UNIVERSITAT POLITÈCNICA DE CATALUNYA – BARCELONATECH

OPE – ORGANIZACIÓN DE LA PRODUCCIÓN Y DE EMPRESA (ASPECTOS TÉCNICOS, JURÍDICOS Y ECONÓMICOS EN PRODUCCIÓN)

Modelos y herramientas de decisión. Análisis de decisiones II

MODELOS Y HERRAMIENTAS DE DECISIÓN 240EO023 – Máster Universitario en Ingeniería de Organización (240MUEO) - ETSEIB

Joaquín Bautista-Valhondo

OPE-PROTHIUS – OPE-MSc.2018/18 240EO023 (20180222) - http://futur.upc.edu/OPE - www.prothius.com -
Departamento de Organización de Empresas – ETSEIB · UPC

PROTHIUS
Càtedra Organització Industrial

Contenido

Decisión multiestado

- *Concepto: Elegir en entornos no certeros*

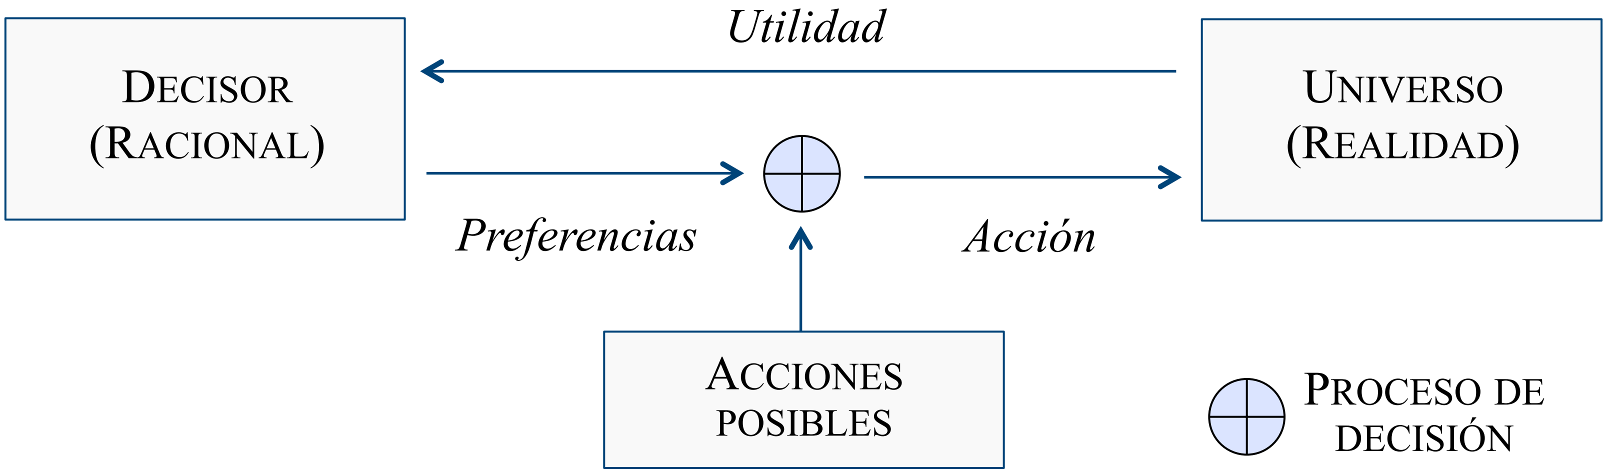

Utilidad: Información que comunica el universo al decisor.

Acciones: Decisiones tomadas por el decisor.

Preferencias: Ordenación de criterios del decisor

Probabilidades: Existe una ley de probabilidad objetiva vinculada a los estados de la naturaleza

Tipología del Universo

Determinista

Se conoce con certeza el estado de la naturaleza que se dará. Factores definidos y conocidos. A cada acción corresponde una y sólo una consecuencia.

Incierto

Diversos estados de la naturaleza posibles. Ninguna ley de probabilidad objetiva referida a ellos. Hay diversos niveles de incertidumbre.

Aleatorio-Probabilista

No se conoce con certeza el estado de la naturaleza que se dará. Existe una ley de probabilidad objetiva.

Hostil

Diversos estados de la naturaleza posibles. No hay ley de probabilidad objetiva referida a los estados. Los estados están influidos por las decisiones de entes inteligentes ajenos con objetivos no coincidentes con los del decisor (Juego)

Decisiones en Universo aleatorio-probabilista

- *Elementos:*
  - *Estados de la naturaleza:* Situaciones en las que nos podemos encontrar, vinculadas a priori a una ley de probabilidad objetiva, tras tomar una decisión.
  - *Acciones del decisor:* Alternativas ante la elección.
  - *Utilidad (resultados):* Evaluación de las consecuencias al elegir (ganancias o pagos).

$$s_j \in S$$
$$a_i \in A$$
$$u_{ij} \in U$$
$$p_j \ \forall s_j \in S$$

	s_1	s_2	...	s_n
a_1	u_{11}	u_{12}		u_{1n}
a_2	u_{21}	u_{22}		u_{2n}
...				
a_m	u_{m1}	u_{m2}		u_{mn}

Tabla-1: Tabla de pagos (utilidades) acción-estado. Los pagos pueden ser ganancias o pérdidas (frustración) para el decisor.

$$U(a_i) = f\left(U_i, S, \vec{p}(S)\right) \text{ con } U_i = \left\{u_{kj} \in U : k = i\right\} \ \forall a_i \in A$$

Ejemplo 2. Presentación (1) · Ganancias y probabilidades

Ejemplo 2 · Lanzamiento de nuevo producto al mercado FHI · Enunciado_1:

La empresa FHI quiere lanzar un nuevo producto al mercado (plan-horizonte 5 años) contando con 4 alternativas posibles y especulando sobre 4 posibles estados del mercado sujetos a una ley de probabilidad objetiva. Las ganancias y probabilidades se recogen en la Tabla-1.

Acciones:

a_1 : Recursos actuales

a_2 : Salida a bolsa

a_3 : Alianza con empresa

a_4 : Alianza y bolsa

Estados de la naturaleza:

s_1 : Bonanza

s_2 : Creecimiento leve

s_3 : Estable

s_4 : Recesión

$\vec{p}(S)$	0.2	0.3	0.4	0.1
$U(A,S)$	s1	s2	s3	s4
a1	100	60	30	0
a2	75	70	10	5
a3	55	30	80	75
a4	35	40	50	80

Tabla-1: Pagos acción-estado (tabla de ganancias) y probabilidades a priori de los estados de la naturaleza sobre la valoración del lanzamiento de un nuevo producto al mercado por parte de la empresa FHI.

Ejemplo 2. Presentación (2) · Frustraciones y probabilidades

Ejemplo 2 · Lanzamiento de nuevo producto al mercado FHI · Enunciado_2:

La empresa FHI quiere lanzar un nuevo producto al mercado (plan-horizonte 5 años) contando con 4 alternativas posibles y especulando sobre 4 posibles estados del mercado sujetos a una ley de probabilidad objetiva. Las frustraciones y probabilidades se recogen en la Tabla-2.

Acciones:

a_1 : Recursos actuales

a_2 : Salida a bolsa

a_3 : Alianza con empresa

a_4 : Alianza y bolsa

Estados de la naturaleza:

s_1 : Bonanza

s_2 : Creecimiento leve

s_3 : Estable

s_4 : Recesión

$\vec{p}(S)$	0.2	0.3	0.4	0.1
$V(A,S)$	s1	s2	s3	s4
a1	0	10	50	80
a2	25	0	70	75
a3	45	40	0	5
a4	65	30	30	0

Tabla-2: Frustraciones acción-estado y probabilidades a priori de los estados de la naturaleza sobre la valoración del lanzamiento de un nuevo producto al mercado por parte de la empresa FHI.

Decisiones en Universo probabilista sin experimentación

Procedimientos:

Sean :

S	Conjunto de estados de la naturaleza, $S=\{s_1,..,s_n\}$
A	Conjunto de acciones posibles, $A=\{a_1,..,a_m\}$, del decisor
$u_{i,j}$	Utilidad (ganancia) normalizada de la acción $a_i \in A$ ante el estado $s_j \in S$
$v_{i,j}$	Frustración normalizada de la acción a_i ante estado s_j : $v_{i,j}=\max\limits_{a_i\in A}\{u_{i,j}\}-u_{i,j}$
p_j	Probabilidad asociada a la ocurrencia del estado $s_j \in S$ · Notaciones: $p_j \equiv p(s_j)\ \forall s_j \in S$
s^*, j^*	Estado más probable: $s^* \equiv s_{j^*}$ · Índice del estado más probable (ab. not.): $j^*=\underset{s_j\in S}{\operatorname{argmax}}\{p_j\}$

Percepción	*Enfoque*	*Decisor*	*Función*	*Acción óptima*
Oportunista	Utilidad	Estado s^*	$\max f(\vec{a},\vec{s})=\max\limits_{a_i\in A}\{u_{i,j^*}\}$	$a^*=\underset{a_i\in A}{\operatorname{argmax}}\{u_{i,j^*}\}$
Oportunista	Frustración	Estado s^*	$\min f(\vec{a},\vec{s})=\min\limits_{a_i\in A}\{v_{i,j^*}\}$	$a^*=\underset{a_i\in A}{\operatorname{argmin}}\{v_{i,j^*}\}$
Probabilista	Utilidad	BAYES	$\max f(\vec{a},\vec{s})=\max\limits_{a_i\in A}\left\{\sum_{j=1}^{n} p_j u_{i,j}\right\}$	$a^*=\underset{a_i\in A}{\operatorname{argmax}}\left\{\sum_{j=1}^{n} p_j u_{i,j}\right\}$
Probabilista	Frustración	BAYES	$\min f(\vec{a},\vec{s})=\min\limits_{a_i\in A}\left\{\sum_{j=1}^{n} p_j v_{i,j}\right\}$	$a^*=\underset{a_i\in A}{\operatorname{argmin}}\left\{\sum_{j=1}^{n} p_j v_{i,j}\right\}$

Ejemplo 2. Resolución · Estado más probable (1)

Ejemplo 2 · Lanzamiento nuevo producto FHI · Resolución Estado más probable · Ganancias:

Los estados de la naturaleza están sujetos a una ley de probabilidad objetiva. Se selecciona la acción que maximiza la ganancia del estado más probable.

Función objetivo:

$$\max f(\vec{a},\vec{s}) = \max_{a_i \in A}\{f_i(a_i)\}$$

$$f_i(a_i) = u_{i,j^*} \quad \forall a_i \in A$$

$$j^* = \underset{s_j \in S}{\operatorname{argmax}}\{p_j\} = 3 \Rightarrow s^* = s_3$$

Acción óptima Oportunista:

$$a^* = \underset{a_i \in A}{\operatorname{argmax}}\{u_{i,3}\}$$

$$\vec{f}(\vec{a}) = (30,10,80,50)$$

$$a^* = \underset{a_i \in A}{\operatorname{argmax}}\{f_i(a_i)\} = a_3$$

$\vec{p}(S)$	0.2	0.3	0.4	0.1	
$U(A,S)$	s1	s2	s3	s4	$f_i(a_i)$
a1	100	60	30	0	30
a2	75	70	10	5	10
a3	55	30	80	75	**80**
a4	35	40	50	80	50

Tabla-3: Mejor acción Estado más probable (enfoque ganancias) sobre lanzamiento de un nuevo producto al mercado por parte de la empresa FHI. Estado más probable s3 : p(s3)=0.4

Ejemplo 2. Resolución · Estado más probable (2)

Ejemplo 2 · Lanzamiento nuevo producto FHI · Resolución Estado más probable · Frustraciones:

Los estados de la naturaleza están sujetos a una ley de probabilidad objetiva. Se selecciona la acción que minimiza la frustración del estado más probable.

Función objetivo:

$$\min f(\vec{a},\vec{s}) = \min_{a_i \in A}\left\{f_i(a_i)\right\}$$

$$f_i(a_i) = v_{i,j^*} \ \forall a_i \in A$$

$$j^* = \underset{s_j \in S}{\operatorname{argmax}}\left\{p_j\right\} = 3 \Rightarrow s^* = s_3$$

Acción óptima Oportunista:

$$a^* = \underset{a_i \in A}{\operatorname{argmin}}\left\{v_{i,3}\right\}$$

$$\vec{f}(\vec{a}) = (50,70,0,30)$$

$$a^* = \underset{a_i \in A}{\operatorname{argmin}}\left\{f_i(a_i)\right\} = a_3$$

$\vec{p}(S)$	0.2	0.3	0.4	0.1	
$U(A,S)$	s1	s2	s3	s4	$f_i(a_i)$
a1	0	10	50	80	50
a2	25	0	70	75	70
a3	45	40	0	5	**0**
a4	65	30	30	0	30

Tabla-4: Mejor acción Estado más probable (enfoque frustraciones) sobre lanzamiento de un nuevo producto al mercado por parte de la empresa FHI. Estado más probable s3 : p(s3)=0.4

PROTHIUS
Càtedra Organització Industrial

Ejemplo 2. Resolución · Bayes sin experimentación (1)

Ejemplo 2 · Lanzamiento nuevo producto FHI · Resolución bayesiana · Ganancias:

Los estados de la naturaleza están sujetos a una ley de probabilidad objetiva. Se selecciona la acción que maximiza la esperanza matemática de la ganancia.

Función objetivo:

$$\max f(\vec{a},\vec{s}) = \max_{a_i \in A} \{ f_i(a_i) \}$$

$$f_i(a_i) = \sum_{j=1}^{n} p_j u_{i,j} \quad \forall a_i \in A$$

Acción óptima BAYES:

$$a^* = \underset{a_i \in A}{\operatorname{argmax}} \left\{ \sum_{j=1}^{n} p_j u_{i,j} \right\}$$

$$\vec{f}(\vec{a}) = (50.0, 40.5, 59.5, 47.0)$$

$$a^* = \underset{a_i \in A}{\operatorname{argmax}} \{ f_i(a_i) \} = a_3$$

$\vec{p}(S)$	0.2	0.3	0.4	0.1	
$U(A,S)$	s1	s2	s3	s4	$f_i(a_i)$
a1	100	60	30	0	50.0
a2	75	70	10	5	40.5
a3	55	30	80	75	**59.5**
a4	35	40	50	80	47.0
UIP	100	70	80	80	81

Tabla-5: Mejor acción bayesiana a priori (enfoque ganancias) sobre lanzamiento de un nuevo producto al mercado por parte de la empresa FHI.
UIP : Utilidad esperada con Información Perfecta (81)

Ejemplo 2. Resolución · Bayes sin experimentación (2)

Ejemplo 2 · Lanzamiento nuevo producto FHI · Resolución bayesiana · Frustraciones:

Los estados de la naturaleza están sujetos a una ley de probabilidad objetiva. Se selecciona la acción que minimiza la esperanza matemática de la frustración.

Función objetivo:

$$\min f(\vec{a},\vec{s}) = \min_{a_i \in A}\{f_i(a_i)\}$$

$$f_i(a_i) = \sum_{j=1}^{n} p_j v_{i,j} \quad \forall a_i \in A$$

Acción óptima BAYES:

$$a^* = \underset{a_i \in A}{\text{argmin}}\left\{\sum_{j=1}^{n} p_j v_{i,j}\right\}$$

$$\vec{f}(\vec{a}) = (31.0, 40.5, 21.5, 34.0)$$

$$a^* = \underset{a_i \in A}{\text{argmin}}\{f_i(a_i)\} = a_3$$

$\vec{p}(S)$	0.2	0.3	0.4	0.1	
$U(A,S)$	s1	s2	s3	s4	$f_i(a_i)$
a1	0	10	50	80	31.0
a2	25	0	70	75	40.5
a3	45	40	0	5	**21.5**
a4	65	30	30	0	34.0

Tabla-6: Mejor acción bayesiana a priori (enfoque frustraciones) sobre lanzamiento de un nuevo producto al mercado por parte de la empresa FHI.

PROTHIUS
Càtedra Organització Industrial

Ejemplo 3. Contexto



Características de un motor

1.- 747 piezas y 330 referencias en 6 versiones del motor diesel
2.- Nº de operaciones de Montaje: 378 (incluida la prueba rápida).
3.- Nº de operarios, para un turno de 135 motores: 42

Características de la fabricación

1.- Montaje: 9 tipos de motores de 3 familias: 4x4 (p1 a p3); furgonetas (p4, p5); camiones MT (p6 a p9).
2.- Nº de operaciones: 140. Atributos: temporales, espaciales y de riesgo
3.- Demanda diaria: 30 motores de cada tipo (instancia #1 Nissan-BCN), 2 turnos de 6h 45’ (8h): c=180 s.

Ejemplo 3. Presentación

Ejemplo 3 · Lanzamiento a línea de lote de componentes de motores · Enunciado:

A la estación K-10 de una línea de motores mixtos llega un lote de 10 componentes con fallo en traza. Se desconoce la procedencia del lote, aunque se sabe que puede tener dos orígenes: (s1) proveedor con 90% de piezas adecuadas o (s2) proveedor con 50% de piezas adecuadas. Si se lanza a línea un lote de procedencia s1 se tiene una ganancia de 2800 um, si se lanza un lote tipo s2 hay pérdidas por valor de 2000 um; si no se lanza el lote a línea hay una caída inmediata de producción valorada en 400 um.

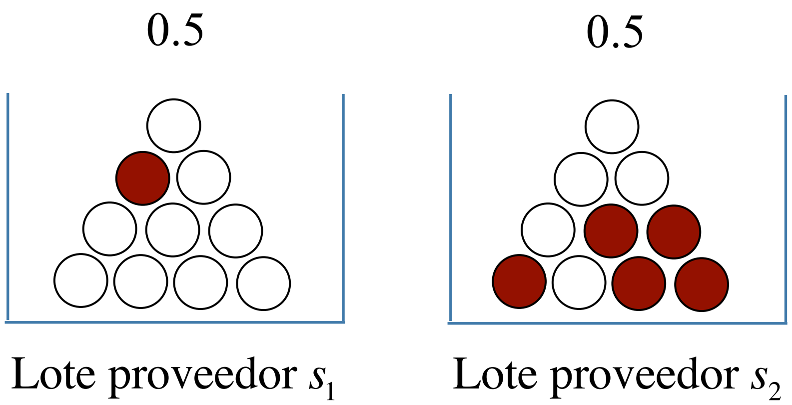

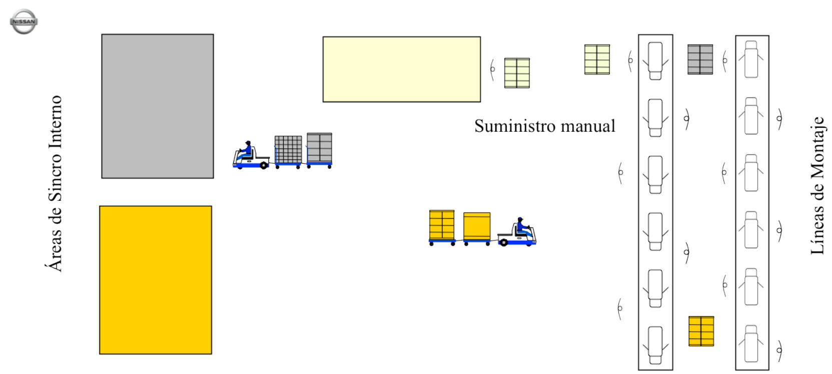

Ejemplo 3. Planteo

Ejemplo 3 · Lanzamiento a línea de lote de componentes de motores · Planteo:

Estación K-10 · Lote 10 componentes con fallo en traza · (s1) 90% (+) o (s2) 50% (+) · Lanzamiento lote: (s1) 2800 um, (s2) -2000 · Retención lote: -400 um.

Acciones:

a_1 : Lanzar lote a línea

a_2 : Retener lote y sustituir

Estados:

s_1 : Lote proveedor_1

s_2 : Lote proveedor_2

Probabilidades a priori:

$p_1 \equiv p(s_1) = 0.5$

$p_2 \equiv p(s_2) = 0.5$

$\vec{p}(S)$	0.5	0.5
$U(A,S)$	s1	s2
LANZAR	2800	-2000
RETENER	-400	-400
Máximo	2800	-400

Tabla-7: Utilidades acción-criterio y probabilidades sobre el lanzamiento a línea del lote de componentes de motores.

Ejemplo 3. Resolución Bayes sin experimentación

Ejemplo 3 · Lanzamiento a línea de lote de componentes de motores · Resolución:

Estación K-10 · Lote 10 componentes con fallo en traza · (s1) 90% (+) o (s2) 50% (+) · Lanzamiento lote: (s1) 2800 um, (s2) -2000 · Retención lote: -400 um.

Función objetivo:

$$\max f(\vec{a},\vec{s}) = \max_{a_i \in A}\{f_i(a_i)\}$$

$$f_i(a_i) = \sum_{j=1}^{n} p_j u_{i,j} \quad \forall a_i \in A$$

Acción óptima BAYES:

$$a^* = \underset{a_i \in A}{\operatorname{argmax}}\left\{\sum_{j=1}^{n} p_j u_{i,j}\right\}$$

$$\vec{f}(\vec{a}) = (400, -400)$$

$$a^* = \underset{a_i \in A}{\operatorname{argmax}}\{f_i(a_i)\} = a_1$$

$\vec{p}(S)$	0.5	0.5	
$U(A,S)$	s1	s2	$f_i(a_i)$
LANZAR	2800	-2000	**400**
RETENER	-400	-400	-400
UIP	2800	-400	1200

Tabla-8: Mejor acción bayesiana a priori (enfoque ganancias) sobre el lanzamiento a línea del lote de componentes de motores. UIP : Utilidad esperada con Información Perfecta (1200)

Decisiones en Universo probabilista con experimentación (1)

Procedimientos:

Sean :

S, A, X Conjuntos de acciones, $A = \{a_1,..,a_m\}$, estados, $S = \{s_1,..,s_n\}$, y resultados, $X = \{x_1,..,x_l\}$

i, j, k Índices de acciones $(a_i \in A)$, estados $(s_j \in S)$ y resultados $(x_k \in X)$

$u_{i,j}, v_{i,j}$ Utilidad (ganancia) y frustración normalizadas de la acción $a_i \in A$ ante el estado $s_j \in S$

$a^*(x_k)$ Acción óptima cuando el resultado del experimento es $x_k \in X$

$$\text{Probabilidades:}\left\{\begin{array}{llll} 1.\ \text{A priori:} & p(s_j) & \text{Conocidas} & \forall s_j \\ 2.\ \text{Condicionales:} & p(x_k/s_j) & \text{Conocidas} & \forall x_k, s_j \\ 3.\ \text{Marginales:} & p(x_k) & p(x_k) = \sum_{j=1}^{n} p(x_k/s_j)p(s_j) & \forall x_k \\ 4.\ \text{A posteriori:} & p(s_j/x_k) & p(s_j/x_k) = \dfrac{p(x_k/s_j)p(s_j)}{p(x_k)} & \forall s_j x_k \end{array}\right\}$$

Enfoque	*Función*	*Acción óptima dependiente* $x_k \in X$
Utilidad	$\max f(\vec{a},\vec{s},x_k) = \max_{a_i \in A}\left\{\sum_{j=1}^{n} p(s_j/x_k)u_{i,j}\right\}$	$a^*(x_k) = \operatorname{argmax}_{a_i \in A}\left\{\sum_{j=1}^{n} p(s_j/x_k)u_{i,j}\right\}$
Frustración	$\min f(\vec{a},\vec{s},x_k) = \min_{a_i \in A}\left\{\sum_{j=1}^{n} p(s_j/x_k)v_{i,j}\right\}$	$a^*(x_k) = \operatorname{argmin}_{a_i \in A}\left\{\sum_{j=1}^{n} p(s_j/x_k)v_{i,j}\right\}$

Nota: $\max_{a_i \in A}\left\{\sum_{j=1}^{n} p(s_j/x_k)u_{i,j}\right\} \Leftrightarrow \min_{a_i \in A}\left\{\sum_{j=1}^{n} p(s_j/x_k)v_{i,j}\right\}$

Ejemplo 3. Resolución Bayes con experimentación (1)

Ejemplo 3 · Lanzamiento a línea de lote de componentes de motores · Resolución:

Estación K-10 · Lote 10 componentes con fallo en traza · (s1) 90% (+) o (s2) 50% (+) · Lanzamiento lote: (s1) 2800 um, (s2) -2000 · Retención lote: -400 um · Experimento

Experimento: Extaer un componente del lote y hacer test · Resultados: $\left\{ \begin{array}{ll} x_1: & \text{Componente correcto} \\ x_2: & \text{Componente con defecto} \end{array} \right\}$

$$p(x_k) = \sum_{j=1}^{n} p(x_k/s_j)\, p(s_j)$$

$p(S)$	0.5	0.5	
$p(X/S)$	s1	s2	$p(X)$
CORRECTO	0.9	0.5	0.7
DEFECTO	0.1	0.5	0.3

Tabla-9: Probabilidades condicionales y marginales sobre el lanzamiento a línea de lote de componentes.

$$p(s_j/x_k) = p(x_k/s_j)\, p(s_j) / p(x_k)$$

	0.7	0.3	
$p(S/X)$	CORRECTO	DEFECTO	$p(S)$
s1	0.643	0.167	0.5
s2	0.357	0.833	0.5

Tabla-10: Probabilidades a posteriori de estados s1 y s2 en función del resultado del experimento (correcto / defecto).

Ejemplo 3. Resolución Bayes con experimentación (2)

Ejemplo 3 · Lanzamiento a línea de lote de componentes de motores · Resolución:

Estación K-10 · Lote 10 componentes con fallo en traza · (s1) 90% (+) o (s2) 50% (+) · Lanzamiento lote: (s1) 2800 um, (s2) -2000 · Retención lote: -400 um · Experimento

Experimento: Extaer un componente del lote y hacer test · Resultados: $\left\{ \begin{array}{ll} x_1: & \text{Componente correcto} \\ x_2: & \text{Componente con defecto} \end{array} \right\}$

$$a^*(x_1) = \underset{a_i \in A}{\text{argmax}} \left\{ \sum_{j=1}^{n} p(s_j/x_1) u_{i,j} \right\} \Rightarrow a^*(x_1) = a_1$$

$p(S/x_1)$	0.643	0.357	
$U(A,S)$	s1	s2	$f_i(a_i)$
LANZAR	2800	-2000	**1085.71**
RETENER	-400	-400	-400

Tabla-11: Mejor acción bayesiana a posteriori si el resultado del experimento es componente correcto

$$a^*(x_2) = \underset{a_i \in A}{\text{argmax}} \left\{ \sum_{j=1}^{n} p(s_j/x_2) u_{i,j} \right\} \Rightarrow a^*(x_2) = a_2$$

$p(S/x_2)$	0.167	0.833	
$U(A,S)$	s1	s2	$f_i(a_i)$
LANZAR	2800	-2000	-1200
RETENER	-400	-400	**-400**

Tabla-12: Mejor acción bayesiana a posteriori si el resultado del experimento es componente con defecto

PROTHIUS
Càtedra Organització Industrial

Decisiones en Universo probabilista con experimentación (2)

Valoración de la experimentación:

Elementos

S, A, X	Conjuntos de acciones, $A = \{a_1,..,a_m\}$, estados, $S = \{s_1,..,s_n\}$, y resultados, $X = \{x_1,..,x_l\}$
i, j, k	Índices de acciones $(a_i \in A)$, estados $(s_j \in S)$ y resultados $(x_k \in X)$
$u_{i,j}, v_{i,j}$	Utilidad (ganancia) y frustración normalizadas de la acción $a_i \in A$ ante el estado $s_j \in S$
$p(s)$	Probabilidad a priori asociada a la ocurrencia del estado $s_j \in S$
$p(x/s)$	Probabilidad de que se obtenga el resultado $x \in X$ condicionada al suceso $s \in S$
$p(x)$	Probabilidad de que se obtenga el resultado $x \in X$ independientemente del suceso
$p(s/x)$	Probabilidad a posteriori del suceso $s \in S$ cuando se obtiene el resultado $x \in X$

Valores

U_{IP}	Utilidad esperada con información perfecta:	$U_{IP} = \sum_{j=1}^{n} p(s_j) \max_{a_i \in A} \{u_{i,j}\}$
U_B	Utilidad esperada sin experimentación (BAYES):	$U_B = \max_{a_i \in A} \left\{ \sum_{j=1}^{n} p(s_j) u_{i,j} \right\}$
C_{IP}	Coste de la información perfecta:	$C_{IP} = U_{IP} - U_B$
U_E	Utilidad esperada con experimentación:	$U_E = \sum_{k=1}^{l} p(x_k) \max_{a_i \in A} \left\{ \sum_{j=1}^{n} p(s_j/x_k) u_{i,j} \right\}$
C_E	Coste de la experimentación:	$C_E = U_E - U_B$

Ejemplo 3. Valoración de la experimentación

Ejemplo 3 · Lanzamiento a línea de lote de componentes de motores · Valoración:

Valores :

1. Utilidad esperada con información perfecta:

$$U_{IP} = \sum_{j=1}^{n} p\left(s_j\right) \max_{a_i \in A} \left\{u_{i,j}\right\} = 0.5 \times 2800 + 0.5 \times (-400) = 1200$$

2. Utilidad esperada sin experimentación (BAYES):

$$U_B = \max_{a_i \in A} \left\{ \sum_{j=1}^{n} p\left(s_j\right) u_{i,j} \right\} = \max \left\{ \begin{matrix} 0.5 \times 2800 + 0.5 \times (-2000) \\ 0.5 \times (-400) + 0.5 \times (-400) \end{matrix} \right\} = \max\left\{400, -400\right\} = 400$$

3. Coste de la información perfecta:

$$C_{IP} = U_{IP} - U_B = 1200 - 400 = 800$$

4. Utilidad esperada con experimentación:

$$U_E = \sum_{k=1}^{l} p\left(x_k\right) \max_{a_i \in A} \left\{ \sum_{j=1}^{n} p\left(s_j / x_k\right) u_{i,j} \right\} = 0.7 \times 1085.71 + 0.3 \times (-400) = 640$$

5. Coste de la experimentación:

$$C_E = U_E - U_B = 640 - 400 = 240$$

Árboles de decisión. Concepto y reducción

Concepto: Grafo que despliega visualmente el problema y permite organizar los cálculos para el análisis de decisiones

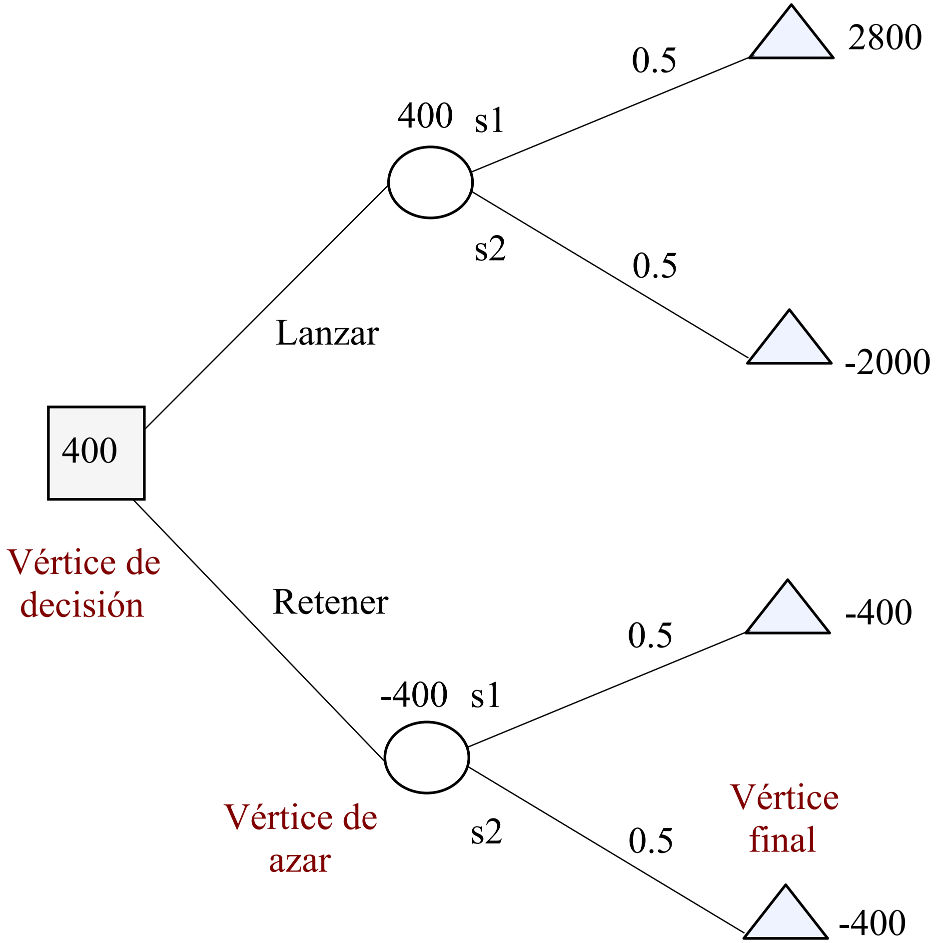

Evaluación y reducción del árbol:

Regla-1 (Vértice de azar):

A todo vértice extremo-origen de AZAR se le asigna la media ponderada (probabilidades) de las utilidades de los vértices extremos-destino.

Regla-2 (Vértice de decisión):

A todo vértice extremo-origen de DECISIÓN se le asigna el valor máximo (mínimo) de las utilidades (frustraciones) de los vértices extremos-destino.

Ejemplo 3. Árbol de decisión (1)

Construcción.

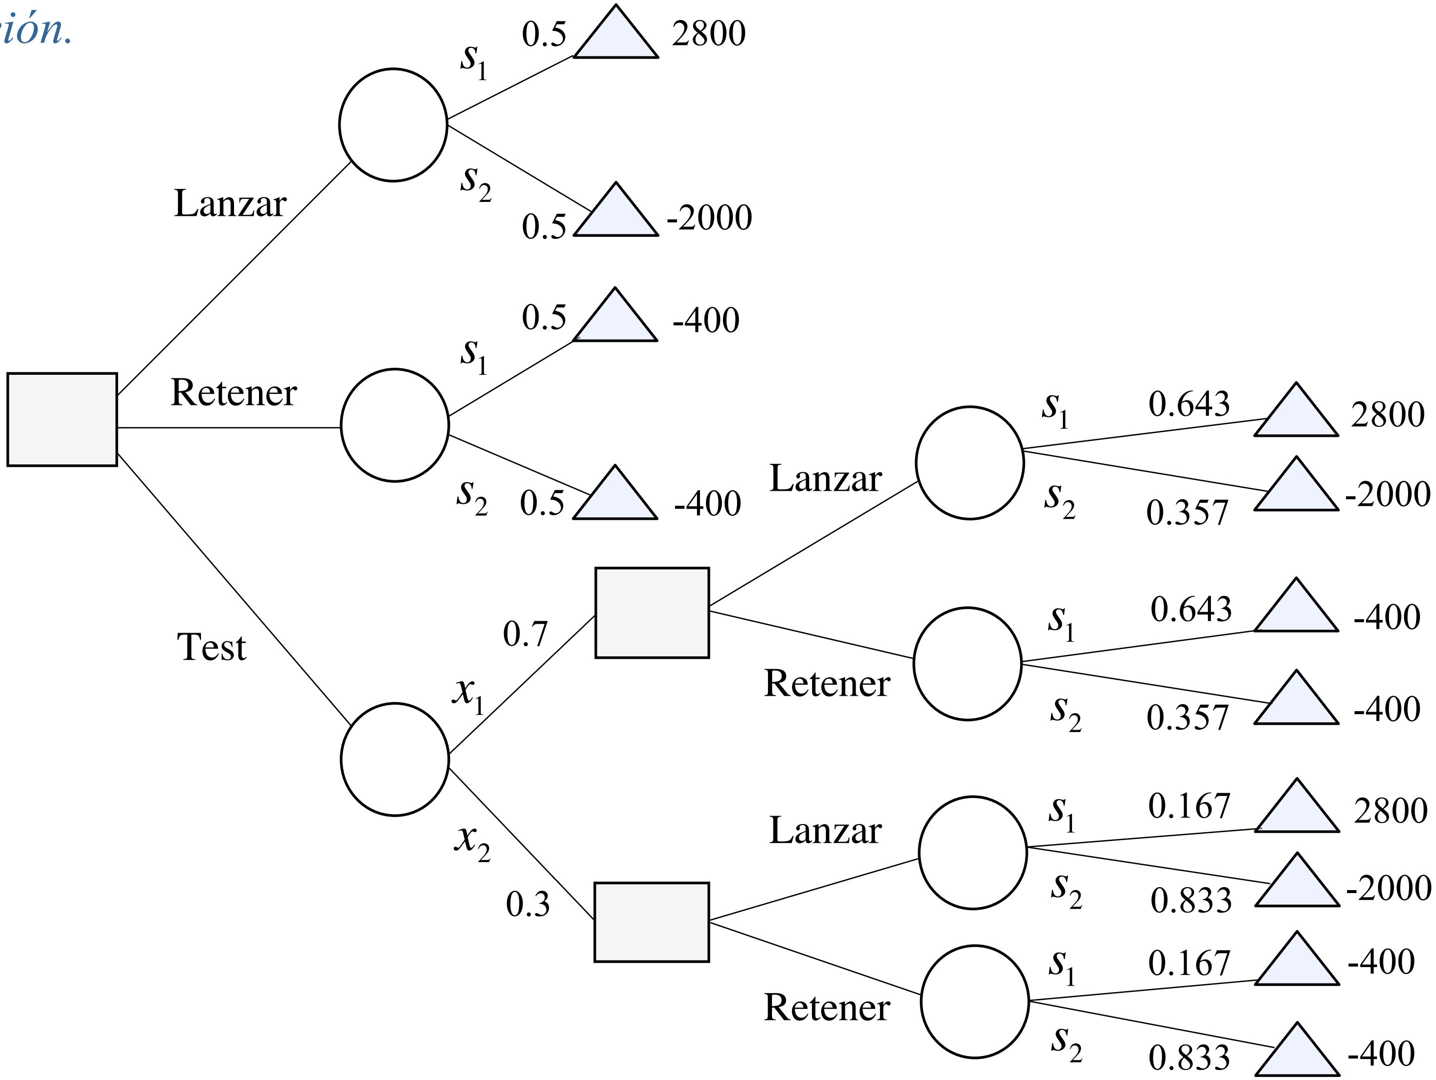

Ejemplo 3. Árbol de decisión (2)

Reducción_1.

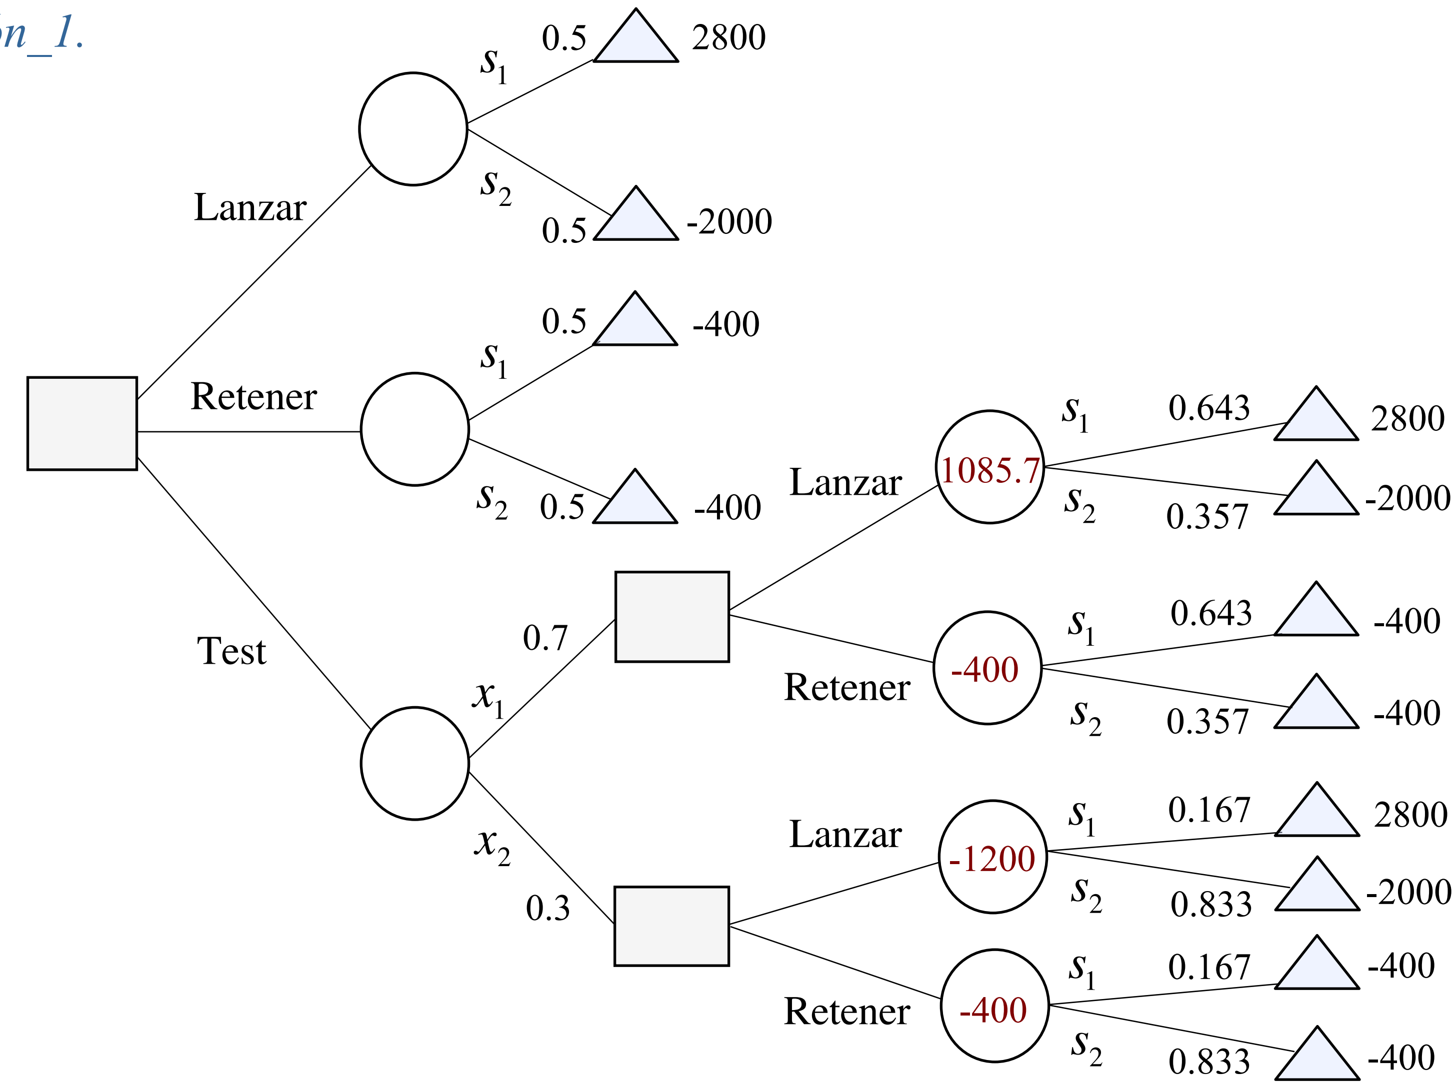

Ejemplo 3. Árbol de decisión (3)

Reducción_2.

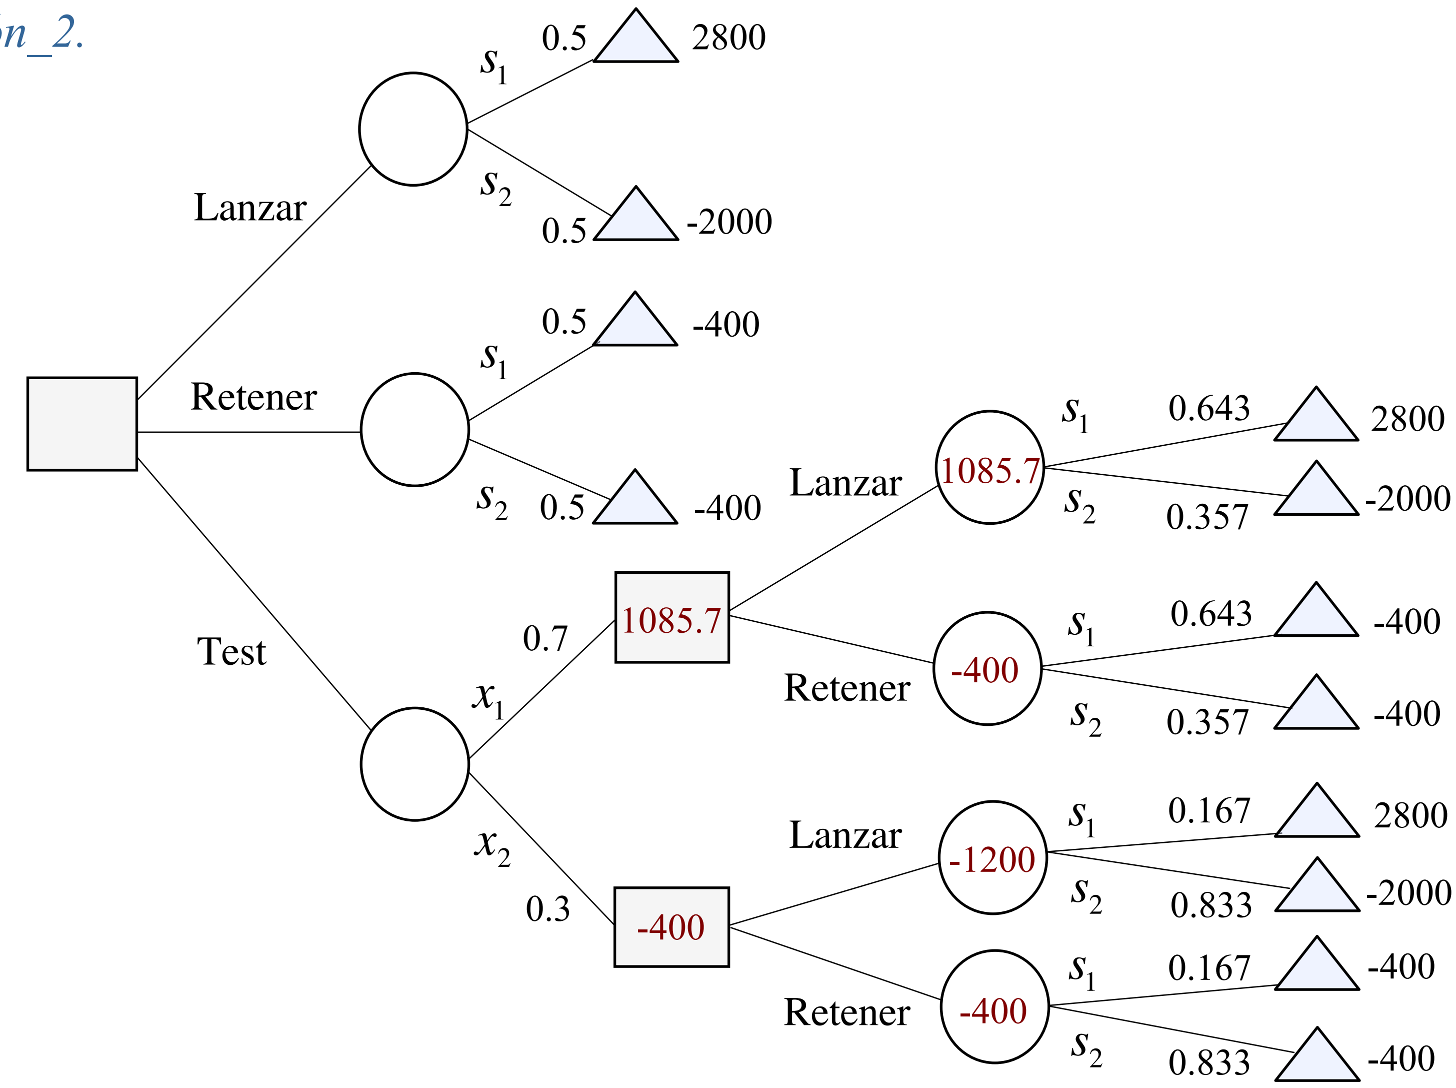

Ejemplo 3. Árbol de decisión (4)

Reducción_3.

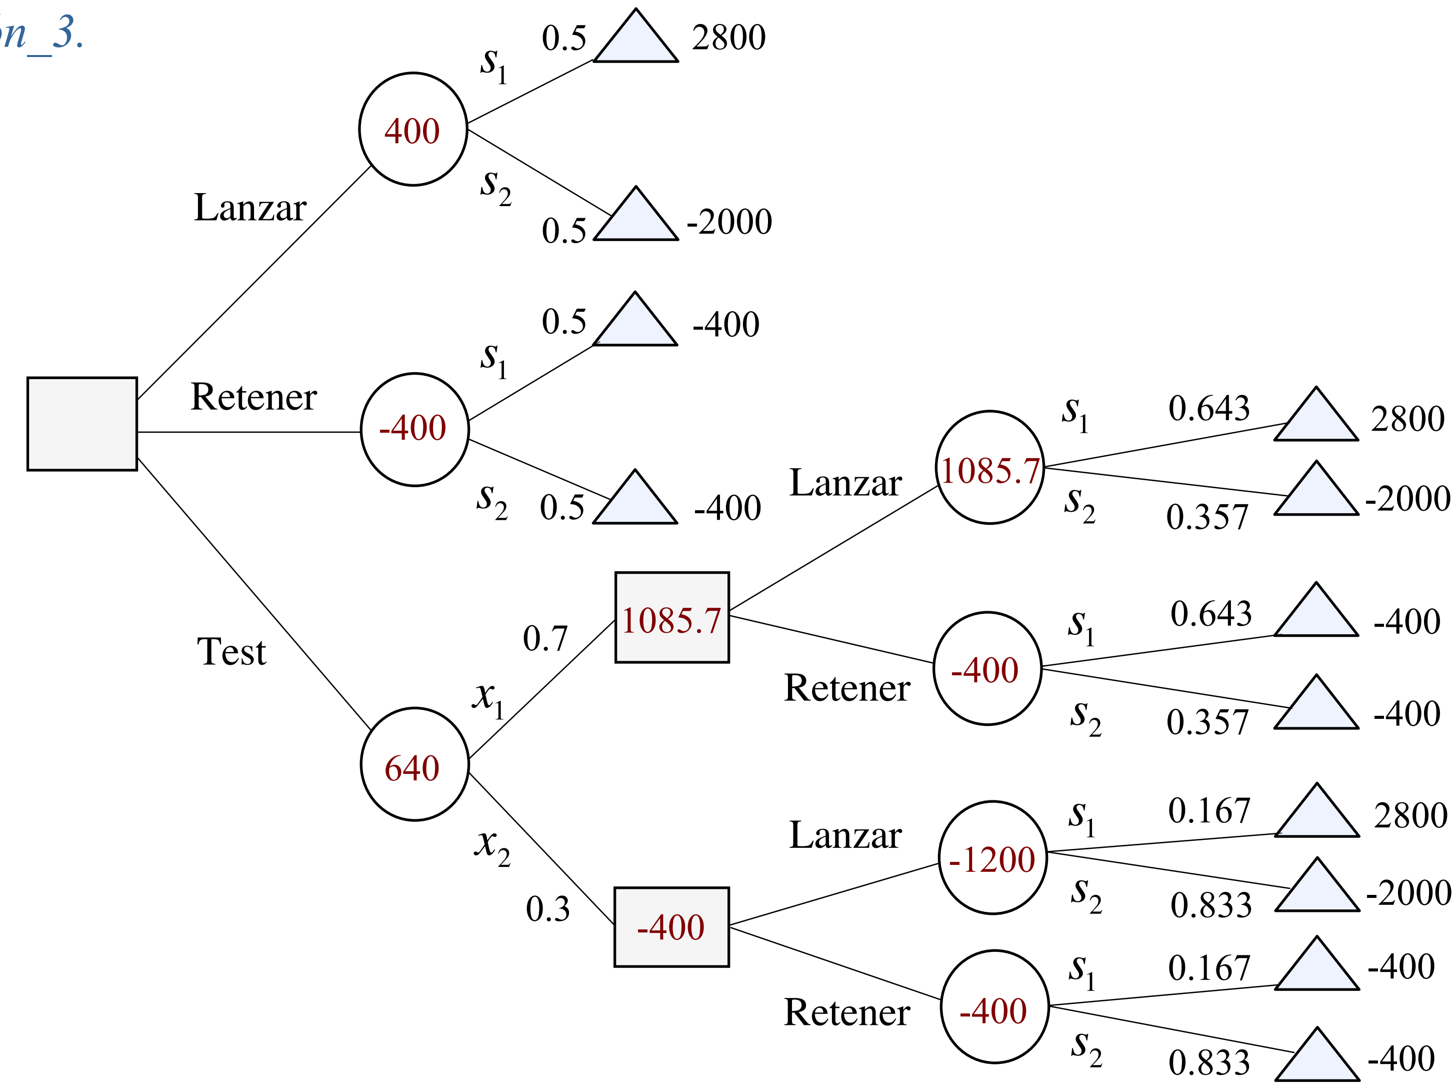

Ejemplo 3. Árbol de decisión (5)

Reducción_4. Acciones

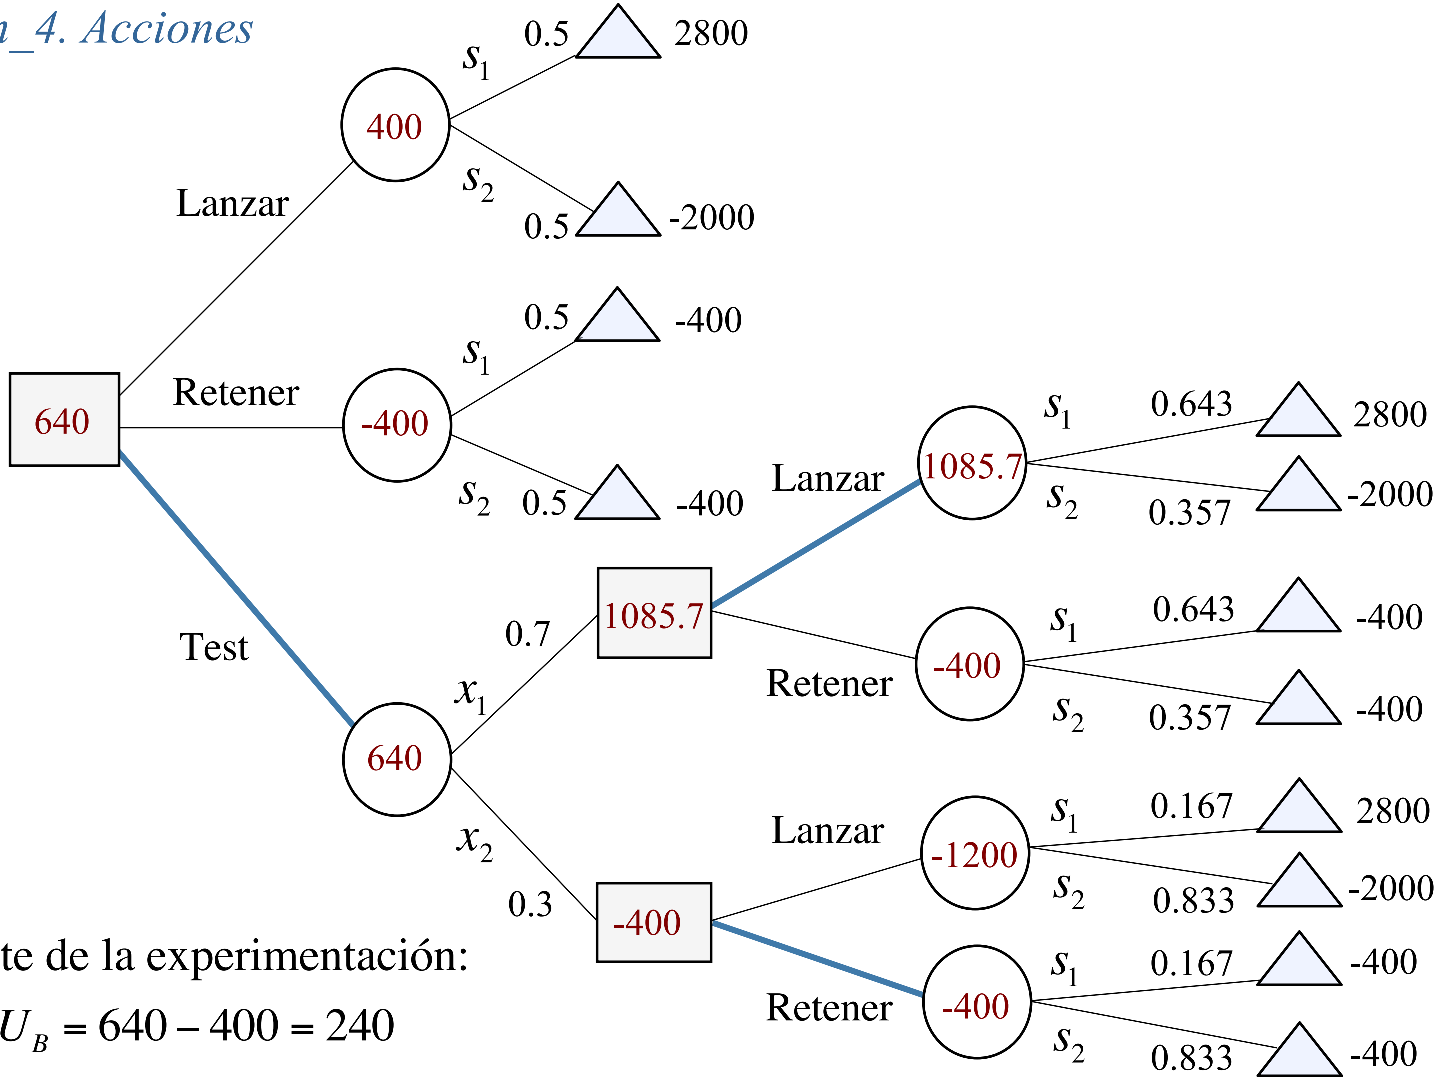

Coste límite de la experimentación:

$$C_E = U_E - U_B = 640 - 400 = 240$$

Incertidumbre o determinismo

"[...] Si concebimos una inteligencia que en un instante determinado abarca todas las relaciones entre todos los entes del universo -una inteligencia lo suficientemente amplia que permitiera someter estos datos al análisis- ésta podría establecer las posiciones respectivas, el movimiento y las propiedades generales de todos estos entes, desde los mayores cuerpos del universo al menor de los átomos; para ella nada sería incierto y el futuro así como el pasado estarían presentes ante sus ojos."

Pierre-Simon Laplace (1814)

Ensayo filosófico sobre las probabilidades