad \quad x_1, x_2 \geq 0. \end{array} \right.$$

Introducimos variables de holgura, pero ahora con signo negativo, y multiplicamos cada ecuación por  $-1$  por ambos lados. La tabla es la siguiente:

	$x_1$	$x_2$	
$x_3$	-1	2	-2
$x_4$	-2	2	-7
$x_5$	-1	-3	2
	-1	-2	0

Y la tabla óptima es :



	$x_4$	$x_2$	
$x_3$	-1/2	3	3/2
$x_1$	1	-1	7/2
$x_5$	-1/2	-4	11/2
	-1/2	-3	7/2

Podemos obtener el caso 1 del caso 2, y el caso 2 del caso 1, multiplicando ambos lados por -1. Podemos usar este procedimiento para convertir el programa en la forma estándar

Si el programa no está en la forma estándar y no se puede transformar a ésta, tendremos que proceder como sigue:

Primero, multiplicamos ambos lados por -1, en donde  $b_i$  sea negativo. Lo que hace que los coeficientes de  $x_{n+i}$  ( $i = 1, \dots, m$ ) sean 1, 0 ó -1.

En los otros dos casos adicionamos variables "artificiales"  $a_i$  en el lado izquierdo del programa y adicionamos  $Ma_i$  a la función objetivo para minimizar (ó restar  $Ma_i$  a la función objetivo para maximizar);  $M$  es considerado como un valor grande comparado con los cálculos que se hacen en el programa. El siguiente ejemplo muestra el procedimiento:

Ejemplo 2.4:

$$\left\{ \begin{array}{l} \text{Min} \quad x_1 - 2x_2 \\ \text{s.a.} \quad x_1 + 2x_2 + x_3 = 1 \\ \quad \quad 3x_1 - x_2 - x_4 = 2 \\ \quad \quad \quad \quad x_1 - 3x_2 = 2 \\ \quad \quad \quad \quad \quad \quad x_1, x_2, x_3, x_4 \geq 0. \end{array} \right.$$

La tabla queda como:

	$x_1$	$x_2$	$x_4$	
$x_3$	1	2	0	4
$a_1$	3 *	-1	-1	1
$a_2$	1	3	0	4
	-1	1	0	0
(M)	4	2	-1	5



El último renglón viene de usar las variables artificiales, y en la entrada del renglón se multiplica por  $M$ . La suma de los últimos renglones, es el renglón que tiene la función objetivo  $x_1 - x_2 + M(a_1 + a_2)$ . Las tablas sucesivas son como sigue:

	$a_1$	$x_2$	$x_4$	
$x_3$		$7/3$	$1/3$	$11/3$
$x_1$		$-1/3$	$-1/3$	$1/3$
$a_2$		$10/3$	$1/3$	$11/3$
(M)		$2/3$	$-1/3$	$1/3$
		$10/3$	$1/3$	$11/3$

La columna  $a_1$  no es de interés y se omite y la tabla final es la siguiente:

	$x_4$	
$x_3$	$1/10$	$11/10$
$x_1$	$-3/10$	$7/10$
$x_2$	$1/10$	$11/10$
	$-4/5$	$-2/5$

En éste caso no es posible igualar a cero las variables artificiales, esto es una indicación de que las restricciones originales eran contradictorias. Esto es posible, aunque, una variable artificial puede quedar al final de la base, con valor de cero.

## 2.4 Programación no-lineal (Método de los multiplicadores de Lagrange).

La formulación general de un problema con restricciones de desigualdad es:

$$(P) \left\{ \begin{array}{l} \text{Opt. } f(x_1, \dots, x_n) \\ \text{s.a.} \\ g_1(x_1, \dots, x_n) \leq 0 \\ \vdots \\ g_m(x_1, \dots, x_n) \leq 0 \\ h_1(x_1, \dots, x_n) \geq 0 \\ \vdots \\ h_k(x_1, \dots, x_n) \geq 0 \end{array} \right.$$

TESIS CON  
FALLA DE ORIGEN

donde las funciones  $f, g, i = 1, \dots, m$  y  $h_j, j = 1, \dots, k$ , están definidas de  $\mathcal{R}^n \rightarrow \mathcal{R}$ . El análisis del problema general (P) se puede reducir al estudio de

$$(P') \quad \left\{ \begin{array}{l} \text{Min } f(x_1, \dots, x_n) \\ \text{s.a.} \\ h_1(x_1, \dots, x_n) \leq 0 \\ \vdots \\ h_{m+k}(x_1, \dots, x_n) \leq 0 \end{array} \right.$$

con  $f: \mathcal{M}^n \rightarrow \mathcal{M}$  y  $h_j: \mathcal{M}^n \rightarrow \mathcal{M}, j = 1, \dots, m+k$ , ya que el problema de  $\max f(x_1, \dots, x_n)$  es equivalente a  $\min[-f(x_1, \dots, x_n)]$  y las restricciones  $h_j(x_1, \dots, x_n) \geq 0, j = 1, \dots, k$  se pueden expresar como  $[-h_j(x_1, \dots, x_n)] \leq 0$ .

**Definición 2.3.** Dada una solución factible  $\bar{x}^*$  del problema (P), se dice que  $\bar{x}^*$  satura la restricción  $i$ -ésima  $g_i(\bar{x}) \leq 0$  si  $g_i(\bar{x}) = 0$ . Análogamente se dirá que  $\bar{x}^*$  no satura la restricción  $i$ -ésima si  $g_i(\bar{x}) < 0$ .

### Teorema 2.1 Condiciones de Kuhn-Tucker.

Sea el programa

$$(1) \quad \left\{ \begin{array}{l} \text{Min } f(x_1, \dots, x_n) \\ \text{s.a.} \\ g_1(x_1, \dots, x_n) \leq 0 \\ \vdots \\ g_m(x_1, \dots, x_n) \leq 0 \end{array} \right.$$

TESIS CON  
FALLA DE ORIGEN

y sea  $\bar{x}^*$  un punto factible tal que  $I = \{i / g_i(\bar{x}^*) = 0\}$ , es decir, satura las restricciones  $g_i(x) \leq 0$  para  $i \in I$ . Supongamos además que en  $\bar{x}^*$  las funciones  $f$  y  $g_i$ , con  $i \in I$  son diferenciables y  $g_j$ , con  $i \notin I$  son continuas y que  $\nabla g_i(\bar{x}^*)$  para  $i \in I$  son linealmente independientes. Entonces, si  $\bar{x}^*$  es un óptimo local del problema (1) y existen  $\lambda_j$  escalares tales que

$$\begin{aligned} \nabla f(\bar{x}^*) + \sum_{i \in I} \lambda_i \nabla g_i(\bar{x}^*) &= \bar{0} \\ \lambda_i &\geq 0, i \in I \\ g_j(\bar{x}^*) &\leq 0, j = 1, \dots, m \end{aligned}$$

Si además suponemos que  $g_j$  para  $i \notin I$  son diferenciables en  $\bar{x}^*$ , las condiciones de Kuhn-Tucker se pueden escribir de forma equivalente como sigue

$$\nabla f(\bar{x}^*) + \sum_{i=1}^m \lambda_i \nabla g_i(\bar{x}^*) = \bar{0}$$

$$\lambda_j g_j(\bar{x}^*) = 0, j = 1, \dots, m$$

$$\lambda_j \geq 0, j = 1, \dots, m$$

$$g_j(\bar{x}^*) \leq 0, j = 1, \dots, m$$

Si el programa se plantea en los términos

$$\begin{cases} \text{Max } f(x_1, \dots, x_n) \\ \text{s.a.} \\ g_1(x_1, \dots, x_n) \leq 0 \\ \vdots \\ g_m(x_1, \dots, x_n) \leq 0 \end{cases}$$

Las condiciones de Kuhn -Tucker se verificarán si existen escalares  $\lambda_j \leq 0$  con  $j = 1, \dots, m$  tales que

$$\nabla f(\bar{x}^*) + \sum_{i=1}^m \lambda_i \nabla g_i(\bar{x}^*) = \bar{0}$$

$$\lambda_j g_j(\bar{x}^*) = 0, j = 1, \dots, m$$

$$\lambda_j \geq 0, j = 1, \dots, m$$

$$g_j(\bar{x}^*) \leq 0, j = 1, \dots, m$$

TESIS CON  
FALLA DE ORIGEN

Los programas de minimización y maximización se pueden formular con las restricciones en la forma  $g_j(\bar{x}) \geq 0, j = 1, \dots, m$ . Esta modificación en la formulación del programa afecta al signo de los escalares  $\lambda_j, j = 1, \dots, m$ . En concreto, para las cuatro posibles formulaciones, los cambios de signo de los escalares  $\bar{\lambda} = (\lambda_1, \dots, \lambda_m)$  se ilustran en el cuadro siguiente:

	min	Max
$\bar{g}(\bar{x}) \leq \bar{0}$	$\bar{\lambda} \geq \bar{0}$	$\bar{\lambda} \leq \bar{0}$
$\bar{g}(\bar{x}) \geq \bar{0}$	$\bar{\lambda} \leq \bar{0}$	$\bar{\lambda} \geq \bar{0}$

Donde  $\bar{g} = (g_1, \dots, g_m)$

A los escalares  $\lambda_j, j = 1, \dots, m$  se les denominan multiplicadores de Lagrange. Es de destacar que todos los multiplicadores asociados a restricciones no saturadas son nulos, mientras que los correspondientes a saturadas pueden ser nulos o no nulos.

### Teorema 2.2 Condiciones de segundo orden de un mínimo local

Sea el programa

$$(1) \quad \begin{cases} \text{Min } f(x_1, \dots, x_n) \\ \text{s.a.} \\ g_1(x_1, \dots, x_n) \leq 0 \\ \vdots \\ g_m(x_1, \dots, x_n) \leq 0 \end{cases}$$

donde  $f, g_1, \dots, g_m$  son funciones  $C^{1,2}$  (es decir, tienen segundas derivadas continuas) y sea  $\bar{x}^*$  una solución factible en la que se verifican las condiciones de Kuhn-Tucker, esto es, existen escalares  $\lambda_1^*, \dots, \lambda_m^* \in \mathcal{R}$ , tales que

$$\begin{aligned} \nabla f(\bar{x}^*) + \sum_{j=1}^m \lambda_j^* \nabla g_j(\bar{x}^*) &= \bar{0} \\ \lambda_j^* g_j(\bar{x}^*) &= 0, \quad j = 1, \dots, m \\ \lambda_j^* &\geq 0, \quad j = 1, \dots, m \\ g_j(\bar{x}^*) &\leq 0, \quad j = 1, \dots, m \end{aligned}$$

Sea la matriz

$$H, l(\bar{\lambda}^*, \bar{x}^*) = Hf(\bar{x}^*) + \sum_{j=1}^m \lambda_j^* Hg_j(\bar{x}^*)$$

Donde  $J = \{j \mid j = 1, \dots, m, g_j(\bar{x}^*) = 0, \lambda_j^* > 0\}$  y el conjunto  $M(\bar{x}^*)$  dado por

$$M(\bar{x}^*) = \{p \in \mathcal{R}^n \mid \nabla g_j(\bar{x}^*) p = 0, \text{ para todo } j \in J, p \neq \bar{0}\}$$

Si  $M(\bar{x}^*) \neq \emptyset$  y para todo  $p \in M(\bar{x}^*)$  se verifica  $p^T H, l(\bar{\lambda}^*, \bar{x}^*) p > 0$ , entonces,  $\bar{x}^*$  es un mínimo local estricto del programa.

### Teorema 2.3 Condiciones de segundo orden de un máximo local

Sea el programa

TESIS CON  
FALLA DE ORIGEN

$$(1') \quad \begin{cases} \text{Max } f(x_1, \dots, x_n) \\ \text{s.a.} \\ g_1(x_1, \dots, x_n) \leq 0 \\ \vdots \\ g_m(x_1, \dots, x_n) \leq 0 \end{cases}$$

donde  $f, g_1, \dots, g_m$  son funciones  $C^2$  y sea  $\bar{x}^*$  una solución factible en la que se verifican las condiciones de Kuhn-Tucker, esto es, existen escalares  $\lambda_1^*, \dots, \lambda_m^* \in \mathfrak{R}^+$ , tales que

$$\begin{aligned} \nabla f(\bar{x}^*) + \sum_{j=1}^m \lambda_j^* \nabla g_j(\bar{x}^*) &= \bar{0} \\ \lambda_j^* g_j(\bar{x}^*) &= 0, j = 1, \dots, m \\ \lambda_j^* &\geq 0, j = 1, \dots, m \\ g_j(\bar{x}^*) &\leq 0, j = 1, \dots, m \end{aligned}$$

si la matriz  $H_j L(\bar{\lambda}^*, \bar{x}^*)$  es negativa definida para todo  $\bar{p} \in M(\bar{x}^*)$  donde

$$M(\bar{x}^*) = \{ \bar{p} \in \mathfrak{R}^n / \nabla g_j(\bar{x}^*) \bar{p} = 0, \text{ para todo } j \in J, \bar{p} \neq \bar{0} \} \neq \emptyset$$

siendo

$$J = \{ j / j = 1, \dots, m, g_j(\bar{x}^*) = 0, \lambda_j^* < 0 \}$$

se verifica que,  $\bar{x}^*$  es un máximo local estricto del programa.

Ejemplo 2.5:

Analizar si se verifican las condiciones de Kuhn-Tucker en los puntos que se indican en el siguiente programa.

$$\begin{cases} \text{Min } (x_1 - 3)^2 + (x_2 - 2)^2 \\ \text{s.a.} \\ x_1^2 + x_2^2 \leq 5 \\ x_1 + x_2 \leq 3 \\ x_1, x_2 \geq 0 \end{cases} \quad \begin{aligned} \bar{x}^* &= (2, 1) \\ \bar{x}'' &= \left( \frac{9}{5}, \frac{6}{5} \right) \end{aligned}$$

TESIS CON  
FALSA DE ORIGEN

las condiciones de kuhn-Tucker son

$$\begin{pmatrix} 2(x_1 - 3) \\ 2(x_2 - 2) \end{pmatrix} + \lambda_1 \begin{pmatrix} 2x_1 \\ 2x_2 \end{pmatrix} + \lambda_2 \begin{pmatrix} 1 \\ 1 \end{pmatrix} + \lambda_3 \begin{pmatrix} -1 \\ 0 \end{pmatrix} + \lambda_4 \begin{pmatrix} 0 \\ -1 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

$$\lambda_1, \lambda_2, \lambda_3, \lambda_4 \geq 0$$

$$\lambda_1(x_1^2 + x_2^2 - 5) = 0, x_1^2 + x_2^2 - 5 \leq 0$$

$$\lambda_2(x_1 + x_2 - 3) = 0, x_1 + x_2 - 3 \leq 0$$

$$\lambda_3(-x_1) = 0, -x_1 \leq 0$$

$$\lambda_4(-x_2) = 0, -x_2 \leq 0$$

En el punto  $\bar{x}^* = (2, 1)$  se verifican todas las restricciones y se saturan la primera y la segunda, por lo que  $\lambda_3 = \lambda_4 = 0$ . Sustituyendo en la ecuación vectorial  $x_1 = 2, x_2 = 1, \lambda_3 = \lambda_4 = 0$  resulta ser el sistema

$$-2 + 4\lambda_1 + \lambda_2 = 0$$

$$-2 + 2\lambda_1 + \lambda_2 = 0$$

cuya solución es  $\lambda_1 = 0, \lambda_2 = 2$ .

Así pues, en  $\bar{x}^* = (2, 1)$  se verifican las condiciones de Kuhn-Tucker con multiplicadores  $\lambda_1 = \lambda_3 = \lambda_4 = 0, \lambda_2 = 2$ .

El punto  $\bar{x}'' = \left(\frac{9}{5}, \frac{6}{5}\right)$  es una solución factible del programa que satura únicamente la segunda restricción. Así pues, sustituyendo en la ecuación vectorial  $x_1 = \frac{9}{5}, x_2 = \frac{6}{5}, \lambda_1 = \lambda_3 = \lambda_4 = 0$  se obtiene el sistema

$$-\frac{12}{5} + \lambda_2 = 0$$

$$-\frac{8}{5} + \lambda_2 = 0$$

que carece de solución. Por tanto, en  $\bar{x}'' = \left(\frac{9}{5}, \frac{6}{5}\right)$  no se verifican las condiciones de Kuhn-Tucker.

A partir de lo anterior sólo es posible afirmar que  $\bar{x}''$  no es la solución óptima del programa

TESIS CON  
FALLA DE ORIGEN

### Teorema 2.4 Condiciones suficientes de óptimo local

Sea el programa

$$(1') \quad \begin{cases} \text{Opt } f(x_1, \dots, x_n) \\ \text{s.n.} \\ g_1(x_1, \dots, x_n) \leq 0 \\ \vdots \\ g_m(x_1, \dots, x_n) \leq 0 \end{cases}$$

con  $f, g_1, \dots, g_m$  funciones diferenciables en un subconjunto abierto  $D \subset \mathcal{M}^n$ , con

$$B = \{\bar{x} \in \mathcal{M}^n / g_j(\bar{x}) \leq 0, j = 1, \dots, m\} \subset D$$

siendo  $B$  un conjunto convexo. Entonces

- (i) Si  $\bar{x}^*$  es una solución factible en la que se cumplen las condiciones de kuhn-Tucker para mínimo y  $f$  es una función convexa en  $B$ , se verifica que  $\bar{x}^*$  es un mínimo global del programa.
- (ii) Si  $\bar{x}^*$  es una solución factible en la que se cumplen las condiciones de kuhn-Tucker para máximo y  $f$  es una función cóncava en  $B$ , se verifica que  $\bar{x}^*$  es un máximo global del programa.

Demostración:

Por ser  $f$  una función convexa y diferenciable en el conjunto convexo  $B$ , se verifica que para todo  $\bar{x} \in B$

$$f(\bar{x}) \geq f(\bar{x}^*) + \nabla f(\bar{x}^*) (\bar{x} - \bar{x}^*)$$

Sea  $I = \{i / i = 1, \dots, m, g_i(\bar{x}^*) = 0\}$  y, por las condiciones de kuhn-Tucker

$$\nabla f(\bar{x}^*) = - \sum_{i \in I} \lambda_i^* \nabla g_i(\bar{x}^*) \text{ con } \lambda_i^* \geq 0, i \in I$$

de donde

$$f(\bar{x}) \geq f(\bar{x}^*) - \sum_{i \in I} \lambda_i^* \nabla g_i(\bar{x}^*) (\bar{x} - \bar{x}^*) \quad (1)$$

TESIS CON  
FALLA DE ORIGEN

por la convexidad del conjunto  $B$ , dados  $\bar{x}, \bar{x}^* \in B$  se verifica que  $\lambda\bar{x} + (1-\lambda)\bar{x}^* \in B$  para todo  $\lambda \in [0,1]$ , por lo tanto para todo  $i \in I$

$$g_i(\lambda\bar{x} + (1-\lambda)\bar{x}^*) = g_i(\lambda\bar{x}^* + \lambda(\bar{x} - \bar{x}^*)) \leq g_i(\bar{x}^*) = 0$$

Por ser  $g_i, i \in I$  funciones diferenciables en  $\bar{x}^*$ , existen todas sus derivadas direccionales en  $\bar{x}^*$  y, en particular para el vector  $\bar{v} = (\bar{x} - \bar{x}^*)$  tenemos

$$g_i(\bar{x}^*; \bar{v}) = \lim_{\lambda \rightarrow 0} \frac{g_i(\bar{x}^* + \lambda(\bar{x} - \bar{x}^*)) - g_i(\bar{x}^*)}{\lambda} = \nabla g_i(\bar{x}^*)(\bar{x} - \bar{x}^*) \leq 0$$

ya que  $g_i(\bar{x}^* - \lambda(\bar{x} - \bar{x}^*)) \leq g_i(\bar{x}^*)$

Así pues de (1) y teniendo en cuenta que  $\lambda_i^* \geq 0$  para  $i \in I$  se obtiene que para todo  $\bar{x} \in B$

$$f(\bar{x}) \geq f(\bar{x}^*)$$

por lo que  $\bar{x}^*$  es mínimo global.

Con éste resultado se asegura por tanto que en programas convexos de minimización las condiciones de Kuhn-Tucker no sólo son necesarias, sino también suficientes y caracterizan soluciones globales.

Si la función objetivo es estrictamente convexa en  $B$ , entonces si  $\bar{x}^*$  es la solución en la que se verifican las condiciones de Kuhn-Tucker, es el mínimo global estricto. Para el caso de maximización, la demostración se hace de manera análoga.

Ejemplo 2.6:

Encontrar la solución óptima del programa

$$\left\{ \begin{array}{l} \text{Min } x_1 + 2x_2 \\ \text{s.a.} \\ x_1 x_2 \geq 1 \\ x_1 - x_2 \leq 2 \\ x_1 \geq 0 \end{array} \right.$$

TESIS CON  
FALLA DE ORIGEN

¿Existe el máximo global para  $f(x_1, x_2) = x_1 + 2x_2$  en el conjunto definido por las restricciones del programa?

Primero transformaremos el programa para que quede de la forma siguiente:

$$\begin{cases} \text{Min } x_1 + 2x_2 \\ \text{s.a.} \\ 1 - x_1 x_2 \leq 0 \\ x_1 - x_2 - 2 \leq 0 \\ -x_1 \leq 0 \end{cases}$$

la función objetivo  $f(x_1, x_2) = x_1 + 2x_2$  es convexa (y también cóncava) y el conjunto de soluciones factibles

$$\begin{aligned} B &= \{(x_1, x_2) \in \mathbb{R}^2 / 1 - x_1 x_2 \leq 0, x_1 - x_2 - 2 \leq 0, -x_1 \leq 0\} \\ &= \{(x_1, x_2) \in \mathbb{R}^2 / 1 - x_1 x_2 \leq 0, x_1 \geq 0\} \cap \{(x_1, x_2) \in \mathbb{R}^2 / x_1 - x_2 - 2 \leq 0\} \end{aligned}$$

es convexo por ser intersección de conjuntos convexos.

Las condiciones de Kuhn-Tucker para este programa son

$$\begin{aligned} 1 - \lambda_1 x_2 + \lambda_2 - \lambda_3 &= 0 \\ 2 - \lambda_1 x_1 - \lambda_2 &= 0 \\ \lambda_1 (1 - x_1 x_2) &= 0 \\ \lambda_2 (x_1 - x_2 - 2) &= 0 \\ \lambda_3 x_1 &= 0 \\ \lambda_1, \lambda_2, \lambda_3 &\geq 0 \\ 1 - x_1 x_2 &\leq 0 \\ x_1 - x_2 - 2 &\leq 0 \\ -x_1 &\leq 0 \end{aligned}$$

Analicemos las distintas posibilidades:

- I.  $\lambda_1 = \lambda_2 = \lambda_3 = 0$
- II.  $\lambda_1 = \lambda_2 = 0$
- III.  $\lambda_1 = \lambda_3 = 0$

No hay soluciones que verifiquen estas condiciones

- IV. Si  $\lambda_2 = \lambda_3 = 0$ ,

entonces

TESIS CON  
FALLA DE ORIGEN

$$\begin{aligned}1 - \lambda_1 x_2 &= 0 \\2 - \lambda_1 x_1 &= 0 \\x_1 x_2 &= 1\end{aligned}$$

de donde

$$\begin{aligned}\frac{1}{x_2} &= \frac{1}{x_1} \\x_1 x_2 &= 1\end{aligned}$$

y resultan los puntos  $(\sqrt{2}, 1/\sqrt{2})$  y  $(-\sqrt{2}, -1/\sqrt{2})$ , aunque sólo el primero es solución factible. El valor de  $\lambda_1$  asociado al punto  $(\sqrt{2}, 1/\sqrt{2})$  es  $\lambda_1^* = \sqrt{2} > 0$ .

Así pues, en  $\bar{x}^* = (\sqrt{2}, 1/\sqrt{2})$  con multiplicadores  $\lambda_1^* = \sqrt{2}, \lambda_2^* = \lambda_3^* = 0$  se verifican las condiciones de Kuhn-Tucker.

Para los casos

V.  $\lambda_1 = 0$

VI.  $\lambda_2 = 0$

no existen soluciones factibles para las que se verifiquen las condiciones de Kuhn-Tucker.

VII. si  $\lambda_3 = 0$ , entonces se tiene el sistema

$$\begin{aligned}1 - \lambda_1 x_2 + \lambda_2 &= 0 \\2 - \lambda_1 x_1 - \lambda_2 &= 0 \\1 - x_1 x_2 &= 0 \\x_1 - x_2 - 2 &= 0\end{aligned}$$

TESIS CON  
FALLA DE ORIGEN

Sustituyendo  $x_1 = x_2 + 2$  en la tercera ecuación resulta  $1 - (x_2 + 2)x_2 = 0$  de donde,  $x_2 = -1 \pm \sqrt{2}$  y se obtienen los puntos

$$\bar{x}^1 = (1 + \sqrt{2}, -1 + \sqrt{2}) \quad \text{y} \quad \bar{x}^2 = (1 - \sqrt{2}, -1 - \sqrt{2})$$

En  $\bar{x}^1$  no se verifican las condiciones de Kuhn-Tucker pues

$$\lambda_1^* = \frac{3}{2\sqrt{2}} \quad \text{y} \quad \lambda_2^* = \frac{\sqrt{2}-3}{2\sqrt{2}} < 0$$

y,  $\bar{x}^2$  no es solución factible.

En resumen, puesto que no existe ninguna solución factible que sature las tres restricciones (VIII), hemos obtenido el único punto

$$\bar{x}^* = (\sqrt{2}, 1/\sqrt{2}) \text{ con } \lambda_1^* = \sqrt{2}, \lambda_2^* = \lambda_3^* = 0$$

En el que se verifican las condiciones de Kuhn-Tucker que en virtud del Teorema 2.4 será mínimo global.

Aunque la función objetivo es también cóncava, y el conjunto factible convexo, el programa

$$\begin{cases} \text{Max } x_1 + 2x_2 \\ \text{s.a.} \\ 1 - x_1 x_2 \leq 0 \\ x_1 - x_2 - 2 \leq 0 \\ -x_1 \leq 0 \end{cases}$$

no tiene máximo global ni local ya que no existe ninguna solución factible en la que se verifiquen las correspondientes condiciones de Kuhn-Tucker. En efecto, para el programa de maximización, las condiciones de Kuhn-Tucker coinciden con las del programa de minimización salvo a las referentes a la positividad de los multiplicadores, que se convierten en

$$\lambda_1, \lambda_2, \lambda_3 \leq 0$$

Teniendo en cuenta, si repasamos la resolución del problema de minimización, es claro que, no existen soluciones factibles que cumplan las condiciones necesarias para ser máximo local.

Por lo que el mínimo global se encuentra en el punto

$$\bar{x}^* = \left( \sqrt{2}, \frac{1}{\sqrt{2}} \right)$$

TESIS CON  
FALLA DE ORIGEN

### 3. Programación Estocástica

#### 3.1 Definición.

La programación estocástica resuelve el problema

$$\left\{ \begin{array}{l} \text{Opt. } f(X) \\ \text{s.a.} \\ g_i(X) \geq 0, i = 1, \dots, m \\ X \in E^n \end{array} \right. \quad (3.1)$$

Cuando algunos de los parámetros de las funciones  $f(X)$  y  $g_i(X), i = 1, \dots, m$  son variables aleatorias. El caso que tomaremos en éste trabajo es cuando adopta la forma lineal

$$\left\{ \begin{array}{l} \text{Max } Z = cX \\ \text{s.a.} \\ AX \leq b \\ X \geq 0 \end{array} \right. \quad (3.2)$$

y las componentes de  $A, b, c$  son total o parcialmente variables aleatorias. Se pueden distinguir dos tipos de programación estocástica: el "pasivo" y el "activo". En el tipo pasivo se espera a que ocurra el valor de la(s) variable(s); entonces se pueden derivar soluciones aproximadas o exactas. En el segundo tipo, se toman las decisiones sobre la variable  $X$  antes de que ocurran todos los eventos aleatorios; esto se puede hacer considerando un conjunto de posibles realizaciones, tomando valores esperados y penalizando la función objetivo, de manera que se eviten desviaciones no tolerables de los valores esperados.

La programación estocástica ha tenido algunas aplicaciones de tipo empírico. Sobresalen en agricultura, secuenciación de aviones, industria química, teoría de control, geroría ejecutiva, mercadotecnia, redes, nutrición, transportes y almacenamiento.

#### 3.2 Programación estocástica de doble etapa.

Considere el programa lineal

$$\left\{ \begin{array}{l} \text{Max } Z = cX \\ \text{s.a.} \\ AX \leq b \\ X \geq 0 \end{array} \right.$$

TESIS CON  
 FALLA DE ORIGEN

donde los vectores  $c, b$  y la matriz  $A$  tienen componentes aleatorias. La función objetivo se convierte en variable aleatoria y por lo tanto, tiene sentido hablar de su valor esperado

$$E(Z) = E(cX) = E\left(\sum_{i=1}^n c_i X_i\right) = \sum_{i=1}^n E(c_i) X_i.$$

En estas estructuras aleatorias se presenta el siguiente problema de factibilidad, muy difícil de resolver: si alguna componente  $a_{ij}$  de  $A$  o  $b_i$  de  $B$  es una variable aleatoria, la restricción correspondiente debe reinterpretarse en el sentido de que una solución de  $X$  es factible, sólo si satisface la restricción para todos los valores posibles de las variables aleatorias en cuestión; hasta el momento no existe un procedimiento práctico que pueda resolver este caso general.

Sin embargo, algunos procedimientos permiten resolver casos particulares, donde se conocen parcial o totalmente los valores asociados a variables aleatorias y sus correspondientes probabilidades.

Sea la siguiente matriz

$$M = \left[ \begin{array}{c|c} c & 0 \\ \hline A & b \end{array} \right]$$

o, explícitamente:

$$M = \left[ \begin{array}{cccc|c} c_1 & c_2 & \dots & c_n & 0 \\ a_{11} & a_{12} & \dots & a_{1n} & b_1 \\ a_{21} & a_{22} & \dots & a_{2n} & b_2 \\ \dots & \dots & \dots & \dots & \dots \\ a_{m1} & a_{m2} & \dots & a_{mn} & b_m \end{array} \right]$$

TESIS CON  
FALLA DE ORIGEN

Sea  $M^k$ ,  $k = 1, \dots, r$  aquella matriz particular de  $M$  donde las variables toman ciertos valores preestablecidos, es decir,

$$M^k = \left[ \begin{array}{c|c} c^k & 0 \\ \hline A^k & b^k \end{array} \right]$$

Sea  $p_t$  la probabilidad de que  $M$  se convierta en  $M^t$  con  $\sum_{t=1}^n p_t = 1$ . El problema estocástico consiste en encontrar el vector  $X$  tal que

$$\left\{ \begin{array}{l} \text{Max } I(Z) = \sum_{t=1}^n p_t c^t X \\ \text{s.a.} \\ A^t X \leq b^t \\ X \geq 0 \end{array} \right. \quad (3.3)$$

El problema anterior puede resultar computacionalmente muy difícil de resolver, para valores muy grandes de  $r$ .

El método de solución llamado de "doble etapa" supone que no es necesario obtener todo el vector  $X$  antes de observar el valor que adoptan las variables aleatorias de  $M$ .

Para cada valor  $j, j = 1, \dots, n$ , sea  $M_j^k, k = 1, \dots, r$  la matriz que se obtiene de  $M^k$  al reemplazar por \* las componentes  $X_j$  del vector de decisiones  $X$  que no se conocerán anticipadamente; \* indica un elemento desconocido. Esto es, si  $M$  se convierte en  $M^k$ ,  $M_j^k$  incluye la parte de  $M^k$  que se conoce cuando se obtiene una realización final en  $X_j$ . El valor que se asigna a  $X_j$  depende de cuál de las matrices  $M_j^k, k = 1, \dots, r; j = 1, \dots, n$  se está observando. Sea  $X_{jk}$  el valor que se asigna a  $X_j$  cuando se observa  $M_j^k$ . La variable  $X_{jk}$  se convierte en el nuevo parámetro de decisión del problema (3.3). Sea  $X^k$  el siguiente vector

$$X^k = \begin{bmatrix} X_{1k} \\ X_{2k} \\ \vdots \\ X_{rk} \end{bmatrix}, \quad k = 1, \dots, r$$

TESIS CON  
FALLA DE ORIGEN

Existe la posibilidad de que algunas variables  $X_{jk}$  se repitan. Si sucede que  $X_{j_1 k_1} = X_{j_2 k_2}$  cuando  $M_{j_1}^{k_1} = M_{j_2}^{k_2}$ , entonces se reemplazan las variables repetidas por una sola variable. Esto asegura que el procedimiento de solución podrá diferenciar la información que se conocerá de la que no se conocerá

El problema (3.3) se reformula como aquel que encuentra los vectores  $X^1, X^2, \dots, X^r$ , tales que

$$\left\{ \begin{array}{l} \text{Max } E(Z) = \sum_{k=1}^r p_k c^k X \\ \text{s.a.} \\ A^k X \leq b^k \\ X \leq 0 \end{array} \right. \quad (3.4)$$

El problema lineal (3.4) se resuelve por el método simplex o su equivalente.

Ejemplo 3.1:

Suponga una matriz  $M$  dada por

$$M = \left[ \begin{array}{cc|c} c_1 & c_2 & 0 \\ a_{11} & a_{12} & b_1 \\ a_{21} & a_{22} & b_2 \\ a_{31} & a_{32} & b_3 \end{array} \right] = \left[ \begin{array}{cc|c} c_1 & c_2 & 0 \\ 1 & 0 & 4 \\ 0 & 1 & 6 \\ a_{31} & a_{32} & 18 \end{array} \right]$$

donde los elementos  $c_1, c_2, a_{31}, a_{32}$  son variables aleatorias. Suponga que los posibles valores de  $c_1$  y  $a_{31}$  son respectivamente (3,3) y (4,2), y que para  $c_2$  y  $a_{32}$  pueden ser (5,2) y (4,3), respectivamente. Por lo tanto, la matriz  $M$  puede adoptar las siguientes estructuras:

$$M^1 = \left[ \begin{array}{cc|c} \bar{3} & \bar{5} & 0 \\ 1 & 0 & 4 \\ 0 & 1 & 6 \\ \bar{3} & \bar{2} & 18 \end{array} \right] \quad M^2 = \left[ \begin{array}{cc|c} \bar{4} & \bar{5} & 0 \\ 1 & 0 & 4 \\ 0 & 1 & 6 \\ \bar{2} & \bar{2} & 18 \end{array} \right]$$

$$M^3 = \left[ \begin{array}{cc|c} \bar{3} & \bar{4} & 0 \\ 1 & 0 & 4 \\ 0 & 1 & 6 \\ \bar{3} & \bar{3} & 18 \end{array} \right] \quad M^4 = \left[ \begin{array}{cc|c} \bar{4} & \bar{4} & 0 \\ 1 & 0 & 4 \\ 0 & 1 & 6 \\ \bar{2} & \bar{3} & 18 \end{array} \right]$$

Los valores de las variables aleatorias se distinguen con un gorro. (̄)

Si conocemos la probabilidad  $p_i$  de que  $M$  se convierta en  $M^k, k=1,2,3,4$  y que ésta es igual a  $p_1 = p_2 = p_3 = p_4 = 0.25$ . Si además conocemos los valores que adoptan  $c_1$  y  $a_{11}$ , se conocen antes de hacer una decisión final en la variable  $X_1$ . Por lo tanto

$$M_1^1 = M_1^3 = \begin{bmatrix} \bar{3} & * & 0 \\ 1 & 0 & 4 \\ 0 & 1 & \bar{6} \\ \bar{3} & * & 18 \end{bmatrix} \quad \text{y} \quad M_1^2 = M_1^4 = \begin{bmatrix} \bar{4} & * & 0 \\ 1 & 0 & 4 \\ 0 & 1 & 6 \\ \bar{2} & * & 18 \end{bmatrix}$$

En forma similar, suponga que  $c_2$  y  $a_{22}$  se conocen antes de seleccionar el valor final de  $X_2$ , por lo que

$$M_2^1 = M_2^3 = \begin{bmatrix} * & \bar{5} & 0 \\ 1 & 0 & 4 \\ 0 & 1 & \bar{6} \\ * & \bar{2} & 18 \end{bmatrix} \quad \text{y} \quad M_2^2 = M_2^4 = \begin{bmatrix} * & \bar{4} & 0 \\ 1 & 0 & 4 \\ 0 & 1 & 6 \\ * & \bar{2} & 18 \end{bmatrix}$$

Sea  $\bar{X}_1$  el valor que se asigna a la variable aleatoria  $X_1$  cuando se observan las matrices  $M_1^1$  o  $M_1^3$ , es decir, cuando se conoce que las variables aleatorias  $c_1$  y  $a_{11}$  adoptan, respectivamente, los valores (3,3). Sea  $X_1^*$  el valor que asigna a la variable  $X_1$  cuando se observan las matrices  $M_1^2$  o  $M_1^4$ , es decir, cuando se conoce que las variables aleatorias  $c_1$  y  $a_{11}$  adoptan los valores (4,2). En forma análoga,  $X_2^*$  es el valor que se asigna a la variable  $X_2$  cuando se observan las matrices  $M_2^1$  o  $M_2^3$ , mientras que  $X_2^*$  es el valor de  $X_2$  cuando se observan  $M_2^2 = M_2^4$ . Por lo tanto

$$X^1 = \begin{bmatrix} \bar{X}_1 \\ \bar{X}_2 \end{bmatrix}, X^2 = \begin{bmatrix} X_1^* \\ \bar{X}_2 \end{bmatrix}, X^3 = \begin{bmatrix} \bar{X}_1 \\ X_2^* \end{bmatrix}, X^4 = \begin{bmatrix} X_1^* \\ X_2^* \end{bmatrix}$$

El programa estocástico puede representarse por su equivalente lineal, consistente en encontrar los vectores  $X^1, X^2, X^3, X^4$ , que

<sup>1</sup> "Inequalities for stochastic linear programming problems" Management science, vol. 6 pp. 494-514, 1964

$$\begin{aligned} \text{Max } E(Z) &= \frac{1}{4} \left[ (3\bar{X}_1 + 5\bar{X}_2) + (4X_1^* + 5\bar{X}_2) + (3\bar{X}_1 + 4X_2^*) + (4X_1^* + 4X_2^*) \right] \\ &= \frac{1}{2} \bar{X}_1 + 2X_1^* + \frac{5}{2} \bar{X}_2 + 2X_2^* \end{aligned}$$

- s.a. a)  $\bar{X}_1 \leq 4$   
 b)  $\bar{X}_2 \leq 6$   
 c)  $3\bar{X}_1 + 2\bar{X}_2 \leq 18$   
 d)  $X_1^* \leq 4$   
 e)  $\bar{X}_2 \leq 6$   
 f)  $2X_1^* + 2\bar{X}_2 \leq 18$   
 g)  $\bar{X}_1 \leq 4$   
 h)  $X_2^* \leq 6$   
 i)  $3\bar{X}_1 + 2X_2^* \leq 18$   
 j)  $X_1^* \leq 4$   
 k)  $X_2^* \leq 6$   
 l)  $2X_1^* + 3X_2^* \leq 18$   
 m)  $\bar{X}_1, \bar{X}_2, X_1^*, X_2^* \geq 0$ .

Las restricciones e), g), j) y k) son redundantes y pueden eliminarse. El problema lineal se resuelve por alguno de los métodos vistos en el capítulo anterior. Se pueden observar las dificultades computacionales (número de variables y restricciones) y combinatorias que se tienen al tratar de formular el equivalente lineal de un programa estocástico.

El procedimiento anterior se conoce en la literatura de la programación estocástica como "modelo de doble etapa" y fue diseñado por Mandansky. A continuación se resume su técnica.

Sea el programa

$$\left\{ \begin{array}{l} \text{Max } \sum_{j=1}^n c_j X_j \\ \text{s.a.} \\ \sum_{j=1}^n a_{ij} X_j = b_i, i = 1, 2, \dots, m \\ X_j \geq 0, j = 1, 2, \dots, n \end{array} \right. \quad (3.5)$$

donde las  $c_j$  son variables aleatorias. El algoritmo de doble etapa supone las siguientes hipótesis:

1. El valor de cada variable aleatoria es independiente de los niveles de todas las variables de decisión  $X_j, j = 1, \dots, n$ .
2. Los niveles de  $X_j, j = 1, \dots, k; k \leq n$  deben fijarse antes de que se conozcan los valores exactos de las variables aleatorias. Note que sólo ocurre para un subconjunto  $k$  de las  $n$  variables de decisión. Esta suposición constituye la "primera etapa".
3. Las restricciones  $i = 1, 2, \dots, g; g \leq m$  contienen únicamente las variables de la primera etapa, es decir,  $X_j, j = 1, \dots, k$  y los valores asociados de  $a_{ij}$  y  $b_i$  se conocen con exactitud.
4. Siempre existen valores factibles para las llamadas variables de la "segunda etapa",  $X_j, j = k+1, \dots, n$ ; éstos se establecen después de conocerse todos los valores de las variables aleatorias.
5. Existe un número finito  $Q$  de posibles valores de la variable aleatoria  $c_j$  ( $j = k+1, \dots, n$ ) y de los coeficientes determinísticos  $a_{ij}, b_i$ , donde  $i = g+1, \dots, m; j = 1, \dots, n$ . Denote a estos conjuntos por  $(c_{jq}, a_{ijq}, b_{iq})$  y por  $p_q, q = 1, 2, \dots, Q$  la probabilidad de ocurrencia del conjunto.

Entonces (3.5) se resuelve por su equivalente determinístico:

$$\left\{ \begin{array}{l} \text{Max. } \sum_{j=1}^k c_j X_j + \sum_{q=1}^Q p_q \left[ \sum_{j=k+1}^n c_{jq} X_{jq} \right] \\ \text{s.a.} \\ \sum_{j=1}^k a_{ij} X_j = b_i, i = 1, \dots, g \quad (\text{la primera etapa}) \\ \sum_{j=1}^k a_{ijq} X_j + \sum_{j=k+1}^n a_{ijq} X_{jq} \quad (\text{reglas de la segunda etapa}) \\ i = g+1, \dots, m; q = 1, 2, \dots, Q \\ X_j \geq 0 \\ X_{jq} \geq 0 \end{array} \right. \quad (3.6)$$

Para el caso general, en que en (3.5) tanto  $c_j$  como  $a_{ij}$  y  $b_i$  son variables aleatorias, los pasos de solución del método de doble etapa son:

Paso 1. Suponga que existen  $Q$  posibles valores de las variables aleatorias  $c_j, a_{ij}, b_i$ . Sean esos valores las ternas  $(c_{jq}, a_{ijq}, b_{iq})$  y sea  $p_q$  la probabilidad de ocurrencia de esos valores.

Paso 2. Rescribir el programa (3.6) como si se conociera el valor exacto de todas las variables aleatorias antes de decidir los niveles de las variables de decisión  $X_j$ . Esto es:

$$\left\{ \begin{array}{l} \text{Max } \sum_{q=1}^Q p_q \sum_{j=1}^n c_{jq} X_{jq} \\ \text{s.a.} \\ \sum_{j=1}^n a_{ij} X_{jq} = b_{ij}, i = 1, 2, \dots, m; q = 1, 2, \dots, Q \\ X_{jq} \geq 0 \end{array} \right. \quad (3.7)$$

$$(3.8)$$

donde  $X_{jq}, j = 1, 2, \dots, n$  son niveles asociados con los valores  $(c_{jq}, a_{ij}, b_{ij})$ .

Paso 3. Se reconoce el hecho de que en realidad no se conocen todos los elementos aleatorios antes de decidir los niveles de las variables  $X_j$ , por lo tanto se debe revisar la formulación del paso 2, insertando restricciones apropiadas que indiquen que ciertas variables deben ser idénticas para los conjuntos apropiados de decisiones. Por ejemplo, si el nivel de  $X_1$  debe determinarse antes de conocer los valores aleatorios, se añade a las restricciones de (3.8) la restricción  $X_{11} = X_{21} = \dots = X_{q1}$ .

Paso 4. Este paso sirve para conectar los pasos 3 y 4 y simplificar las expresiones. Por ejemplo, en el paso 2 se pone  $X_{11}$  cuando aparezca cualquier  $X_{q1}, q = 1, 2, \dots, Q$ .

Ejemplo 3.1:

Considere una empresa que debe determinar el nivel de producción  $X_t$  para  $t = 1, 2, 3, 4$ . Sea  $D_t$  la demanda del periodo  $t$ . La demanda insatisfecha en un periodo se pierde. Sea  $I_t$  el inventario al finalizar el periodo  $t$  con  $I_0 = I_3 = 0$ . Sea  $c_t$  la unidad de ganancia en la venta del producto e igual a la diferencia del precio de venta  $r$ , menos el costo de producción,  $e_t$ . Sea  $h_t$  el costo unitario de almacenamiento en el periodo  $t$ .

El modelo de producción es

$$\left\{ \begin{array}{l} \text{Max } \sum_{t=1}^3 c_t X_t - \sum_{t=1}^2 h_t I_t - (h_3 + r) I_3 \\ \text{s.a.} \\ X_1 - I_1 + S_1 = D_1 \\ I_1 + X_2 - I_2 + S_2 = D_2 \\ I_2 + X_3 - I_3 + S_3 = D_3 \\ X_t, I_t, S_t \geq 0, t = 1, 2, 3 \end{array} \right.$$

donde  $S_t$  es la venta perdida en el periodo  $t, t = 1, 2, 3$ . se analizan a continuación cuatro casos.

En el primer caso,  $D_t$  es una variable aleatoria e independiente del nivel de producción  $X_t$  para toda  $t$ . Se conocen los posibles valores que tomarán las variables aleatorias  $D_1, D_2, \dots, D_n$  antes de fijar el valor de la variable de decisión. La variable aleatoria  $D$  puede tomar dos valores, cada uno con cierta probabilidad;  $D_2$  puede tener cuatro valores, dependiendo del valor de  $D_1$ , y  $D_3$  puede tener ocho valores, dependiendo del valor de  $D_2$ . Por lo tanto, la terna de valores  $(D_{q1}, D_{q2}, D_{q3}), q = 1, \dots, 8$  pueden resumirse simbólicamente en la siguiente tabla.

$D_1$	$D_2$	$D_3$	$P_q$
$D_{11} = D_{21} = D_{31} = D_{41}$	$D_{12} = D_{22}$	$D_{13}$	$p_1$
	$D_{32} = D_{42}$	$D_{23}$	$p_2$
$D_{51} = D_{61} = D_{71} = D_{81}$	$D_{33}$	$D_{33}$	$p_3$
	$D_{43}$	$D_{43}$	$p_4$
	$D_{52} = D_{62}$	$D_{53}$	$p_5$
	$D_{63}$	$D_{63}$	$p_6$
	$D_{72} = D_{82}$	$D_{73}$	$p_7$
		$D_{83}$	$p_8$

Si los valores de todas las variables aleatorias se conocen antes de decidir los niveles de producción de  $X_t$ , el paso 1 de la metodología produce el siguiente programa lineal determinístico equivalente:

$$\left\{ \begin{array}{l} \text{Max } \sum_{q=1}^8 p_q \left[ \sum_{t=1}^1 c_t X_{qt} - \sum_{t=1}^2 h_t I_{qt} - (h_3 + r) I_{q3} \right] \\ \text{s.a.} \\ X_{q1} - I_{q1} + S_{q1} = D_{q1} \\ I_{q1} + X_{q2} - I_{q2} + S_{q2} = D_{q2} \\ I_{q2} + X_{q3} - I_{q3} + S_{q3} = D_{q3} \end{array} \right.$$

que se resuelve por cualquiera de los métodos del capítulo anterior de programación lineal.

TESIS CON  
FALLA DE ORIGEN

El segundo caso supone que se conoce el valor de la demanda  $D_t$  y de las demandas anteriores  $D_{t-1}, D_{t-2}, \dots, D_1$  antes de fijar el nivel de  $X_t$ . No se conoce el valor de las demandas futuras  $D_{t+1}, \dots, D_n$ . Entonces, en concordancia con el paso 2 de la metodología, se establecen las restricciones que se muestran a continuación:

$(X_{q1}, I_{q1}, S_{q1})$	$(X_{q2}, I_{q2}, S_{q2})$
$X_{31} = X_{21} = X_{31} = X_{41}$	$X_{12} = X_{22}$
$I_{11} = I_{21} = I_{31} = I_{41}$	$I_{12} = I_{22}$
$S_{11} = S_{21} = S_{31} = S_{41}$	$S_{12} = S_{22}$
	$X_{32} = X_{42}$
	$I_{32} = I_{42}$
	$S_{32} = S_{42}$
$X_{51} = X_{61} = X_{71} = X_{81}$	$X_{52} = X_{62}$
$I_{51} = I_{61} = I_{71} = I_{81}$	$I_{52} = I_{62}$
$S_{51} = S_{61} = S_{71} = S_{81}$	$S_{52} = S_{62}$
	$X_{72} = X_{82}$
	$I_{72} = I_{82}$
	$S_{72} = S_{82}$

Por ejemplo, si se conoce que  $D_1 = D_{11} = \dots = D_{41}$ , entonces los niveles de  $X_1, I_1$  y  $S_1$  serán los mismos para  $q = 1, 2, 3, 4$ . En forma similar, si se conoce que  $D_2 = D_{32} = D_{42}$ , entonces  $X_2, I_2$  y  $S_2$  serán los mismos para  $q = 3, 4$ .

En la aplicación del paso 3, las restricciones de tipo

$$I_{qt} - X_{qt} - I_{qt} + S_{qt} = D_{qt} \quad \text{para toda } q, t$$

son idénticas para  $q = 1, 2, 3, 4$ , por lo que sólo se utiliza una de ellas.

El tercer caso supone que se conoce el valor de  $D_1, \dots, D_{t-1}$  antes de fijar el valor de  $X_t$ . El paso 2 del método indica añadir la restricción adicional que se muestra a continuación:

$X_{q1}$	$(I_{q1}, S_{q1}, X_{q2})$	$(I_{q2}, S_{q2}, X_{q1})$
$X_{11} = \dots = X_{81}$	$I_{11} = \dots = I_{41}$	$I_{12} = I_{22}$
	$S_{11} = \dots = S_{41}$	$S_{12} = S_{22}$
	$X_{12} = \dots = X_{42}$	$X_{13} = X_{23}$
		$I_{32} = I_{42}$
		$S_{32} = S_{42}$
		$X_{33} = X_{43}$
$X_{51} = \dots = X_{81}$	$I_{51} = \dots = I_{81}$	$I_{52} = I_{62}$
	$S_{51} = \dots = S_{81}$	$S_{52} = S_{62}$
	$X_{52} = \dots = X_{82}$	$X_{53} = X_{63}$
		$I_{72} = I_{82}$
		$S_{72} = S_{82}$
		$X_{73} = X_{83}$

Se nota que todas las  $X_{q1}$  deben ser idénticas, dado que el nivel  $X_1$  se fijó antes del conocimiento exacto de  $D_1$ . Las restricciones de igualdad en  $I_{q1}, S_{q1}$  y  $X_{q2}$  ocurren para los mismos valores de  $q$ , porque los niveles de estas variables se establecen al conocer el valor exacto de  $D_1$ . El grupo de restricciones de la forma

$$I_{q,t-1} + X_{qt} - I_{qt} + S_{qt} = D_{qt} \quad \text{para toda } q, t$$

se reduce considerablemente.

El cuarto y último caso consiste en fijar los niveles de todas las  $X_t$  antes de conocer los valores de las variables aleatorias  $D_t$ . En este caso el modelo contiene únicamente las variables  $X_{11}, X_{12}, X_{13}, I_{q1}, S_{q1}, q = 1, 5; I_{q2}, S_{q2}, q = 1, 3; I_{q3}, S_{q3}, q = 1, 2, \dots, 8$ .

Al ir del primero (información perfecta) al último caso (información imperfecta), se incrementa el número de restricciones de igualdad, que reducen en consecuencia los posibles valores de  $X_t$ .

### 3.3. Programación estocástica restringida

A. Charnes y W. Cooper desarrollaron este enfoque para resolver problemas de programación estocástica. La filosofía de la "programación estocástica restringida" está basada en la premisa de que es altamente deseable, pero no absolutamente necesario que se respeten las restricciones de programa. Explícitamente, esta técnica reemplaza las restricciones lineales

$$\sum_{j=1}^n a_{ij} X_j \leq h_i, \quad i = 1, 2, \dots, m \quad (3.9)$$

por

$$P \left[ \sum_{j=1}^n a_{ij} X_j \leq h_i \right] \geq \alpha_i, \quad i = 1, 2, \dots, m \quad (3.10)$$

donde  $P\{\}$  significa probabilidad y  $\alpha_i$  son constantes establecidas por el decisor. Una solución  $X_j \geq 0, j = 1, \dots, n$  es factible si satisface 3.10. Esta expresión indica que las restricciones 3.9 pueden violarse con una probabilidad de  $1 - \alpha_i$ , donde éste es el riesgo de falla aceptado por el decisor.

Se supone que todos los valores de  $X_j$  deben determinarse antes de conocer los valores de las variables aleatorias. El objetivo consiste en convertir las restricciones probabilísticas 3.10. en equivalentes determinísticos. Se tiene que

$$P \left\{ \sum_{j=1}^n a_{ij} X_j \leq h_i \right\} = P \left\{ \frac{\sum_{j=1}^n a_{ij} X_j - E(h_i)}{\sigma_{h_i}} \leq \frac{h_i - E(h_i)}{\sigma_{h_i}} \right\} \quad (3.11)$$

donde  $E(h_i)$  y  $\sigma_{h_i}$  son respectivamente el valor esperado y la desviación estándar de la variable aleatoria  $h_i, i = 1, \dots, m$ . Como se ha supuesto que  $h_i$  tiene una distribución normal,  $[h_i - E(h_i)]/\sigma_{h_i}$  es una nueva variable aleatoria con distribución normal con media cero y desviación estándar uno.

Demostración:

Sea  $z_i = [b_i - E(b_i)]/\sigma_b$ , y queremos saber la distribución de esta nueva variable aleatoria, para lo cual usaremos la técnica de la función generadora de momentos vista en el capítulo 1.

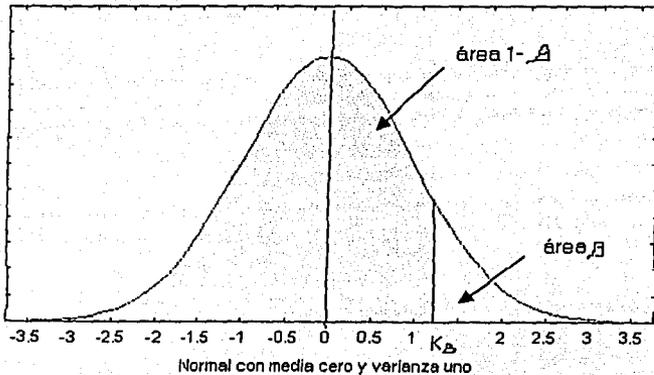
$$E[e^{zt}] = E[e^{(b_i - E(b_i))/\sigma_b}] = E\left[e^{b_i/\sigma_b}\right] e^{-\frac{\mu t}{\sigma_b}} = e^{\frac{\mu t}{\sigma_b}} e^{\frac{\sigma_b^2 t^2}{2\sigma_b^2}} e^{-\frac{\mu t}{\sigma_b}} = e^{t^2/2}$$



De la curva de la distribución normal se desprende que si  $z$  es una variable aleatoria con distribución normal estándar, entonces

$$p\{z \geq K_\beta\} = \beta$$

donde  $K_\beta$  es una constante y  $\beta$  es un número real entre 0 y 1, como se ilustra en la figura siguiente.



Las tablas del apéndice A proporcionan el valor de  $K_\beta$  para varios valores de  $\beta$ . Por ejemplo:

$$K_{0.8508} = 1.04, K_{0.9292} = 1.47, K_{0.9985} = 2.96.$$

por lo que se infiere que

TESIS CON  
FALLA DE ORIGEN

$$p\left\{K_{\alpha_i} \leq \frac{b_i - E(b_i)}{\sigma_{b_i}}\right\} = \alpha_i \quad (3.12)$$

La probabilidad 6.18 aumenta si el número  $K_{\alpha_i}$  se reemplaza por uno menor y disminuye si se substituye por uno mayor. Por lo tanto

$$p\left\{\sum_{j=1}^n \frac{a_j X_j - E(b_i)}{\sigma_{b_i}} \leq \frac{b_i - E(b_i)}{\sigma_{b_i}}\right\} \geq \alpha_i$$

si y sólo si

$$\sum_{j=1}^n \frac{a_j X_j - E(b_i)}{\sigma_{b_i}} \leq K_{\alpha_i} \quad (3.13)$$

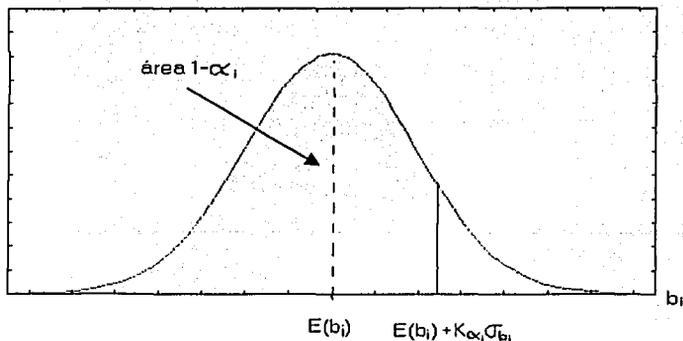
Lo anterior induce a concluir que

$$p\left\{\sum_{j=1}^n a_j X_j \leq b_i\right\} > \alpha_i$$

si y sólo si

$$\sum_{j=1}^n a_j X_j \leq E(b_i) + K_{\alpha_i} \sigma_{b_i}, i = 1, \dots, m \quad (3.14)$$

por lo que si 3.14 substituye a 3.10 se logra el equivalente determinístico, como se ilustra en la figura siguiente.



TESIS CON  
FALLA DE CARGEN

El problema determinístico equivalente consiste entonces en

$$\left\{ \begin{array}{l} \text{Opt } E(Z) = \sum_{j=1}^n E(c_j) X_j, \\ \text{s.a.} \\ \sum_{j=1}^n a_{ij} X_j \leq E(b_i) + K_{\alpha_i} \sigma_{b_i}, i = 1, 2, \dots, m \\ X_j \geq 0, j = 1, 2, \dots, n. \end{array} \right. \quad (3.15)$$

En el caso más general, cuando  $b_i$  tiene una distribución de probabilidad cualquiera, el problema estocástico

$$\left\{ \begin{array}{l} \text{Opt } \sum_{j=1}^n c_j X_j, \\ \text{s.a.} \\ P \left\{ \sum_{j=1}^n a_{ij} X_j \leq b_i \right\} \geq \alpha_i, i = 1, \dots, m \end{array} \right.$$

se resuelve por su equivalente determinístico

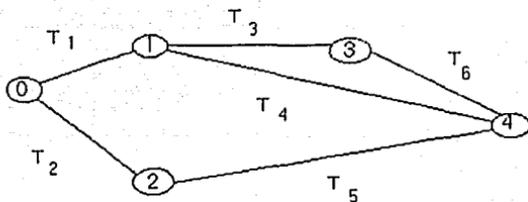
$$\left\{ \begin{array}{l} \text{Opt } \sum_{j=1}^n c_j X_j, \\ \text{s.a.} \\ \sum_{j=1}^n a_{ij} X_j \geq F^{-1}(\alpha_i), i = 1, \dots, m \end{array} \right. \quad (3.16)$$

TESIS CON  
FALLA DE ORIGEN

donde  $F^{-1}(\alpha_i)$ , de poder obtenerse, es la función inversa de la distribución de probabilidad de  $b_i, i = 1, \dots, m$ .

Ejemplo 3.2:

Supongamos una red de actividad, con los datos que se muestran a continuación:



El tiempo pesimista es  $d+t$ , mientras que el tiempo de terminación acelerada es  $d-t$ . El tiempo de ejecución de cada actividad  $i, i=1, \dots, 5$  es una variable aleatoria con distribución conocida  $f_i(Z)$ .

Variable aleatoria	$d$	$t$	$d-t$	$d+t$	$f_i(Z)$
$T_1$	19	10	9	29	$0.5[(Z-19)/10]^{1.5}$
$T_2$	13	5	8	18	$0.5[(Z-13)/5]^{1.5}$
$T_3$	2	1	1	3	$0.5[(Z-2)/1]^{1.5}$
$T_4$	25	6	19	31	$0.5[(Z-25)/6]^{1.5}$
$T_5$	37	16	21	53	$0.5[(Z-37)/16]^{1.5}$
$T_6$	17	10	7	27	$0.5[(Z-17)/10]^{1.5}$

Si se define por  $X_i$  el tiempo en el cual se termina el evento asociado al nodo  $i$ , se requiere entonces resolver el siguiente problema estocástico:

$$\left\{ \begin{array}{l}
 \text{Min } X_4 \\
 \text{s.a.} \\
 p[X_1 \geq T_1] \geq 0.8 \\
 p[X_2 \geq T_2] \geq 0.9 \\
 p[-X_1 + X_3 \geq T_3] \geq 0.7 \\
 p[-X_1 + X_4 \geq T_4] \geq 0.9 \\
 p[-X_2 + X_4 \geq T_5] \geq 0.8 \\
 p[-X_3 + X_4 \geq T_6] \geq 0.7 \\
 X_i \geq 0, i=1, \dots, 4
 \end{array} \right.$$

TESIS CON  
 FALLA DE ORIGEN

para resolver este problema estocástico se utiliza el equivalente determinístico 3.16, basado en el cálculo de la función inversa  $F^{-1}(\alpha_i)$ , como se muestra a continuación:

Variable aleatoria	$d$	$t$	$F^{-1}(Z)$	$\alpha_i$	$F^{-1}(\alpha_i)$
$T_1$	19	10	$19 + 10(2Y - 1)^3$	0.8	21.1
$T_2$	13	5	$13 + 5(2Y - 1)^3$	0.9	15.6
$T_3$	2	1	$2 + (2Y - 1)^3$	0.7	2.1
$T_4$	25	6	$25 + 6(2Y - 1)^3$	0.9	28.1
$T_5$	37	16	$37 + 16(2Y - 1)^3$	0.8	40.5
$T_6$	17	10	$17 + 10(2Y - 1)^3$	0.7	17.6

El equivalente determinístico es

$$\begin{cases}
 \text{Min } X_4 \\
 \text{s.a.} \\
 X_1 \geq 21.1 \\
 X_2 \geq 15.6 \\
 -X_1 + X_3 \geq 2.1 \\
 -X_1 + X_4 \geq 28.1 \\
 -X_2 + X_4 \geq 40.5 \\
 -X_3 + X_4 \geq 17.5 \\
 X_i \geq 0, i = 1, 2, 3, 4
 \end{cases}$$

TESIS CON  
FALLA DE CALIDAD

que se resuelve como un problema de programación lineal (visto en el capítulo 1).

En lo siguiente y para los fines de este trabajo, sólo se trabajará con el caso en el que la distribución de las variables aleatorias son normales, esto se debe a que trabajar con otro tipo de distribución se puede volver una tarea complicada ya que no son tan fáciles de manejar y la transformación puede ser un trabajo complicado.

### 3.4 Caso 1. Coeficientes $a_j$ con distribución Normal.

En este caso, cada  $a_j$  está normalmente distribuida con media  $E\{a_j\}$  y varianza  $\text{var}\{a_j\}$ . Además, la covarianza de  $a_j$  y  $a_{r,j}$  está dada como

$$\text{cov}\{a_j, a_{r,j}\} = E\{a_j - E\{a_j\}\}(a_{r,j} - E\{a_{r,j}\}).$$

Considere la  $i$ -ésima restricción

$$P\left\{\sum_{j=1}^n a_j X_j \leq h_i\right\} \geq 1 - \alpha,$$

y definimos

$$h_i = \sum_{j=1}^n a_j X_j \quad (3.15)$$

Entonces  $h_i$  está distribuida normalmente con

$$E\{h_i\} = \sum_{j=1}^n E\{a_j\} X_j \quad \text{y} \quad \text{var}\{h_i\} = \bar{X}^T D_i \bar{X} \quad (3.16)$$

donde

$$\bar{X} = (X_1, X_2, \dots, X_n)^T$$

$$D_i = i\text{-ésima matriz de covarianza} = \begin{pmatrix} \text{var}\{a_{i1}\} & \cdots & \text{cov}\{a_{i1}, a_{in}\} \\ \vdots & \ddots & \vdots \\ \text{cov}\{a_{in}, a_{i1}\} & \cdots & \text{var}\{a_{in}\} \end{pmatrix} \quad (3.17)$$

ahora,

$$P\{h_i \leq h_i\} = P\left\{\frac{h_i - \mu_i}{\sigma_{h_i}} \leq \frac{h_i - \mu_i}{\sigma_{h_i}}\right\} \geq 1 - \alpha,$$

donde  $(h_i - \mu_i)/\sigma_{h_i}$  es normal estándar. Lo que significa que

TESIS CON  
 FALLA DE ORIGEN

$$\Phi(K_{\alpha}) = 1 - \alpha \quad (3.18)$$

Entonces la desigualdad  $p\{h_i \leq h\} \geq 1 - \alpha$ , se verifica si y sólo si

$$\frac{h_i - \mu_i}{\sigma_{h_i}} \geq K_{\alpha} \quad (3.19)$$

lo que proporciona la restricción no lineal siguiente

$$\sum_{j=1}^n t_j [a_{ij}] X_j + K_{\alpha} \sqrt{\bar{X}^T D_i \bar{X}} \leq h_i \quad (3.20)$$

la cual es equivalente a la restricción estocástica original.

Para el caso especial en el que las distribuciones normales son independientes, se tiene que

$$\text{cov}\{a_{ij}, a_{i'j'}\} = 0$$

esto se puede demostrar fácilmente de la definición de covarianza.

Y la última restricción se reduce a

$$\sum_{j=1}^n t_j [a_{ij}] X_j + K_{\alpha} \sqrt{\sum_{j=1}^n \text{var}[a_{ij}] X_j^2} \leq h_i$$

Esta restricción puede transformarse utilizando la transformación siguiente

$$Y_i = \sqrt{\sum_{j=1}^n \text{var}[a_{ij}] X_j^2}, \quad \text{para toda } i \quad (3.21)$$

Por lo que, la restricción original es equivalente a

$$\sum_{j=1}^n t_j [a_{ij}] X_j + K_{\alpha} Y_i \leq h_i \quad (3.22)$$

y

$$\sum_{j=1}^n \text{var}[a_{ij}] X_j^2 - Y_i^2 = 0$$

donde  $Y_i^2 \geq 0$ .

TESIS CON  
 FALLA DE ORIGEN

## Ejemplo 3.3:

Un inversionista quiere arriesgar su capital en  $n$  acciones diferentes. Su selección es tal que asegure una probabilidad de 0.05 o menos, de perder en la inversión. Se tienen disponibles las estimaciones de los precios de las acciones en ese momento. Estas estimaciones son variables aleatorias, distribuidas normalmente con media  $\mu_i$  y varianza  $\sigma_i^2$ . Si  $X_i$  es la fracción del capital disponible para invertir en la acción  $i, i = 1, \dots, n$ , entonces el problema consiste en maximizar el rendimiento total de la inversión

$$\left\{ \begin{array}{l} \text{Max } E[Y] = \sum_{i=1}^n \left( \frac{\mu_i}{c_i} \right) X_i \\ \text{s.a.} \\ P \left\{ \left[ \sum_{i=1}^n \left( \frac{\mu_i}{c_i} \right) X_i \right] \geq 1.0 \right\} \geq 0.95 \end{array} \right.$$

Donde  $c_i$  es el costo inicial de la acción  $i$ . El equivalente determinístico se logra utilizando la fórmula de inversión 3.15, obteniéndose la restricción

$$\sum_{i=1}^n \left[ \frac{\mu_i}{c_i} \right] X_i - t \left[ \sum_{i=1}^n \left( \frac{X_i}{c_i} \right)^2 \sigma_i^2 \right]^{\frac{1}{2}} \geq 1.0$$

El valor de  $t$  se obtiene de las tablas de la distribución normal,  $K = t/(t)$ , cuando  $K = 0.95$ ; el valor generado por las tablas es  $t = 1.645$ . El problema determinístico se convierte en uno no lineal que se puede resolver por los métodos de programación no lineal del capítulo anterior y queda la siguiente manera:

$$\left\{ \begin{array}{l} \text{Max } E[Y] = \sum_{i=1}^n \left( \frac{\mu_i}{c_i} \right) X_i \\ \text{s.a.} \\ \sum_{i=1}^n \left[ \frac{\mu_i}{c_i} \right] X_i - t \left[ \sum_{i=1}^n \left( \frac{X_i}{c_i} \right)^2 \sigma_i^2 \right]^{\frac{1}{2}} \geq 1.0 \end{array} \right.$$

TESIS CON  
FALLA DE ORIGEN

### 3.5 Caso 2. Coeficientes $b_i$ con distribución Normal.

En este caso únicamente  $b_i$  es normal con media  $\mu_i$  y varianza  $\sigma_i^2$ . El análisis de este caso es muy similar al caso 1. Considere la restricción estocástica

$$P\left\{b_i \geq \sum_{j=1}^n a_{ij} X_j\right\} \geq \alpha, \quad (3.23)$$

como en el caso 1,

$$P\left\{\frac{b_i - \mu_i}{\sigma_i} \geq \frac{\sum_{j=1}^n a_{ij} X_j - \mu_i}{\sigma_i}\right\} \geq \alpha, \quad (3.24)$$

esto puede suceder únicamente si

$$\frac{\sum_{j=1}^n a_{ij} X_j - \mu_i}{\sigma_i} \leq K_\alpha, \quad (3.25)$$

por consiguiente, la restricción estocástica es equivalente a la restricción lineal determinística

$$\sum_{j=1}^n a_{ij} X_j \leq \mu_i + K_\alpha \sigma_i, \quad (3.26)$$

por lo que, en el caso 2 el modelo de restricciones aleatorias puede convertirse en un problema equivalente.

#### Ejemplo 3.4:

Considere el problema con restricciones aleatorias

$$\left\{ \begin{array}{l} \text{Max } Z = 5X_1 + 6X_2 + 3X_3 \\ \text{s.a.} \\ P\{a_{11}X_1 + a_{12}X_2 + a_{13}X_3 \leq 8\} \geq 0.95 \\ P\{5X_1 + X_2 + 6X_3 \leq b_2\} \geq 0.10 \\ X_j \geq 0 \end{array} \right.$$

Con las variables aleatorias  $a_j$  con distribución normal con las siguientes medias y varianzas:

$$\begin{aligned} E[a_{11}] &= 1 & E[a_{12}] &= 3 & E[a_{13}] &= 9 \\ \text{var}[a_{11}] &= 25 & \text{var}[a_{12}] &= 16 & \text{var}[a_{13}] &= 4 \end{aligned}$$

El parámetro  $b_2$  está distribuido normalmente con media 7 y varianza 9.

De las tablas de la distribución normal obtenemos

$$K_{a_1} = K_{0.95} \cong 1.645, \quad K_{a_2} = K_{0.90} \cong 1.285.$$

Para la primera restricción, la restricción determinística equivalente está dada como

$$X_1 + 3X_2 + 9X_3 + 1.645\sqrt{25X_1^2 + 16X_2^2 + 4X_3^2} \leq 8$$

y para la segunda restricción

$$5X_1 + X_2 + 6X_3 \leq 7 + 1.285(3) = 10.855$$

por lo que el problema completo queda de la forma siguiente:

$$\left\{ \begin{array}{l} \text{Max } Z = 5X_1 + 6X_2 + 3X_3 \\ \text{s.a.} \\ X_1 + 3X_2 + 9X_3 + 1.645\sqrt{25X_1^2 + 16X_2^2 + 4X_3^2} \leq 8 \\ 5X_1 + X_2 + 6X_3 \leq 10.855 \\ X_i \geq 0, i = 1, 2, 3 \end{array} \right.$$

el cual, se resuelve por los métodos del capítulo pasado.

### 3.6 Caso 3. Todos los coeficientes $a_j$ y $b_i$ con distribución Normal.

En este caso, todas las  $a_j$  y  $b_i$  son variables aleatorias Normales independientes (para simplificar los cálculos). Ahora consideremos la restricción

$$\sum_{j=1}^n a_j X_j \leq b_i$$

la cual se puede escribir como

$$Y_i = \sum_{j=1}^n a_{ij} X_j - b_i \leq 0 \quad (3.27)$$

de donde se puede ver que  $Y_i$  tiene distribución Normal con media  $\mu_i$  y varianza  $\sigma_i^2$ .

Demostración:

Sea  $w_i = \sum_{j=1}^n a_{ij} X_j$ , entonces  $Y = w_i - b_i$  pero sabemos que  $w_i$  tiene distribución Normal

con  $\mu_{w_i} = \sum_{j=1}^n \mu_{w_j} X_j$  y  $\sigma_{w_i}^2 = \sum_{j=1}^n \sigma_{w_j}^2 X_j^2$  (por el ejemplo 11 del capítulo 1).

Entonces

$$\begin{aligned} \exp(tY_i) &= \exp[(w_i - b_i)t] = \exp(w_i t) \exp[-t b_i] = \\ &= \exp\left(\mu_{w_i} t + \frac{1}{2} \sigma_{w_i}^2 t^2\right) \exp\left(-\mu_{b_i} + \frac{1}{2} \sigma_{b_i}^2 t^2\right) = \\ &= \exp\left[(\mu_{w_i} - \mu_{b_i})t + \frac{1}{2} (\sigma_{w_i}^2 + \sigma_{b_i}^2) t^2\right] \end{aligned}$$

TESIS CON  
FALLA DE CALIDAD EN

por lo que  $Y_i$  se distribuye como una variable aleatoria Normal con  $\mu_i = \mu_{w_i} - \mu_{b_i}$  y  $\sigma_i^2 = \sigma_{w_i}^2 + \sigma_{b_i}^2$

□

Esto muestra que la restricción aleatoria se reduce en este caso a la misma situación del caso 1, y se trata de forma similar.

Nuestro interés ahora se basa en encontrar el equivalente determinístico para la restricción

$$P\{Y_i \leq 0\} \quad (3.28)$$

ahora,

$$P\{Y_i \leq 0\} = P\left\{\frac{Y_i - \mu_i}{\sigma_i} \leq \frac{-\mu_i}{\sigma_i}\right\} \geq 1 - \alpha, \quad (3.29)$$

de donde  $(Y_i - \mu_i) / \sigma_i$  tiene distribución Normal estándar.

Sea  $K_{\alpha}$  el valor Normal estándar tal que

$$\Phi(K_{\alpha}) = 1 - \alpha,$$

Entonces la desigualdad  $p\{Y_i \leq 0\} \geq 1 - \alpha$ , se verifica si y sólo si

$$\frac{-\mu_{Y_i}}{\sigma_{Y_i}} \geq K_{\alpha}, \quad (3.30)$$

lo que proporciona la siguiente restricción determinística equivalente

$$\mu_{Y_i} + K_{\alpha} \sqrt{\sum_{j=1}^n (\sigma_{a_{ij}}^2 + \sigma_{b_{ij}}^2)} Y_j \leq 0 \quad (3.31)$$

Con lo que queda el programa determinístico completo.

TESIS CON  
FALLA DE ORIGEN

## APÉNDICE I

### Funciones Indicadoras

**Definición .** Una función "indicadora" de un conjunto  $A$  es una función que toma el valor de 1 en todos los puntos de  $A$  y el valor de 0 en todos los puntos de  $A^c$ , y se denota mediante  $I_{\{A\}}$ . Por tanto  $I_{\{A\}}(x) = 1$  si  $x \in A$  e  $I_{\{A\}}(x) = 0$  en los demás casos.

Dos de las propiedades básicas para el uso de las funciones indicadoras son las siguientes.

1. El producto de funciones indicadoras puede reemplazarse por una sola función indicadora; para ser mas específicos, para los eventos  $A_1, A_2, \dots, A_n$ , tenemos:

$$I_{\{A_1\}} I_{\{A_2\}} \cdots I_{\{A_n\}} = I_{\{A_1 \cap A_2 \cap \dots \cap A_n\}}, \quad (1)$$

Por lo que el producto de las funciones indicadoras de los conjuntos  $A_1, A_2, \dots, A_n$  es igual a la función indicadora de la intersección de los mismos conjuntos. Estrictamente hablando, este método es una forma abreviada de escribir la siguiente familia de ecuaciones: para cada observación  $x$ .

$$I_{\{A_1\}}(x) I_{\{A_2\}}(x) \cdots I_{\{A_n\}}(x) = I_{\{A_1 \cap A_2 \cap \dots \cap A_n\}}(x). \quad (2)$$

2. La suma de funciones indicadoras en algunas circunstancias se puede expresar como una sola función indicadora . Si los eventos  $A_1, A_2, \dots, A_n$  son mutuamente excluyentes, entonces:

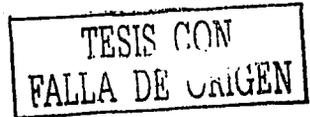
$$I_{\{A_1\}} + I_{\{A_2\}} + \cdots + I_{\{A_n\}} = I_{\{A_1 \cup A_2 \cup \dots \cup A_n\}}.$$

Un resultado importante se obtiene cuando  $n = 2$  y  $A_2 = A_1^c$ . Entonces  $A_1 \cup A_2 = A$ , donde  $A$  es el total, lo que implica que  $I_{\{A_1 \cup A_2\}}$  es idénticamente igual a uno. Por lo que para un evento  $A$

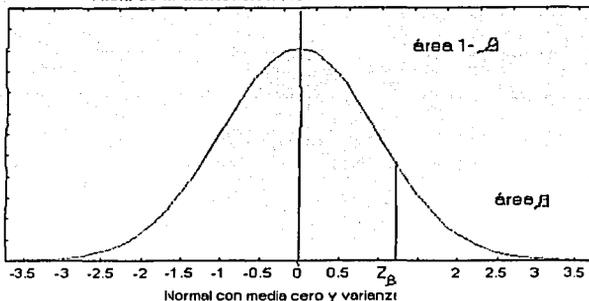
$$I_{\{A\}} + I_{\{A^c\}} = 1, \text{ entonces } I_{\{A^c\}} = 1 - I_{\{A\}}.$$

Por ejemplo, sean  $A$  y  $B$  dos conjuntos, entonces:

$$\begin{aligned} I_{\{A \cup B\}} &= 1 - I_{\{A^c \cap B^c\}} \\ &= 1 - I_{\{A^c\}} I_{\{B^c\}} \\ &= 1 - (1 - I_{\{A\}})(1 - I_{\{B\}}) \\ &= I_{\{A\}} + I_{\{B\}} - I_{\{A \cap B\}}. \end{aligned}$$



APÉNDICE II  
Tabla de la distribución Normal estándar acumulativa.



z	0	0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08	0,09
-3.5	0,00023267	0,0002241	0,00021582	0,00020782	0,00020010	0,00019268	0,00018547	0,00017853	0,00017184	0,00016538
-3.4	0,00033698	0,00032487	0,00031316	0,00030184	0,00029091	0,00028034	0,00027013	0,00026028	0,00025075	0,00024156
-3.3	0,00044834	0,00043854	0,00042914	0,00042009	0,00041139	0,00040304	0,00039507	0,00038749	0,00038028	0,00037345
-3.2	0,00056782	0,00055937	0,00055122	0,00054336	0,00053577	0,00052844	0,00052137	0,00051456	0,00050799	0,00050176
-3.1	0,00069676	0,00068935	0,00068218	0,00067524	0,00066854	0,00066207	0,00065583	0,00064981	0,00064401	0,00063842
-3.0	0,00134997	0,00134331	0,00133689	0,00133070	0,00132474	0,00131901	0,00131350	0,00130821	0,00130313	0,00129825
-2.9	0,00186588	0,00186021	0,00185476	0,00184953	0,00184451	0,00183970	0,00183510	0,00183071	0,00182652	0,00182253
-2.8	0,00255519	0,00255021	0,00254544	0,00254088	0,00253653	0,00253238	0,00252843	0,00252468	0,00252112	0,00251775
-2.7	0,00334670	0,00334241	0,00333831	0,00333439	0,00333065	0,00332708	0,00332369	0,00332047	0,00331742	0,00331454
-2.6	0,00424612	0,00424251	0,00423907	0,00423580	0,00423269	0,00422974	0,00422695	0,00422431	0,00422182	0,00421948
-2.5	0,00525968	0,00525665	0,00525378	0,00525106	0,00524849	0,00524607	0,00524380	0,00524167	0,00523968	0,00523782
-2.4	0,00639753	0,00639501	0,00639261	0,00639032	0,00638814	0,00638606	0,00638408	0,00638220	0,00638041	0,00637871
-2.3	0,00766408	0,00766197	0,00766000	0,00765815	0,00765641	0,00765477	0,00765323	0,00765178	0,00765041	0,00764912
-2.2	0,00906243	0,00906061	0,00905892	0,00905734	0,00905585	0,00905445	0,00905313	0,00905189	0,00905072	0,00904961
-2.1	0,01059302	0,01059149	0,01059004	0,01058866	0,01058735	0,01058611	0,01058493	0,01058381	0,01058274	0,01058171
-2.0	0,01226406	0,01226271	0,01226143	0,01226021	0,01225904	0,01225792	0,01225685	0,01225582	0,01225483	0,01225388
-1.9	0,01407328	0,01407209	0,01407096	0,01406988	0,01406885	0,01406786	0,01406691	0,01406600	0,01406513	0,01406429
-1.8	0,01602604	0,01602499	0,01602399	0,01602303	0,01602211	0,01602123	0,01602038	0,01601956	0,01601877	0,01601800
-1.7	0,01812917	0,01812821	0,01812730	0,01812642	0,01812557	0,01812475	0,01812396	0,01812319	0,01812244	0,01812171
-1.6	0,02038431	0,02038344	0,02038261	0,02038181	0,02038103	0,02038028	0,02037955	0,02037884	0,02037815	0,02037748
-1.5	0,02279352	0,02279273	0,02279198	0,02279125	0,02279054	0,02278985	0,02278918	0,02278853	0,02278789	0,02278727
-1.4	0,02535681	0,02535609	0,02535540	0,02535473	0,02535408	0,02535344	0,02535281	0,02535219	0,02535158	0,02535098
-1.3	0,02806627	0,02806561	0,02806497	0,02806434	0,02806372	0,02806311	0,02806251	0,02806191	0,02806132	0,02806074
-1.2	0,03092105	0,03092044	0,03091984	0,03091925	0,03091867	0,03091810	0,03091754	0,03091698	0,03091643	0,03091588
-1.1	0,03391333	0,03391277	0,03391221	0,03391166	0,03391112	0,03391058	0,03391005	0,03390952	0,03390899	0,03390847
-1.0	0,03703214	0,03703161	0,03703108	0,03703055	0,03703002	0,03702950	0,03702898	0,03702846	0,03702794	0,03702742
-0.9	0,04027634	0,04027583	0,04027531	0,04027479	0,04027427	0,04027375	0,04027323	0,04027271	0,04027219	0,04027167
-0.8	0,04364515	0,04364465	0,04364414	0,04364362	0,04364310	0,04364258	0,04364206	0,04364154	0,04364102	0,04364050

TESIS CON  
FALLA DE ORIGEN