



INSTITUTO POLITÉCNICO NACIONAL

CENTRO DE INVESTIGACIÓN EN COMPUTACIÓN

**CARACTERIZACIÓN Y PONDERACIÓN
DE PROPIEDADES LÓGICAS SOBRE
VALORES CUALITATIVOS ORGANIZADOS
EN JERARQUÍAS.**

T E S I S

**QUE PARA OBTENER EL GRADO DE
DOCTOR EN CIENCIAS DE LA COMPUTACIÓN**

**PRESENTA LA
M. EN C. EDITH ADRIANA JIMÉNEZ CONTRERAS**

DIRECTORES:

**DR. ADOLFO GUZMÁN ARENAS
DR. SERGUEI PAVLOVICH LEVACHKINE**

MÉXICO, D.F., FEBRERO 2013





INSTITUTO POLITÉCNICO NACIONAL
SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

SIP-14

ACTA DE REVISIÓN DE TESIS

En la Ciudad de México, D. F. siendo las 12:00 horas del día 19 del mes de Junio de 2009 se reunieron los miembros de la Comisión Revisora de Tesis designada por el Colegio de Profesores de Estudios de Posgrado e Investigación del:

Centro de Investigación en Computación

para examinar la tesis de grado titulada:

“CARACTERIZACIÓN Y PONDERACIÓN DE PROPIEDADES LÓGICAS SOBRE VALORES CUALITATIVOS ORGANIZADOS EN JERARQUÍAS”

Presentada por la alumna:

JIMENEZ

CONTRERAS

EDITH ADRIANA

Apellido paterno

Materno

nombre(s)

Con registro:

A	0	5	0	8	1	7
---	---	---	---	---	---	---

aspirante al grado de: **DOCTORADO EN CIENCIAS DE LA COMPUTACIÓN**

Después de intercambiar opiniones los miembros de la Comisión manifestaron **SU APROBACIÓN DE LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

LA COMISIÓN REVISORA

Presidente

Dr. Jesús Guillermo Figueroa Nazuno

Secretario

Dr. José de Jesús Medel Juárez

Primer vocal
(Director de Tesis)

Dr. Adolfo Guzmán Arenas

Segundo vocal
(Director de Tesis)

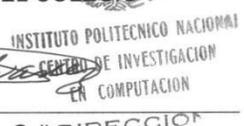
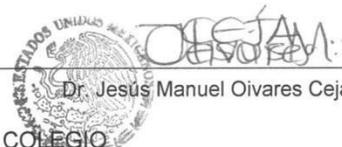
Dr. Serguei Pavlovich Levahckine

Tercer vocal

Dr. Jesús Manuel Oivares Ceja

EL PRESIDENTE DEL COLEGIO

Dr. Jaime Álvarez Gallegos





INSTITUTO POLITÉCNICO NACIONAL
SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

CARTA CESIÓN DE DERECHOS

En la Ciudad de México D.F. el día 31 del mes de octubre del año 2012, el (la) que suscribe Edith Adriana Jiménez Contreras alumno (a) del Programa de Doctorado en Ciencias de la Computación con número de registro A050817, adscrito al Centro de Investigación en Computación, manifiesta que es autor (a) intelectual del presente trabajo de Tesis bajo la dirección de Dr. Adolfo Guzmán Arenas y el Dr. Serguei Pavlovich Levachkine y cede los derechos del trabajo intitulado Caracterización y Ponderación de Propiedades Lógicas sobre Valores Cualitativos Organizados en Jerarquías, al Instituto Politécnico Nacional para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, gráficas o datos del trabajo sin el permiso expreso del autor y/o director del trabajo. Este puede ser obtenido escribiendo a la siguiente dirección dyidyia@yahoo.com, edithajc@hotmail.com. Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.

Edith Adriana Jiménez Contreras

AGRADECIMIENTOS

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por su apoyo y patrocinio en la realización de este trabajo.

También quiero agradecer al Centro de Investigación en Computación (CIC), por darme la oportunidad de realizar mis estudios en esta institución.

A mi director de tesis Adolfo Guzmán Arenas, por brindarme la confianza para poder desarrollar este trabajo. Así mismo, por haber sido un excelente guía y haber tenido la dedicación para hacer las revisiones pertinentes a esta tesis, que fueron puliendo este trabajo.

De la misma manera, quiero agradecer al Dr. Serguei Pavlovich Levachkine, por su ayuda y colaboración en este trabajo.

A mis sinodales Gilberto Lorenzo Martínez Luna, Jesús Manuel Olivares Ceja y José de Jesús Medel Juárez, quienes me asesoraron y apoyaron durante el desarrollo de este trabajo.

Resumen

El principal objetivo de este trabajo **CARACTERIZACIÓN Y PONDERACIÓN DE PROPIEDADES LÓGICAS SOBRE VALORES CUALITATIVOS ORGANIZADOS EN JERARQUÍAS** es calcular el grado de inconsistencia de una bolsa de afirmaciones y también de una bolsa de objetos que encapsulan afirmaciones.

Aquí se tiene un evento del cual se quiere determinar el valor de una variable cualitativa (o característica, o rasgo, o variable lingüística), por ejemplo la religión de Pedro. Varios observadores reportan el valor que ellos ven. Curiosamente, las observaciones no coinciden, pero los observadores no son mentirosos. La explicación es que la precisión de ellos puede variar, debido al método que usaron para percibir lo solicitado (la religión de Pedro). Se quiere determinar el “consenso” o valor más plausible, dado el conjunto (de hechos, una bolsa) de valores observados; es decir, a partir de la información disponible. Además, se desea determinar qué tan divergentes o inconsistentes son estos valores, es decir, se desea cuantificar su inconsistencia.

También se estudiará el caso en el cual se desean observar varias características de un mismo objeto. En este caso, los observadores reportan objetos, y se quiere hallar el objeto que mejor los representa –llamado consenso- y la inconsistencia de una bolsa de objetos. En este caso, el consenso de una bolsa de objetos es el objeto de la bolsa que mejor representa a toda la bolsa.

Palabras clave: F.4 LOGICA MATEMATICA Y LENGUAJES FORMALES, H.3 ALMACENAMIENTO Y RECUPERACION DE INFORMACION, I.2.3 Deducción y Prueba del Teorema, I.2.4 Formalismos y Métodos de Representación del Conocimiento, confusión total, confusión promedio, centroide, outlier, inconsistencia.

Abstract

The main objective of this work CHARACTERIZATION AND PONDERATION OF LOGIC PROPERTIES ABOUT QUALITATIVE VALUES ORGANIZED IN HIERARCHIES is to compute the degree of inconsistency of a bag of statements and also of a bag of objects that possess several properties, available as statements.

Here there is an event to determine the value of a qualitative variable (or characteristic, or trait, or linguistic variable), e.g. Pedro's religion. Several observers reported their observation. Curiously, the observations don't match. But the observers aren't liars. The explanation is that the accuracy of the observers may vary due to the method they used to receive the request (Peter's religion). In this work, it wants to determine the "consensus" or the value more plausible, since all (in fact, a bag) of values observed. Furthermore, determine the divergence of inconsistency from those values. That's to say, quantify their inconsistency.

Also the thesis, studies the case to observe several characteristics of a same object. In this case, the observers report objects, and it want to find the object that represents its –called consensus- and the inconsistency of a bag of objects.

Keywords: F.4 MATHEMATICAL LOGIC AND FORMAL LANGUAGES, H.3 INFORMATION STORAGE AND RETRIEVAL, I.2.3 Deduction and Theorem Proving, I.2.4 Knowledge Representation Formalisms and Methods, total confusion, average confusion, centroid, outlier, inconsistency.

CONTENIDO

LISTA DE FIGURAS.....	V
LISTA DE TABLAS.....	VII
GLOSARIO	VIII
CAPÍTULO 1. INTRODUCCIÓN.....	1
1.1 ANTECEDENTES	2
1.2 JUSTIFICACIÓN	5
1.3 TESIS (LOGROS O CONTRIBUCIONES ORIGINALES DE ESTE TRABAJO).....	6
1.4 OBJETIVO GENERAL	7
La tesis desarrollará la solución a los siguientes problemas:	7
1.5 ALCANCES	8
1.6 ORGANIZACIÓN DEL TRABAJO.....	9
1.7 CONTRIBUCIONES ORIGINALES	11
1.8 SOLUCIÓN	12
<i>Problema 1. Medir la inconsistencia de un conjunto de afirmaciones y hallar el valor más plausible (aceptable), al que se le llamará centroide o consenso.</i>	13
<i>Problema 2. Hallar uno o más centroides cuando el problema permite que haya más de uno.</i>	13
<i>Problema 3. Cálculo incremental de la inconsistencia.</i>	14
<i>Problema 4. Detectando y eliminando la afirmación que más contribuye a la inconsistencia.</i>	14
<i>Problema 5. Análisis de afirmaciones empaquetadas en objetos.</i>	14
CAPÍTULO 2. ESTADO DEL ARTE	16
2.1 LÓGICA DE PRIMER ORDEN.....	16
2.2 LÓGICA PARACONSISTENTE	19
<i>Lógica multi-valuada</i>	20
2.3 LA TEORÍA MATEMÁTICA DE LA EVIDENCIA	22
2.4 LÓGICA DIFUSA	26
2.5 TEORÍA DE KRIPKE.....	27
<i>Intuiciones de Kripke</i>	28
<i>Puntos fijos</i>	29
<i>El criterio significativo oracional expuesto por Kripke</i>	29
2.6 REDES SEMÁNTICAS.....	30
2.7 TEOREMA DE ARROW.....	32
2.8 ANÁLISIS DE CLUSTER O RECONOCIMIENTO DE PATRONES	37
CAPÍTULO 3. FUNDAMENTOS TEÓRICOS.....	39
3.1 TEORÍA DE LA MEDIDA	39
3.2 LA INCONSISTENCIA	42
<i>Actuando en presencia de la inconsistencia</i>	44
<i>Ignorar, resolver o rechazar la inconsistencia</i>	44
3.3 JERARQUÍAS Y CONFUSIÓN	45
<i>Concepto de jerarquía</i>	45
Tipos de jerarquías	46
<i>Propiedades y funciones en jerarquías</i>	47
<i>Confusión no normalizada en utilizar r en lugar de s para jerarquías simples</i>	47
CAPÍTULO 4. MODELO PARA MEDIR LA INCONSISTENCIA DE UNABOLSA DE VALORES CUALITATIVOS.....	48
4.1 DESCRIPCIÓN FORMAL DEL MODELO DE INCONSISTENCIA (MI)	50
4.2 ANÁLISIS EXPERIMENTAL	57

Experimento 1	57
CAPÍTULO 5. ENCONTRANDO VARIOS CENTROIDES.....	72
5.1 TÉCNICAS PARA ENCONTRAR CÚMULOS.....	73
CAPÍTULO 6. ACTUALIZACIÓN DE INCONSISTENCIA CUANDO LLEGA UNA AFIRMACIÓN NUEVA.....	86
CAPÍTULO 7. ENCONTRANDO INCONSISTENCIA CUANDO SE ELIMINA EL GREATEST OUTLIER.....	97
CAPÍTULO 8. MEDICIÓN DE INCONSISTENCIA ENTRE OBJETOS	102
CAPÍTULO 9. ARQUITECTURA DE LA IMPLEMENTACIÓN DEL SOFTWARE PARA MEDIR INCONSISTENCIA.....	119
CAPÍTULO 10. CONCLUSIONES	123
BIBLIOGRAFÍA.....	124

LISTA DE FIGURAS

Figura 1. Bosquejo general del modelo de inconsistencia cuando se trata de afirmaciones o de objetos.	12
Figura 2. Representación de una red semántica.	31
Figura 3. Jerarquía de Transporte.	37
Figura 4. Jerarquía de algunos animales.	47
Figura 5. Esquema del cálculo de inconsistencia de una bolsa de valores cualitativos.	50
Figura 6. En el inciso (a) se muestra que h_a es descendente de h_b y $CONF(h_a, h_b) = 0$. En (b) se puede observar que h_a es ascendente de h_b y $CONF(h_a, h_b) = 1$	51
Figura 7. Jerarquía de algunos lugares del mundo donde cada asterisco representa una observación sobre el sitio indicado.	61
Figura 8. Especificación en XML que representa la jerarquía de mascotas.	63
Figura 9. Jerarquía elegida y pantalla de captura para elegir jerarquía, valores cualitativos y número de observaciones.	64
Figura 10. Pantalla para calcular el valor más plausible de una bolsa de afirmaciones.	65
Figura 11. Matriz que muestra la $conf(r,s)$ y la confusión total, donde r representa a la fila y s a la columna.	65
Figura 12. Estos datos representan la confusión promedio por cada valor cualitativo.	66
Figura 13. Jerarquía de algunos animales.	68
Figura 14. Especificación en XML que representa a la jerarquía de mascotas.	69
Figura 15. Matriz que muestra la $conf(r,s)$ y la confusión total.	69
Figura 16. Pantalla que muestra entre otras cosas el centroide de la bolsa de vc_i	70
Figura 17. Esquema del cálculo de inconsistencia sobre cúmulos.	72
Figura 18. Bosquejo del cálculo de inconsistencia cuando se agrega una nueva afirmación.	86
Figura 19. Jerarquía de algunos animales que incluye la nueva observación.	90
Figura 20. Pantallas para agregar nueva observación.	95
Figura 21. Matriz de confusiones e inconformidades que presenta cada afirmación.	96
Figura 22. Jerarquía de algunos transportes, donde cada símbolo * representa una observación sobre dicho valor cualitativo.	98
Figura 23. En esta jerarquía los nodos con el símbolo * representa una observación sobre ese vc_i	100
Figura 24. Bosquejo de la manera en que se calcula la inconsistencia de una bolsa de objetos. ...	102
Figura 25. Jerarquías de valores cualitativos que representan animales, transportes y religiones.	108
Figura 26. Representación de las jerarquías Mascota, Transporte y Religión en formato XML.	109
Figura 27. Pantalla para capturar las propiedades de la bolsa de objetos.	110
Figura 28. Pantalla para agregar valor de las propiedades de cada objeto.	111
Figura 29. Pantalla que ayuda a realizar el cálculo de inconsistencia.	111
Figura 30. Pantalla de inconformidades de cada objeto.	112
Figura 31. Pantalla que imprime el valor de inconsistencia de la bolsa de objetos.	112
Figura 32. Jerarquías que Escolaridad y Partidos Políticos.	114
Figura 33. Representación en XML de las jerarquías Escolaridad y Partidos Políticos.	114
Figura 34. Pantalla para capturar las propiedades de los objetos de la bolsa.	115
Figura 35. Pantalla para calcular la inconsistencia de la BO.	115
Figura 36. Pantalla que muestra la confusión total de cada objeto.	116

Figura 37. Comparación de OxO sobre una BO donde se aprecia claramente, los objetos a medir, las jerarquías utilizadas, las propiedades de cada objeto y la confusión promedio. 117

Figura 38. Esta imagen presenta la inconsistencia de la bolsa y los centroides que aparecieron en ella. 118

Figura 39. Esquema de la implementación del análisis para medir inconsistencia. 122

LISTA DE TABLAS

Tabla 1. Matriz de $\text{Conf}(r,s)$ y confusiones totales por cada vc_i .	62
Tabla 2. Matriz de $\text{conf}(r,s)$ de votantes fuertes.	73
Tabla 3. Matriz de $\text{conf}(r,s)$ de votantes débiles.	74
Tabla 4. Matriz de $\text{conf}(r,s)$ de un cluster creado con dos votantes indecisos.	75
Tabla 5. Matriz de $\text{conf}(r,s)$ de un cluster creado más un votante indeciso.	75
Tabla 6. Matriz de $\text{conf}(r,s)$ de un cluster con un votante fuerte y uno indeciso.	75
Tabla 7. Matriz de $\text{conf}(r,s)$ de un cluster con un votante fuerte y dos indecisos.	76
Tabla 8. Matriz de $\text{conf}(r,s)$ de un cluster con un votante fuerte y uno indeciso.	76
Tabla 9. Representación en forma general de cómo se calculan las confusiones de cada vc_i .	77
Tabla 10. Matriz de confusiones del primer ejemplo de este trabajo.	78
Tabla 11. Matriz de $\text{conf}(r,s)$ de un bloque con un votantes indecisos.	79
Tabla 12. Matriz de $\text{conf}(r,s)$ de un bloque con un votantes indecisos.	80
Tabla 13. Matriz de $\text{conf}(r,s)$ de un bloque con un votantes indecisos.	81
Tabla 14. Matriz de $\text{conf}(r,s)$ de un bloque con un votantes fuertes.	81
Tabla 15. Matriz de $\text{conf}(r,s)$ del cluster {Distrito_Federal, Texas, Estados_Unidos, La_Gloria, Perote, California}.	82
Tabla 16. Matriz de $\text{conf}(r,s)$ del cúmulo {Texas, Estados_Unidos, California}.	83
Tabla 17. Matriz de $\text{conf}(r,s)$ del cluster {Texas, Estados_Unidos, La_Gloria, Perote}.	84
Tabla 18. Matriz de $\text{conf}(r,s)$ del cluster {Texas, Estados_Unidos, La_Gloria, Perote, California}.	84
Tabla 19. Matriz de $\text{conf}(r,s)$ del cluster {Distrito_Federal, Texas, Estados_Unidos, La_Gloria, California, Perote}.	84
Tabla 20. Actualización de la bolsa de afirmaciones	91
Tabla 21. Actualización de la bolsa de afirmaciones	92
Tabla 22. Resultados de confusión total por cada valor cualitativo.	93
Tabla 23. Resultados de inconformidades sobre la bolsa de afirmaciones.	93
Tabla 24. Resultado de calcular la confusión de cada valor cualitativo en la bolsa.	98
Tabla 25. Tabla resultante cuando se descarta al valor cualitativo Globo, generando una nueva bolsa.	99
Tabla 26. Matriz de valores cuando se elimina Embarcación.	99
Tabla 27. Matriz de confusiones con solo dos valores cualitativos.	99
Tabla 28. Confusiones individuales, totales y promedio de cada vc_i .	100
Tabla 29. Resultado de confusiones totales y promedio cuando se elimina vc_2 .	101

Glosario

Afirmación (o valor) más disparatado (The greatest outlier). Corresponde al valor más alejado del centroide de la bolsa, el valor que más “choca” con el sentir promedio de los observadores de la bolsa. Y se calcula viendo cuál s maximiza $\text{conf}(r^*, s)$ donde r^* es el centroide de la bolsa.

Altura de una jerarquía. Es el número de niveles totales que tiene la jerarquía. Por ejemplo, la jerarquía de la figura 4 tiene 4 niveles por lo que $h = 4$.

Bolsa de objetos. Es una bolsa compuesta por objetos denotada por $BO = \{O_1, O_2, \dots, O_n\}$, donde cada objeto está formado por m pares (propiedad, valor), como $(p_1, vc_1), (p_2, vc_2), \dots, (p_m, vc_m)$, el subíndice m representa el número de objeto, n el número de valor cualitativo.

Bolsa de valores cualitativos. Se define a B como una bolsa de valores cualitativos y se denota por

$$B = \{vc_1, vc_2, \dots, vc_{n-1}, vc_n\},$$

Donde existe un vc_i (valor cualitativo) que representa a una y solo una a_i (caso 1) o que representa a una o más a_i (caso 2).

Centroide de una bolsa de valores cualitativos. Una bolsa $B = \{vc_1, vc_2, \dots, vc_{n-1}, vc_n\}$, se define como el elemento vc_i de la bolsa que minimiza la confusión promedio.

$$r^* = \frac{\min \left[\sum_{i=1}^n \text{conf}(vc_1, vc_i), \sum_{i=1}^n \text{conf}(vc_2, vc_i), \dots, \sum_{i=1}^n \text{conf}(vc_{n-1}, vc_i), \sum_{i=1}^n \text{conf}(vc_n, vc_i) \right]}{O_T}$$

También se llama r^* o consenso. Es el valor que menos descontento o confusión (total o promedio) produce en los elementos de la bolsa. Es el valor más plausible si la única información que tenemos son las afirmaciones de la bolsa. Es similar al centro de gravedad de un conjunto de números.

Centroide (en BO). El centroide de una bolsa de objetos (también llamado objeto centroide) $BO = \{O_1, O_2, \dots, O_n\}$ se representa por O^* y es el valor más plausible si la única información que tenemos son las afirmaciones (expresadas como objetos) de la bolsa.

Confusión no normalizada. Si $r, s \in H$, entonces la confusión de utilizar r en lugar de s , escrita como $\text{conf}(r, s)$, es :

- $CONF(r, r) = CONF(r, s) = 0$, donde s es cualquier ascendente de r ;
- $CONF(r, s) = 1 + CONF(r, father_of(s))$.

La medida CONF, cuenta las ligas descendentes desde r a s .

Confusión (normalizada). Ésta se define como:

$$conf(r, s) = \frac{CONF(h_a, h_b)}{h}$$

Representa el descontento o disconformidad que se observa o se produce, cuando dan un valor h_a , siendo que el valor deseado era h_b . Por ejemplo, $conf(perro, animal)$ utilizando la jerarquía de la figura 4, donde la altura de la jerarquía es $h=4$ es:

$$conf(perro, animal) = \frac{CONF(perro, animal)}{h} = \frac{0}{4} = 0.$$

Confusión entre dos objetos. La confusión de usar un objeto O_r en lugar de un objeto O_s se calcula como:

$$\begin{aligned} conf(O_r, O_s) &= \frac{conf(vc_{r,1}, vc_{s,1}) + conf(vc_{r,2}, vc_{s,2}) + \dots + conf(vc_{r,n}, vc_{s,n})}{n(P)} \\ &= \frac{\sum_{i=1}^n conf(vc_{r,i}, vc_{s,i})}{n(P)}, \end{aligned}$$

donde $n(P)$ denota el número de propiedades del objeto.

Se compara el valor de la primera propiedad entre ambos objetos, en seguida el segundo valor de la segunda propiedad entre los objetos, y así para los demás valores que conforman los objetos, entonces se obtiene la suma de cada propiedad dividida por el número de propiedades totales.

Confusión total (en B). La confusión total que un valor cualitativo vc_i produce en $B = \{vc_1, vc_2, \dots, vc_{n-1}, vc_n\}$ es:

$$conf(vc_i, vc_1) + conf(vc_i, vc_2) + \dots + conf(vc_i, vc_i) + \dots + conf(vc_i, vc_n).$$

El descontento total de los elementos de la bolsa; es decir, la suma de los descontentos de cada uno de los miembros vc_1, vc_2, \dots, vc_n cuando se escoge vc_i en lugar de cada uno de ellos.

Confusión total (en una BO). La confusión total que O_i produce en $BO = \{O_1, O_2, \dots, O_n\}$ es:

$$\begin{aligned} & \frac{\text{conf}(vc_{i,1}, vc_{1,1}) + \text{conf}(vc_{i,2}, vc_{2,2}) + \dots + \text{conf}(vc_{i,i}, vc_{i,i}) + \dots + \text{conf}(vc_{i,n}, vc_{n,n})}{n(P)} \\ &= \text{conf}(O_i, O_1) + \text{conf}(O_i, O_2) + \dots + \text{conf}(O_i, O_n) \\ &= \sum_{j=1}^n \text{conf}(O_i, O_j). \end{aligned}$$

Es el descontento total de los objetos de la bolsa; es decir, la suma de cada uno de los descontentos de O_1, O_2, \dots, O_n , cuando se elige O_i en lugar de cada uno de ellos.

Confusión promedio (en B). Confusión total dividida por el número de observaciones (O_T) de la bolsa de vc_i . Para el centroide r^* su valor se calcula enseguida:

$$r^* = \frac{\min \left[\sum_{i=1}^n \text{conf}(vc_1, vc_i), \sum_{i=1}^n \text{conf}(vc_2, vc_i), \dots, \sum_{i=1}^n \text{conf}(vc_{n-1}, vc_i), \sum_{i=1}^n \text{conf}(vc_n, vc_i) \right]}{O_T}.$$

La confusión promedio para el r^* , cuyo valor será el vc_i que nos dio la confusión total mínima, se interpretará como vc_i que representa a la a_i afirmación que mejor modela el evento E.

Confusión promedio (en BO). La confusión promedio de cada objeto en la bolsa es la confusión total que cada objeto produce dividida por el número de objetos de la bolsa representados por k.

Escenario. Se tiene un evento o hecho (digamos de Juan Pérez) que se describe mediante variables cualitativas. Nos fijamos en una de ellas –el color del cabello de Juan. (Esto será una variable cualitativa). Hay varios observadores que van a mirar el color del cabello de Juan Pérez. Lo que reportan no es un número (no van a medir el color del pelo, sino lo van a ver), sino un valor simbólico: negro, café, rubio. Previo a ir a verle el cabello, se ponen de acuerdo en el contexto o lenguaje que van a usar para reportar colores. Por ejemplo, no admiten el color “fucsia”. Estos valores forman el contexto que es común a esos observadores. Estos valores se van a arreglar o colocar en una jerarquía. Ahora bien, de los varios observadores que miran (observan) esa variable, no todos reportan el mismo valor simbólico. Unos dicen que es negro; otros, es muy negro; Otros, es café. Uno dice que es rojo. Estas discrepancias o inconsistencias no se deben a que los observadores tengan cierta tendencia a decir mentiras (lo que se maneja con la teoría de la evidencia de

Dempster-Schafer) ni a que “no estén seguros” de lo que vieron (lo que se puede manejar con conjuntos difusos). Tampoco es sensato descartarlos y decirles “no les creo a ninguno de ustedes, puesto que me traen resultados inconsistentes” (como lo haría la lógica formal). Debido a que los observadores son creíbles (todos dicen la verdad, o creen decirla), la diferencia de sus observaciones se debe a la distinta precisión o exactitud de su método de observación. Uno dijo que la mascota de Juan era un perro, porque lo oyó ladrar; el otro vio pelos en la puerta de la casa de Juan, y reporta que era un mamífero; otro vio al perro de lejos, y le pareció un Pastor Alemán. Otro lo examinó a detalle, lo tocó: Dijo que era un Doberman hembra.

Por lo que se tiene un conjunto de afirmaciones (cada afirmación es el resultado de una observación) que son del tipo $var = val$, donde var es la misma para todas las afirmaciones, pero val no lo es. (Puede haber dos val iguales, o sea dos observadores que reportaron el mismo color de pelo de Juan). Se habla de una bolsa de afirmaciones, o más escuetamente, de una bolsa de valores cualitativos. Se trabaja con bolsa en lugar de conjunto para poder capturar afirmaciones con valores de var valores iguales, lo que los conjuntos no permiten. Se trata de hallar qué tan inconsistentes o divergentes son esas afirmaciones.

Inconsistencia de una bolsa de vc_i . Se denota por σ , se representa por el valor de confusión promedio del centroide r^* donde $\sigma \in [0,1]$ y se calcula como:

$$r^* = \frac{\min \left[\sum_{i=1}^n \text{conf}(vc_1, vc_i), \sum_{i=1}^n \text{conf}(vc_2, vc_i), \dots, \sum_{i=1}^n \text{conf}(vc_{n-1}, vc_i), \sum_{i=1}^n \text{conf}(vc_n, vc_i) \right]}{O_T}$$

Inconsistencia (en BO). La inconsistencia de una bolsa de objetos se denota por σ donde $\sigma \in [0,1]$. Éste es el valor de confusión promedio que el centroide O^* produce en la bolsa.

Jerarquía. Una jerarquía simple (normal) es un árbol con una raíz E, ellos crecen hacia abajo y si un nodo tiene hijos, éste forma una partición del padre (ver figura 4).

Nivel. El nivel de cualquier nodo en una jerarquía es la longitud de su trayectoria desde la raíz.

Variable cualitativa o variable simbólica. Variable cuyos valores no son números, sino valores cualitativos. También llamada variable lingüística¹. Por ejemplo, nacionalidad.

Es una variable cuyos valores no son números sino palabras o sentencias en un lenguaje natural o artificial. (Zadeh L.A. The Concept of a Linguistic Variable and its Application to Approximate Reasoning - I, Information Sciences, 8:3, 199-249).1975^a).

Valor cualitativo o valor simbólico. Valor no numérico. Es aquel que describe una variable cualitativa, por ejemplo algunos valores simbólicos de la variable mascota serían animal, oso, perro, etc.

Capítulo 1. Introducción

Esta tesis trata sobre la inconsistencia; es decir, la contradicción que surge cuando hay varias afirmaciones sobre un mismo evento u objeto, que no concuerdan entre sí.

Cuando dos afirmaciones A y B son inconsistentes, se tiene que $A \wedge B$ es falso. Esta es la noción que aprendemos de la Lógica. Toda proposición lógica es Falsa (0) o Verdadera (1). No hay valores intermedios. No hay valor 0.7.

Sin embargo, en la vida real, una afirmación puede contradecir "ligeramente" a otra. Por ejemplo, "la mascota de Juan es un Doberman" dice la afirmación A. Pero la afirmación B dice "la mascota de Juan es un perro". Si bien A no está de acuerdo con B, la contradicción entre A y B no es fuerte; B contradice "un poco" a A. El resultado de $A \wedge B$ no es 0, sino algo entre 0 y 1, por ejemplo 0.6. Nuestra intuición dice que la inconsistencia en casos reales es un número entre 0 y 1 (algo entre verdadero y falso). Nótese que si C dice que "la mascota de Juan es una lagartija", entonces la contradicción entre C y A es mayor. Es decir, la inconsistencia se puede cuantificar.

¿Cómo se tiene ese resultado intuitivo? Porque "perro" no difiere mucho de "Xoloitzcuintle". La confusión de usar perro en vez de Xoloitzcuintle es baja, porque "perro" es ascendente inmediato de "Xoloitzcuintle" (ver capítulo 4). Y la confusión de usar animal en vez de Xoloitzcuintle es mayor, debido a que "animal" no es ascendente inmediato de Xoloitzcuintle y la confusión crece cuando se calcula el recorrido de "animal" a "Xoloitzcuintle".

La idea es definir la confusión entre dos valores cualitativos, para luego cuantificar o medir la inconsistencia entre dos o más afirmaciones.

Este capítulo trata estos antecedentes y profundiza en este enfoque. Además contiene varios problemas que se solucionarán con la cuantificación de la inconsistencia, y esboza tales soluciones, que se desarrollan en capítulos posteriores.

Este capítulo está conformado por los puntos importantes que avalan la realización de este trabajo que son los antecedentes, la justificación, hipótesis, los objetivos para la realización de éste, el alcance que tiene el trabajo y contribuciones originales. Así como el estado del arte donde se comentan trabajos relacionados con este tema.

1.1 Antecedentes

La inconsistencia se presenta en bases de datos, especificación de requerimientos de software, en noticias, en la fusión de fuentes heterogéneas, etc. Por ejemplo, cuando se tiene información relevante sobre un cliente en dos bases de datos y se presentan desacuerdos en los datos de la persona.

Hay autores que interpretan la inconsistencia como creencias sobre aspectos de la realidad y lo que tratan de hacer es una revisión sobre éstas para determinar la inconsistencia. La revisión de creencias [2] (Beliefrevision) es el proceso de creencias cambiantes para tomar en cuenta una nueva pieza de información sobre un evento de la realidad. La palabra "cambiantes" involucra su actualización y su revisión. Es decir, la actualización (Beliefupdate) se refiere a nueva información que se tenga acerca de la situación presente y creencias viejas se refieren al pasado; por lo que la actualización va a ser la operación de cambiar las creencias viejas (anteriores) tomando en consideración las nuevas. La revisión es el proceso de introducir información nueva dentro del conjunto de la información vieja sin generar una inconsistencia. Esta información va a modelar una situación o aspecto de la realidad.

La principal suposición en la revisión de afirmaciones es tratar de que hayapocos cambios en la base del conocimiento, de modo que la base original y la nueva sean tan similares como seaposible. En el caso de la revisión, se esfuerza en conservar tanta información como se pueda por los cambios que se presenten. Nótese que tanto en revisión como en actualización de creencias, algunas afirmaciones "viejas" podrían ser suprimidas.

En este trabajo se estudiarán situaciones o circunstancias de la realidad referentes a un aspecto en particular, aspecto que se describe como un conjunto de afirmaciones. Si los observadores difieren en sus valores reportados no se debe a que sean mentirosos, sino a la exactitud de sus observaciones, o sea al error que existe según el método que usa cada quien, por ejemplo, para observar la altura de una persona, o su religión; en este sentido, el modo de obtener la inconsistencia en este trabajo difiere de Dempster-Schafer. También varía de la lógica clásica en que toda observación se toma en cuenta, aunque sea inconsistente con otras que ya se tenían.Lo cual quiere decir que ninguna se suprime o ignora.

Estas afirmaciones se obtienen a través de observadores (reporteros, informadores) y se analizarán sobre una jerarquía de valores cualitativos, involucrando para ellos una fórmula de confusión que nos dice la confusión que existe entre los valores cualitativos en una jerarquía. Por ejemplo, calcular la confusión de pedir América y obtener México.

En este trabajo se presenta un modelo y sus implementaciones que resuelven los siguientes problemas:

- Dado un conjunto de afirmaciones que describen un evento, ¿Qué fue lo más plausible que sucedió? y además medir su certidumbre. Es decir, de la lista de afirmaciones, el modelo permitirá determinar la inconsistencia de éstas. Y determinará cuál de estas afirmaciones es la que mejor representa a todas ellas. Por

ejemplo, sobre el color del cabello de Luis un observador dice que es rojo, otras afirmaciones al respecto son que es castaño claro, castaño oscuro, rubio, negro; se trata de determinar el consenso que más se acerque al color del pelo de Luis. Se trata de averiguar el valor que estaría más cercano a la verdad, **dada la información disponible**. También se determinará qué tan divergentes son estas afirmaciones entre sí. Esta divergencia se definirá como σ (sigma), la inconsistencia de un conjunto de afirmaciones en un rango de $0 \leq \sigma \leq 1$. Una σ pequeña indica que en el conjunto, las afirmaciones difieren poco entre sí, son bastante cercanas una de la otra; es decir, hay consistencia (hay bastante consistencia, hay poca inconsistencia). Una σ cercana a 1 representa que existe bastante discrepancia, afirmaciones divergentes. Una σ cercana a 1 indica inconsistencia (bastante inconsistencia), cercanía a Falso. Nótese que esta técnica mide la inconsistencia, en vez de decir simplemente “inconsistentes o contradictorios” (F, falso) o “son consistentes” (V, verdadero).

- Habrá casos en que es posible interpretar el conjunto de afirmaciones no como variaciones de un solo valor real, sino como variaciones de varios valores reales. Si hay varias afirmaciones sobre el padre de Juan, es claro que en realidad sólo tendrá un padre. En este caso, “padre de” no puede tener varios valores. Mientras que un conjunto de afirmaciones discordantes sobre los hermanos de Juan, puede interpretarse como que Juan tiene más de un hermano. Para un conjunto A de afirmaciones, en ocasiones es permisible determinar más de un centroide, representados por $R = \{r_0^*, r_1^*, \dots, r_k^*\}$. Son los valores más plausibles para este conjunto de afirmaciones. Se puede tener un conjunto de afirmaciones bastante inconsistente, pero si se parte en dos conjuntos y a cada uno se le halla su centroide, ya no lo sería tanto. Por ejemplo, Dios creó a la mujer, Dios creó a Eva, Dios creó una hembra, Dios creó un hombre, Dios creó a Adán, Dios creó a Eva a partir de Adán. Si se encuentran las particiones apropiadas de este conjunto de afirmaciones, se obtendrá de cada cluster (cúmulo, conglomerado, bloque) de la partición su centroide, de tal manera que el resultado arroja que existen dos centroides, Eva y Adán. Cada centroide representa el valor más plausible para cada bloque. El centroide de ese cúmulo minimiza la suma de las inconformidades de cada afirmación, (la inconformidad de una afirmación cuando se escoge como consenso r en vez del valor s que esa afirmación asevera, es simplemente $\text{conf}(r, s)$). Nos dice qué tan descontento está el observador que observó s cuando se entera de que el consenso es r). Al sumar todas las inconformidades producidas por r , se tiene la confusión total si se eligiese r como “representante” o consenso de la bolsa. Debe haber un valor r^* tal que esa confusión total sea mínima. Tal r^* es el centroide del cúmulo.
- Cálculo incremental de la inconsistencia. Cuando aparece una nueva afirmación sobre un evento, se quiere calcular qué tanto modifica la inconsistencia y el centroide que se tenía sobre ese evento.
- A veces el evento es un objeto observado que posee varias características que los informantes observan simultáneamente. Tales observaciones son inseparables, por lo que las afirmaciones contienen información encapsulada. Cada objeto está compuesto de características, las cuales aparecen en la afirmación inevitablemente unidas. Por ejemplo, un observador vio que el ladrón era un chino alto, y otro

observó que el cleptómano era un zapoteca chaparro, un tercero vio al manilargo y le pareció un asturiano alto. Pero nadie vio a un chino chaparro, ni a un zapoteca alto. Se desea hallar el objeto o evento que represente el valor más plausible. En el ejemplo el objeto se refiere al ladrón.

Por ejemplo, Juan afirma que el descubridor de América era un genovés alto. Luis dice que era un italiano alto. En cambio, Pedro cree que el descubridor de América fue un asturiano bajo. Se trata de calcular el descubridor de América más plausible.

Otro ejemplo, seann objetos: $O_1 = \{\text{Raúl } \{\text{color: negro}\}, \{\text{altura: alto}\}, \{\text{mascota: labrador}\}, \{\text{edad: 25}\}\}$, $O_2 = \{\text{Pedro } \{\text{color: negro}\}, \{\text{altura: chaparro}\}, \{\text{mascota: doberman}\}, \{\text{edad: 20}\}\}$, $O_3 = \{\text{Luis } \{\text{color: blanco}\}, \{\text{altura: media}\}, \{\text{mascota: American Pit}\}, \{\text{edad: 28}\}\}$, $O_4 = \{\text{Mario } \{\text{color: moreno}\}, \{\text{altura: enano}\}, \{\text{mascota: perro}\}, \{\text{edad: 19}\}\}$, se trata de hallar el centroide de esos cuatro objetos.

Se utilizarán jerarquías definidas en el capítulo 3, para encontrar la inconsistencia cuyo valor es un número entre cero y uno. El valor cualitativo u objeto más plausible de un conjunto de objetos generará un valor de inconsistencia más cercano a cero sobre el conjunto de objetos.

1.2 Justificación

Se puede medir un objeto, sacar su peso, su longitud, su volumen, etc. y obtener valores numéricos. Por ejemplo, puedo sacar las medidas de una puerta, el volumen de un líquido y a partir de los valores numéricos se pueden hacer cálculos como sumar o calcular la diferencia entre dos longitudes. Se trata de mediciones cuantitativas. Por ejemplo, cuatro trabajadores toman la medida a una puerta resultando las siguientes: $0.87m \times 2m$, $0.88m \times 2.3m$, $1m \times 3m$ y $0.86m \times 2m$. ¿Qué hacer frente a estos valores contradictorios?, ¿Se declara que las medidas son inconsistentes y que todo se reduce a falso y se despide a los trabajadores? O se trata de medir qué tan mentiroso es cada uno para obtener conclusiones sobre el tamaño de la mesa. Lo que se puede hacer es promediar las alturas y el ancho encontrando así valores más creíbles y hallar su varianza; es decir, aceptar la inevitabilidad del error en una medición.

Por otro lado, si las mediciones no son numéricas, se tienen observaciones sobre un suceso en particular. Ya no se habla de mediciones (puesto que no se obtienen números), sino de observaciones, que arrojan un valor simbólico cualitativo. Por ejemplo, se tienen diferentes afirmaciones de varias personas sobre el color del suéter de Pedro, como "el suéter de Pedro es rojo", "el suéter de Pedro es rosa", "el suéter de Pedro es claro", "el suéter de Pedro es anaranjado". ¿Cómo sacar el centroide de estas afirmaciones que involucran diferentes tonalidades de colores?, ¿cómo utilizar estas afirmaciones para determinar cuál es el valor que más se aproxima a lo que se vio?, ¿se puede encontrar el grado de discrepancia entre cada una de estas afirmaciones? Debido a que no se puede medir un concepto como lo hacemos con una mesa, un círculo, etc., este trabajo permitirá colocar valores cualitativos sobre una jerarquía y ver sus desemejanzas. En este trabajo se presenta esta metodología que permitirá encontrar el "promedio" (llamado centroide) de constantes cualitativas.

Cuando se trata de encontrar la inconsistencia de un conjunto de mediciones o valores cualitativos se ha utilizado la lógica clásica (también llamada Aristotélica), la lógica paraconsistente, la lógica difusa, la lógica casi-clásica.

En los anteriores tipos de lógica excepto la lógica difusa se tiene el problema de que las afirmaciones solo toman dos valores, verdadero o falso, no existe forma de obtener grados de veracidad o falsedad. Pero existen eventos en el mundo real que no podemos hablar de verdaderos o falsos en su totalidad; como por ejemplo determinar si el cielo es azul o si el clima está templado o cálido. O bien, hay observadores que no siempre dicen la verdad. O bien, los observadores tienen distinta precisión o exactitud al efectuar sus observaciones (distintos métodos o formas para observar el hecho o evento).

1.3 Tesis (logros o contribuciones originales de este trabajo)

Es posible calcular la inconsistencia a partir de comparaciones cualitativas.

Se puede medir la inconsistencia de un conjunto de afirmaciones que contienen valores cualitativos, tomando en cuenta que los observadores tienen distinta precisión o exactitud en una afirmación.

Se puede hallar el consenso o centroide de tal conjunto de afirmaciones, es el que produce la menor confusión total en los observadores. A esa confusión total más pequeña se le llama o define como “la inconsistencia de un conjunto de afirmaciones”.

Además se puede calcular la inconsistencia de un conjunto de objetos, es decir, afirmaciones encapsuladas en objetos y poder hallar los centroides.

1.4 Objetivo general

Presentar un modelo y su implementación para medir la inconsistencia de un conjunto de afirmaciones que modelan o describen un evento.

Esto es, de una bolsa que contiene afirmaciones inconsistentes, se quiere encontrar la que minimice la confusión total obteniendo un valor que va a representar el valor que mejor describe lo que sucedió o se observó en una situación en particular.

La tesis desarrollará la solución a los siguientes problemas:

1. Medir la inconsistencia de un conjunto de afirmaciones cualitativas y hallar el valor más plausible.
2. Clustering de datos. Es decir, hallar los varios centroides de un conjunto de afirmaciones, cuando el problema permite tener varios centroides.
3. Analizar y medir la inconsistencia que una nueva afirmación añadida al conjunto de afirmaciones, provoca en el nuevo conjunto. Qué tanto esta afirmación cambia la inconsistencia del conjunto.
4. Determinación de la afirmación más alejada del consenso. Esto es, determinar afirmaciones que aportan mucho a la inconsistencia (es decir hallar el valor más discrepante). Si se retira tal observación, la inconsistencia baja lo más posible.
5. En lo anterior las afirmaciones son aisladas y todos pertenecen a una misma jerarquía. Ahora se van a estudiar afirmaciones que vienen en paquete (caracterizaciones de un objeto), a fin de hallar el centroide y la inconsistencia del conjunto de afirmaciones.

1.5 Alcances

En este trabajo se desarrollará un modelo para medir la inconsistencia de valores cualitativos. Medir la inconsistencia de una bolsa de afirmaciones reportadas por observadores (reporteros, informadores) para encontrar el mejor modelo de la realidad. Estas afirmaciones tienen distinta precisión. La validación del modelo se llevará a cabo sacando ejemplos de eventos o sucesos de la realidad con sus afirmaciones y jerarquía correspondiente para determinar el grado de inconsistencia.

Lo que se requerirá para la realización de esta tesis es:

- Estudio de jerarquías.
- Estudio de la teoría de la semántica de confusión en jerarquías.
- Estudio del tema de inconsistencia en bases del conocimiento.

1.6 Organización del trabajo

Este trabajo se conforma de 10 capítulos, el primero contiene una introducción de la tesis.

En el capítulo 2 se presenta el estado del arte referente al tema de inconsistencia.

En el capítulo 3 se aborda el tema de teoría de la medida, también se trata el tema de la inconsistencia en información, ya sea en documentos, bases de datos, noticias, etc. Se da una breve introducción a las jerarquías y sus propiedades, ya que tanto el conjunto de afirmaciones como las características de los objetos deben estar representados en una jerarquía para obtener la inconsistencia.

El conocer ¿Qué tan inconsistentes son un conjunto de afirmaciones sobre un mismo evento? o ¿Qué tanto una afirmación contradice a otra? También se presenta en este capítulo explicando la confusión de usar un valor simbólico cualitativo r en lugar de s sobre una jerarquía. Por ejemplo, la confusión que resulta cuando se habla de "Avión" en lugar de "Transporte".

El capítulo 4 describe ¿Cómo calcular el valor más plausible a cerca de un evento, dada una serie de afirmaciones contradictorias sobre ese evento? A diferencia de la teoría de Dempster-Schaffer, que supone que cada informante tiene un grado de credibilidad (tendencia a decir mentiras), esta teoría de la inconsistencia supone que todos los informantes tienen la misma credibilidad, pero que difieren en la precisión o grado de detalle con que observan el evento.

El capítulo 5 estudia el caso cuando una bolsa de afirmaciones tiene varias explicaciones. Por ejemplo, saber cuáles son las mascotas de Juan. En este caso, es importante saber ¿cuáles minimizan la inconsistencia? Este capítulo describe cómo partir una bolsa de afirmaciones en n cúmulos (clusters, grupos o bloques) y hallar las mascotas más creíbles, es decir, los "centroides" de cada partición.

El capítulo 6 muestra cómo se vuelve a calcular la inconsistencia frente a nuevas observaciones.

El capítulo 7 dice cuál de las afirmaciones eliminar de un conjunto de afirmaciones dado, de forma tal que el nuevo subconjunto tenga la mayor consistencia (menor inconsistencia) posible. Es decir, ¿cuál de las afirmaciones de un conjunto contribuye más a su inconsistencia?, ¿cuál es la afirmación más discordante o disonante? *thegreatestoutlier*.

El capítulo 8 estudia varias afirmaciones hechas simultáneamente por los mismos observadores, en diferentes aspectos del evento observado; múltiples observaciones (más de un valor) que no pueden separarse una de la otra; es decir, la afirmación viene "encapsulada", la cual formará un objeto. Por ejemplo, "el asesino era un hombre alto negro", el homicida era una mujer japonesa baja", "el matón era una persona robusta de Nigeria". Note que nadie afirmó que el homicida era un japonés robusto. Aquí se quiere encontrar el "centroide" de los objetos observados, el objeto más plausible, así como la

inconsistencia (desacuerdo) de un conjunto de afirmaciones. Se trata de encontrar el centroide de varios objetos caracterizados por valores cualitativos.

El capítulo 9 presenta la arquitectura de las aplicaciones construidas en Java para llevar a cabo el análisis de inconsistencia sobre una bolsa de valores cualitativos y de objetos.

Finalmente, en el capítulo 10 se presentan las conclusiones del trabajo.

1.7 Contribuciones originales

Se presenta un modelo para poder medir la inconsistencia en un conjunto de valores cualitativos. Se asume que los informadores son veraces, de modo que las contradicciones o valores diferentes se deben a la precisión o exactitud o método con que llevaron a cabo sus observaciones. Para ello se usará una función de confusión que permita determinar esta inconsistencia y encontrar uno o varios posibles centroides.

La lógica no permite determinar si una afirmación es en cierto grado errónea o no, solo nos dice si algo es verdadero o falso partiendo de proposiciones o premisas. En este trabajo se presentan criterios o maneras de determinar grados de inconsistencia o verdad de un conjunto de afirmaciones y trabajar sobre sus valores cualitativos. Es decir, cuál afirmación que describe una situación es la que mejor representa el conjunto de afirmaciones disímbolas, el consenso.

¿Qué sucedería si se agrega una nueva afirmación?, ¿Cuánto modificaría la consistencia o inconsistencia? O si se elimina una afirmación ruidosa, es decir, genera mucha inconsistencia, ¿Cómo resolver estas situaciones?

Ahora bien, si se tienen afirmaciones en paquetes como objetos, con la finalidad de hallar el centroide y la inconsistencia del conjunto de afirmaciones.

1.8 Solución

La solución de estos problemas requiere realizar tanto la parte teórica como las aplicaciones necesarias para poder calcular la inconsistencia de un conjunto de afirmaciones. La figura 1 muestra un diseño de cómo se analiza un evento cuando se trata de afirmaciones y objetos (como afirmaciones encapsuladas). Cuando los observadores construyen una jerarquía con valores cualitativos se va a calcular la inconsistencia sobre un conjunto de afirmaciones sobre un evento en particular; y cuando los observadores construyen más de una jerarquía de valores cualitativos se va a medir la inconsistencia sobre un conjunto de objetos.

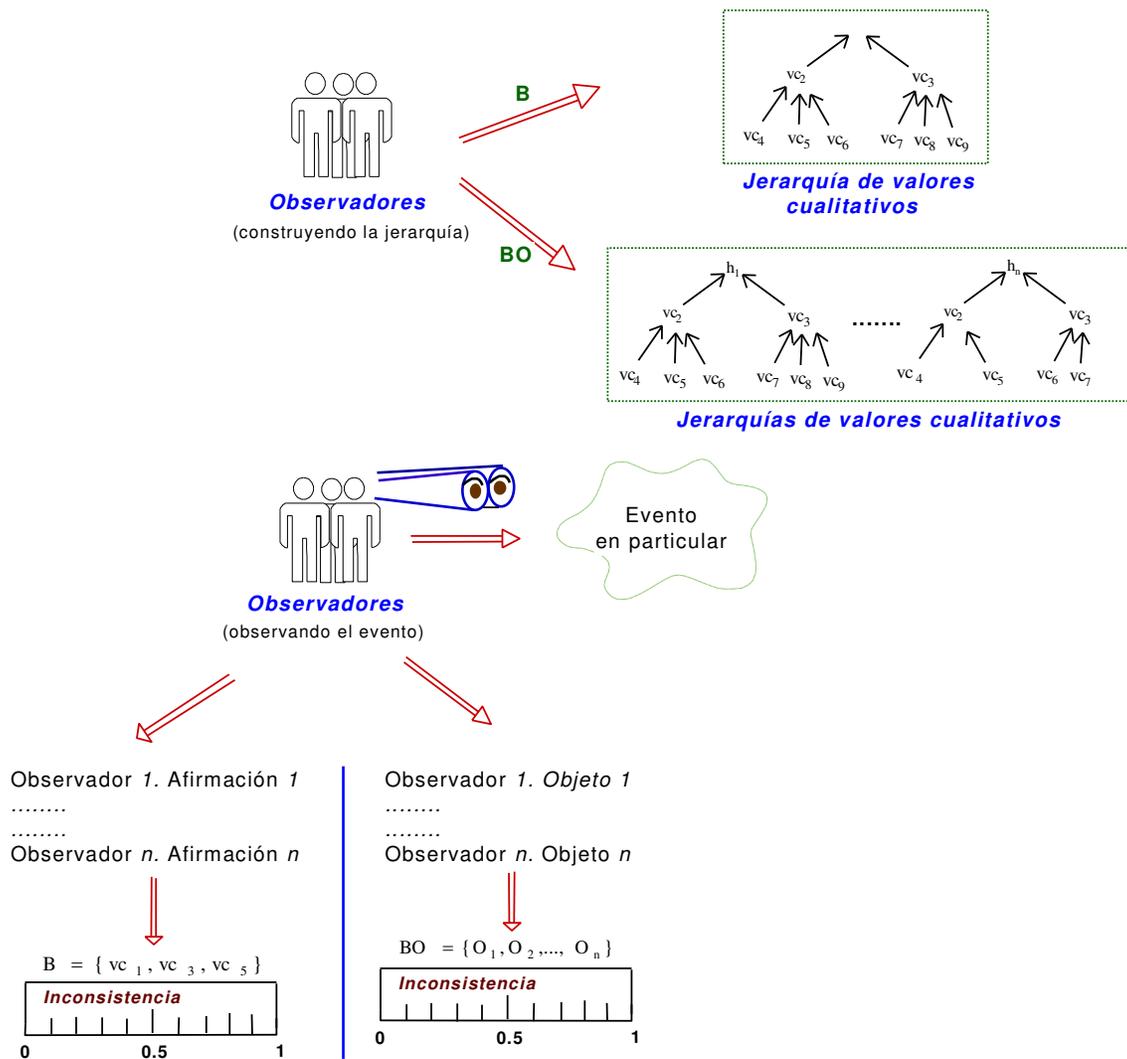


Figura 1. Bosquejo general del modelo de inconsistencia cuando se trata de afirmaciones o de objetos.

Este capítulo explica brevemente los problemas que esta tesis resuelve, y su solución. En los capítulos del cuatro al ocho se presentan soluciones formales y ejemplos.

Problema 1. Medir la inconsistencia de un conjunto de afirmaciones y hallar el valor más plausible (aceptable), al que se le llamará centroide o consenso.

Debido a que dos o más observadores pueden hacer énfasis sobre la misma afirmación, se podrá tener una o más observaciones sobre ésta. Por este motivo, se utilizará el término bolsa de afirmaciones sobre el evento observado, en lugar de utilizar conjunto (que no permite repetir elementos) o lista (que da un orden a sus elementos). Debido a que la estructura de bolsa permite valores repetidos desordenados.

Se van analizar estas afirmaciones utilizando una función de confusión (que se define más adelante en el punto 4.1 del capítulo 4), la cual me va permitir calcular el posible centroide de la bolsa de afirmaciones. Esto es, para poder calcular la inconsistencia de cada afirmación contenida en la bolsa y obtener cuál afirmación genera menor confusión total, es decir, cual es la más plausible.

Problema 2. Hallar uno o más centroides cuando el problema permite que haya más de uno.

Dada una bolsa de valores (referidos a una jerarquía) encontrar varios centroides, si el tipo de problema permite tener varios centroides. Es decir, encontrar los centroides que minimicen la confusión (descontento) total.

Partiendo de dos técnicas:

- Crear cúmulos agrupando valores cualitativos, clasificándolos como votantes fuertes; y valores donde la inconsistencia sea mayor, éstos serán votantes débiles.
- Se realizaran dos formas para hacer agrupamientos de una bolsa de valores cualitativos.
 - a) A partir de la matriz de confusiones de la bolsa se agrupan los valores de confusión de acuerdo al mismo número de confusión para posteriormente obtener cúmulos haciendo **particiones** de los valores cualitativos con menor confusión.
 - b) A partir de la matriz de confusiones de la bolsa se agrupan los valores de confusión de acuerdo al mismo número de confusión para posteriormente obtener cúmulos de dos, tres, hasta $(n-1)_{vc_i}$.

Las particiones del conjunto deben cumplir con lo siguiente:

Sea H un conjunto no vacío de afirmaciones, C es un cluster de H que nos interese, y la partición tiene índices en un conjunto I , digamos $C_i: i \in I$, estos requisitos se convierten en:

1. $C_i \neq \emptyset \forall i \in I$,
2. $\forall i, j \in I$ o bien $C_i = C_j$ o $C_i \cap C_j = \emptyset$,

$$3. \bigcup_{i \in I} C_i = H$$

Los conjuntos de C interesantes son aquellos donde C_1, C_2, \dots, C_n minimicen la confusión total.

Problema 3. Cálculo incremental de la inconsistencia.

Este procedimiento se acerca a la actualización de afirmaciones (belief updating). El soporte de r^* (denota el centroide o afirmación que minimiza la confusión), σ son las n afirmaciones $h_1, h_2, h_3, \dots, h_{i+1}, \dots, h_n$. La medición de la inconsistencia la proporciona el cálculo de σ (inconsistencia) con respecto a las n afirmaciones, r^* se calcula con la función de confusión.

Se calcula la nueva inconsistencia resultante cuando aparece una nueva afirmación h_{n+1} , la cual se agrega al conjunto de afirmaciones H . Aquí se toman en cuenta dos consideraciones:

Cuando la nueva afirmación h_{n+1} no hace crecer la σ_{vieja} se dice que ésta es consistente con:

$$r^*, \sigma_{vieja}$$

Cuando la nueva afirmación h_{n+1} genera una $\sigma_{nueva} \neq \sigma_{vieja}$, entonces la inconsistencia de la nueva bolsa se modifica.

Problema 4. Detectando y eliminando la afirmación que más contribuye a la inconsistencia.

Averiguar la afirmación h_i que si se retira del conjunto de afirmaciones H , reduce lo más posible la inconsistencia. Se trata de hallar la más discordante.

Problema 5. Análisis de afirmaciones empaquetadas en objetos.

Aquí se va a trabajar con objetos O que encapsulan afirmaciones atómicas.

Sea

O un objeto,

S_1, S_2, \dots, S_m , las características del Objeto o variables simbólicas,

V_1, V_2, \dots, V_m , los valores de las características.

La solución es el objeto O^* que minimiza $\sum \text{conf}(O^*, O_i)$, es decir, lo que se va a obtener es:

- El centroide de varios objetos.- Esto es, encontrar los objetos menos inconsistentes o más creíbles,
- poder promediar objetos, y
- poder hallar la inconsistencia o discrepancia de una bolsa de objetos.

Por ejemplo, se tiene el evento en que ocurrió un asalto y se quiere determinar qué persona es el asaltante. Entonces, existen observadores que van a dar las características del presunto asaltante según su opinión, cercanía al suceso, grado de distracción, etc. Ahora bien, se tienen que analizar todos los individuos (objetos) que se cayeron dentro de la descripción del asaltante y se obtendrá el que más se parece de acuerdo a la descripción de los observadores. Esto se logra obteniendo el objeto menos inconsistente, es decir el que se aproxime al suceso ocurrido.

Capítulo 2. Estado del Arte

En esta sección, se presentan trabajos que analizan el tema sobre cómo encontrar la inconsistencia, ya sea en sistemas de software, reportes de noticias, etc. Estos trabajos se apoyan de los tipos de lógica que filósofos o matemáticos han ido creando.

2.1 Lógica de primer orden

Uno de los objetivos de la lógica es precisamente eliminar estas ambigüedades y estudiar los principios de los razonamientos correctos.

Constantemente tomamos decisiones de lo que creemos es verdadero y con frecuencia discrepamos sobre si lo es o no en casos particulares.

Por ejemplo, si yo creo que todos los perros son mamíferos y que todos los mamíferos son seres racionales, entonces tiene sentido suponer que todos los perros son seres racionales. Quien no está de acuerdo acertadamente con esta clasificación biológica, podría apreciar la forma consistente y razonable en la utilización de las creencias erróneas como base sobre la que establece nuevas creencias.

Es posible distinguir los razonamientos válidos de los no válidos independientemente de que estemos o no de acuerdo con el contenido que expresen dichos razonamientos.

Constantemente tomamos decisiones acerca de lo que creemos que es verdadero en distintos aspectos de nuestras vidas. Aunque todo el mundo está de acuerdo en preferir creer lo que es verdad, con frecuencia discrepamos sobre lo que es verdadero en casos particulares. Si bien muchas de nuestras convicciones fundamentales sobre el mundo que nos rodea las adquirimos de cualquier manera mediante el uso de la razón, todos reconocemos que nuestras creencias sobre el mundo y las afirmaciones que acaecen en el mismo mundo están de algún modo ligadas.

En conclusión, podemos estar de acuerdo con el camino que sigue un razonamiento aunque discrepemos de sus puntos de partida y de llegada. Es decir, es posible distinguir los razonamientos válidos de los no válidos independientemente de que estemos o no de acuerdo con el contenido que expresen dichos razonamientos.

La lógica es la disciplina que estudia esta distinción determinando las condiciones bajo las cuales la verdad de ciertas creencias conduce con certeza a la verdad de alguna otra creencia. La lógica estudia los principios de los razonamientos correctos.

Hay que apresurarse a señalar que la lógica no garantiza que siempre lleguemos a conclusiones verdaderas, ya que algunas veces las creencias de las que partimos son erróneas (como suponer que todos los mamíferos son seres racionales, en el ejemplo anterior). Lo que sí garantiza la lógica es que siguiendo los principios de los razonamientos

correctos, no salgan otros errores aparte de los derivados de la posible falsedad de los conocimientos que sustentan nuestros razonamientos.

La lógica de primer orden trabaja con:

- lógica proposicional (enunciados)
- lógica de predicados

La lógica proposicional utiliza la composición de enunciados con los conectores y, o, si...entonces. Las proposiciones o enunciados las formalizan en un lenguaje simbólico (p, q, r, etc.) y define los conectores. Las conclusiones que salen de las premisas o proposiciones pueden tomar un solo valor ya sea verdadero o falso que generalmente se representan como T/F o V/F, o en álgebra booleana como 0 o 1.

La lógica de predicados expresa detalles que la lógica proposicional no puede, representados como argumentos o términos unidos a sentencias. También tienen un valor de veracidad (verdadero o falso) que depende de sus términos. La lógica de predicados utiliza dos cuantificadores: $\forall x$, indica que la fórmula bien formada, dentro de su enlace es verdadera para todos los valores posibles de las variables cuantificables. $\exists x$, indica que la fórmula bien formada, dentro de su enlace es verdadera para algún valor o valores dentro del dominio.

Mucha información en reportes de noticias frecuentemente es sorprendente e inesperada. Su interés es en muchas perspectivas a cerca del mundo y cuando cualquiera de estas violada (inconsistentes) por información nueva, con esto se tiene un fuerte indicador de que la información es interesante. En [22] lo que hacen Byrne y Hunter, consideran para un lenguaje de aplicación la sintaxis de expectativas, la precisión y valides de expectativas, y exploran las relaciones entre estos problemas. Cada expectativa se ve como una regla que describe como si la condición fuese verdadera, entonces se espera que la consecuencia sea verdadera. Aunque una expectativa no sea 100 % precisa, es normalmente correcta y cuando es violada, se considera a la información que causa esta violación como excepcional. Es decir, el trabajo de Byrne y Hunter es cubrir muchas expectativas a cerca del mundo, y cuando cualquiera de esas expectativas es violada por información nueva. Entonces tienen un fuerte indicador de que es información interesante. Se puede ver esto con reportes de noticias, particularmente el caso de noticias científicas, técnicas y de negocios, donde la información en los reportes de noticia normalmente continúa existiendo la tendencia o refuerzo de información esperada. Cada vez que entra un reporte, se comparará con un conjunto de expectativas para identificar cuáles son violadas por el reporte. Una expectativa se viola por un reporte cuando la unión de las expectativas y el reporte es inconsistente. Consideran el lenguaje de reportes, basado en un conjunto finito de predicados P. Entonces la exactitud de una expectativa es dependiendo del número de veces que ha sido violada dividida por el número de veces que ha sido disparada. Así se minimiza el error, cuando necesitan maximizar la precisión.

Por ejemplo, una expectativa que surge con reportes de noticias sobre negocios es "cuando una compañía hace una oferta de adquisición para otra compañía, la compañía tiene los

recursos financieros suficientes para pagar por la oferta". Otro ejemplo, "cuando una compañía está en administración, las cuentas acumuladas muestran que la compañía está produciendo una pérdida neta".

Byrne y Hunter definen las expectativas como fórmulas de lógica clásica. La información de entrada que utilizan está en forma de reporte. Cada reporte es un conjunto consistente de literales.

En este trabajo no se utiliza lógica clásica para calcular la inconsistencia de un conjunto de afirmaciones, los valores de cada afirmación se generan a partir de la confusión entre cada una de ellas para poder determinar la inconsistencia del evento que se observó.

Un sistema implementado basado en [23], acepta reportes de noticias estructuradas en XML como entrada; traduce cada reporte a una literal lógica; identifica la historia de la cual es parte el reporte; busca inconsistencias entre el reporte, el conocimiento de fondo, y un conjunto de expectativas; clasifica y evalúa esas expectativas; y de salida da reportes de noticias de interés para el usuario junto con explicaciones asociadas de porque éstos son interesantes. Lo que hacen es buscar noticias interesantes basadas en las expectativas que se tienen a cerca del mundo. Si los reportes de noticias violan una expectativa, esto indica que la noticia es interesante.

Gabbay y Hunter [19, 20] afirman que hay una diferencia fundamental entre la manera en que las personas manejamos la inconsistencia y la manera en que ésta es manejada en sistemas lógicos formales. Para una persona, resolver la inconsistencia no es necesariamente restaurando la consistencia proporcionando reglas contundentes de cómo actuar cuando surge la inconsistencia. Para la inteligencia artificial hay una necesidad urgente de revisar el punto de vista de que la inconsistencia es una cosa "mala", en lugar de verla principalmente como "buena". Las inconsistencias pueden ser leídas como señales para tomar acciones externas, tales como "preguntar al usuario" o invocar "el sistema de mantenimiento verdadero" o como señales para acciones internas que activan algunas reglas y desactivan otras. Existe la necesidad de desarrollar un marco de trabajo en el cual la inconsistencia pueda ser vista de acuerdo al contexto. Muchos dicen que las bases de datos deberían estar libres de inconsistencia y tratar de erradicarla. Otros creen que mejor debería estar aislada. Los datos de la forma q y $\neg q$, para cualquier proposición q no pueden existir juntas y el conflicto se debe resolver de alguna manera. Pero existen casos en los que lo anterior, puede ser aceptable y no necesita ser resuelto. En otros casos, q y $\neg q$ sirven como bienvenida de una acción (trigger) para varias acciones lógicas.

Desde que todo es una consecuencia de una inconsistencia, la lógica clásica no es útil en el modelar el razonamiento de un agente como con creencias inconsistentes. [30]. Lin hace diferencia entre creencias consistentes de las inconsistentes. Para ello propone dos operadores de creencia B^c y B , para creencias consistentes y creencias, respectivamente. B^c tiene la propiedad modus ponens, por la cual el agente es capaz de razonar con creencias consistentes y trazar conclusiones consistentes. B tolera la inconsistencia, y por B el agente puede razonar sobre sus creencias inconsistentes mejor. El concepto de la creencia consistente y el formalismo lógico que propone Lin son nuevos, en que el razonamiento consistente sobre la información en una base del conocimiento es posible. Desarrollaron sus

axiomas con lógica clásica y la aplicación de B^c y B en el razonamiento a cerca de conocimiento implícito en un grupo de agentes y la eliminación de inconsistencia de desde una base de conocimiento.

Una base del conocimiento podría ser inconsistente mientras el conocimiento del mundo no es inconsistente. Para Lin es más apropiado ver la base del conocimiento como la reflexión de las creencias de un agente, en lugar de como el verdadero estado de acciones en el mundo real. Esto es, asumen que hay un agente que razona acerca del mundo de acuerdo a la base del conocimiento. Por ejemplo, se tiene la base del conocimiento $\psi = p \wedge \neg p \wedge q \wedge (q \supset r)$, entonces $\psi \models \alpha$ para cualquier fórmula α en la lógica clásica. Pero, intuitivamente q y r son irrelevantes a la inconsistencia. Sería deseable que ellas sean distinguidas de p como información valuable. En este caso, q y $q \supset r$ son creíbles consistentemente (creencias consistentes del agente) debido a que no están envueltas en la inconsistencia. En contraste, se dice que p y $\neg p$ son creíbles inconsistentemente (creencias inconsistentes del agente). Las creencias inconsistentes no tienen significado y ellas representan las creencias que son dañadas por la inconsistencia, mientras que las consistentes son todavía evaluables a pesar de la inconsistencia.

La motivación de la lógica que propone Lin es para proporcionar algunas maneras para razonar a cerca de creencias consistentes. En la vida una base del conocimiento debe ser consistente y esto se puede ver en sistemas expertos médicos, cuyos conocimientos se obtienen de múltiples expertos médicos, donde es común que los médicos tengan diferentes puntos de vista en su dominio de especialidad. Entonces la pregunta es: ¿dado el conflicto (inconsistencia) en el sistema experto, pueden los diagnósticos correctos estar hechos en las enfermedades de los pacientes? Por ejemplo, dada la base del conocimiento $\psi = p \wedge \neg p \wedge q \wedge (q \supset r)$, donde p "significa que el paciente tiene hepatitis", entonces es claro que el diagnóstico de que el paciente tiene hepatitis es erróneo, debido a que otra pieza del conocimiento en la base del conocimiento ψ ya tiene $\neg p$. Así es el diagnóstico que el paciente no tiene hepatitis. Ambos podrían tener un efecto perjudicial en el paciente, por ejemplo, los resultados pasados que el paciente va a través de tratamiento innecesario y los resultados después del tratamiento del paciente serían tardíos. En cambio, ellos deben hacerse en base a las creencias consistentes. Por ejemplo, se tiene $\neg p$ pero r que significa "el paciente tiene hepatitis", y $q \supset r$ es la regla que significa que "si un paciente tiene ictericia, entonces él/ella tiene hepatitis". No debería tener problema afirmar que "el paciente tiene hepatitis" de acuerdo al afirmación que él/ella tiene ictericia. Entonces, se necesita de alguna manera del razonamiento a cerca de creencias consistentes, para que las decisiones o afirmaciones puedan ser hechas si ellas son "creídas consistentemente" por la base del conocimiento.

2.2 Lógica paraconsistente

La lógica paraconsistente fue desarrollada para comprender mejor las contradicciones en lugar de excluirlas. Una lógica se dice que es paraconsistente si admite que una conclusión sea obtenida de premisas contradictorias [16]. Este tipo de lógica fue propuesta por Jean

Lukasiewicz y Nicolai I. Vasiliev. Dentro de la lógica paraconsistente algunas lógicas que se han utilizado para tratar la inconsistencia son:

- Lógica multi valuada (multidimensional).
- Lógica quasi-classica. La lógica quasi-clásica fue propuesta por Besnard y Hunter, la que consideran como una adaptación de la lógica clásica. Las reglas de la demostración de la lógica quasi-clásica son subconjunto de las reglas de la lógica. Este tipo de lógica también entra en lo que es la lógica paraconsistente.

Lógica multi-valuada

La lógica multi-valuada fue creada por el lógico y filósofo Lukasiewicz (1920), y desarrollada primero en Polonia. Su primera intención fue utilizar un valor de verdad adicional para "posible" y manejarlo en modalidades "es necesario que" y "es posible que". Se llama así porque asigna un vector de verdad a una afirmación, en vez de un solo valor. Este tipo de lógica es un nuevo sistema para modelar lógica paraconsistente. La lógica multi-valuada se toma con más de dos estados, por ejemplo la lógica cuarta-valuada toma los estados de 0, 1, 2 y 3.

Paralelo a las aproximaciones de Lukasiewicz, el matemático americano Post (1921) introdujo una idea básica de grados de verdad adicionales, y lo aplicó a los problemas de la representatividad de funciones.

Más tarde Godel (1932) trató de entender la lógica intuicionista en términos de muchos grados de verdad. La lógica intuicionista no tiene una matriz lógica característica con solamente muchos grados de verdad finitos. Pocos años más tarde, Jaskowski (1936) construyó una matriz característica valuada infinita para lógica intuicionista. Sin embargo, los grados de verdad de esta matriz no tienen una buena y simple interpretación intuitiva.

Una aplicación filosófica de la lógica tri-valuada a la discusión de paradojas fue propuesta por el lógico ruso Bochvar (1938) y una aplicación matemática a la función parcial y relaciones por el lógico americano Kleene (1938). Más tarde los conectivos de Kleene llegaron a ser filosóficamente interesantes como una herramienta técnica para determinar los puntos fijos en la teoría de revisión de la verdad iniciada por Kripke (1975).

Hunter y Nuseibeh [10], en trabajos previos defendieron desarrollos continuados de especificaciones en presencia de inconsistencia usando lógica clásica, para representar especificaciones parciales e identificar inconsistencias entre ellas. En [10], ahora presentan una adaptación de la lógica clásica, a la cual llaman casi-clásica (quasi-classical, QC), que permite razonamiento continuado en la presencia de inconsistencia. Ésto les facilita un análisis lógico de información inconsistente. En este trabajo, discuten la aplicación de la lógica QC en el análisis de especificaciones multi-perspectivas. Tales especificaciones son desarrolladas por múltiples participantes, quienes sostienen traslapes, inconsistencia frecuente, vistos del sistema que están desarrollando. Estos autores presentan una aproximación formal que soporta acción continuada (incluyendo razonamiento) en presencia de inconsistencia y facilita la grabación y seguimiento de información (inconsistente) durante el razonamiento. Su trabajo presenta dos partes principales:

Razonamiento. Hunter y Nuseibeh dirigen la noción de "tolerando inconsistencia" proponiendo una adaptación a la lógica clásica, la lógica QC. La adaptación es una debilidad de la lógica clásica.

Análisis. Éste se dirige a la necesidad de analizar especificaciones inconsistentes en el punto anterior. En particular, proponen el uso de la nombrada lógica QC que registra y sigue información usada en el razonamiento. Presentan reglas de esta lógica que se pueden utilizar para el seguimiento de la información durante el razonamiento. Usando esta aproximación se puede proporcionar un "análisis lógico" de información inconsistente.

La motivación de [10] fue por la necesidad de tratar con especificaciones inconsistentes de una forma que les permitiera analizar las fuentes probables de inconsistencia, el continuo razonamiento en una forma racional en presencia de la inconsistencia y proporcionar una base para actuar en la inconsistencia. En [10], los autores presentan una visión de los antecedentes y motivación para su aproximación. Describen los tipos de información de desarrollo del software con el que están tratando, la conveniencia de la lógica para representar tal información. La información en desarrollo incluye: a) Información de la especificación, acerca del sistema actual (producto) siendo desarrollado; b) Método de la información, acerca del proceso de desarrollo y la representación de esquemas usados al expresar especificaciones parciales. Esta información también incluye restricciones de integridad entre esquemas de representación, que son capturadas como "reglas inter-punto de vista" [14]. Estas reglas describen relaciones entre esquemas de representación, y así las relaciones entre especificaciones parciales expresadas usando esos esquemas de representación; c) Información del dominio, la cual es incrementalmente capturada en un proceso de especificación envolvente. Esta información puede referirse al dominio del problema en el cual el sistema será instalado. Por ejemplo, ésta puede incluir ontologías para un dominio de problema en particular tales como telecomunicaciones. Los tres tipos de información antes mencionados se pueden traducir en fórmulas lógicas. En [12] traducen y detectan inconsistencia en información específica solamente.

Grant y Hunter [31] proporcionan una medida para cuantificar la inconsistencia de una base del conocimiento, permitiendo de este modo, la comparación de la inconsistencia de varias bases del conocimiento, representadas como fórmulas lógicas de primer orden. Se basan en el uso de la lógica casi-clásica para tal propósito. Este tipo de lógica es un formalismo para el razonamiento y análisis de información inconsistente. Estos autores extienden un marco de trabajo para usar una versión de la lógica de primer orden de lógica QC para medir la inconsistencia en teorías de primer orden. Les motiva a usar una aproximación de la lógica QC por considerar algunas fórmulas como de las bases de datos o bases del conocimiento, restricciones de integridad. Ellos definen una medida de inconsistencia extrínseca que puede ser usada para comparar la inconsistencia de diferentes bases del conocimiento. También proporcionan una formalización de igualdad para consistente, llamada casi-igualdad, donde usan ésta en ejemplo de una aplicación para medir la inconsistencia entre fuentes heterogéneas de información y restricciones de integridad a priori para fusión. El proporcionar tal medida, como ya se dijo les permite comparar diferentes bases del conocimiento y evaluar la calidad de su información. Si dada la oportunidad a elegir entre diferentes bases del conocimiento, se puede elegir la menos inconsistente. Estos autores usan de la lógica para consistente, la lógica QC, porque se ajusta más para tratar con

afirmaciones de bases del conocimiento típicas, particularmente restricciones de integridad de bases de datos y que han sido violadas por datos. La lógica QC se ha utilizado para comparar fuentes heterogéneas, donde las inconsistencias surgen frecuentemente entre las fuentes. Por ejemplo, supongamos que se está tratando con un grupo de médicos consultando a algún paciente, un grupo de testimonios de algún incidente o de un conjunto de reportes de periódicos cubriendo algún evento. Todas éstas son situaciones donde se espera algún grado de inconsistencia en la información. Suponga que la información de cada fuente es representada por un conjunto de fórmulas. Entonces se puede preguntar, si una fuente es más inconsistente que otra y en qué grado.

Hunter presenta trabajos utilizando lógica QC para poder determinar la inconsistencia en lo que les llama fuentes heterogéneas. Para ello utiliza un conjunto de restricciones representadas por una disyunción de literales, donde los datos están representados por las literales. Hunter representa estas fuentes de información como fórmulas utilizando la lógica de primer orden para verificar la inconsistencia de los datos a medir. Entonces, hace uso de cuantificadores, la disyunción, define modelos y restricciones que la fuente que se está analizando debe cumplir. En la metodología que se trata en este trabajo, no hay necesidad de utilizar restricciones definidas por la lógica de primer orden, ni restricciones definidas a partir de la disyunción, aquí cada afirmación toma su valor de acuerdo a una jerarquía construida para poder realizar el cálculo de inconsistencia. En otros trabajos realizados por Hunter, define tablas de verdad que determinan la veracidad o falsedad y a partir de ahí define el valor de inconsistencia. En este trabajo todas las afirmaciones tienen la misma credibilidad por lo que no se requieren de tablas de verdad ni de la lógica multi evaluada para definir desde antes cuántos valores de inconsistencia podrán tenerse definidos.

Hunter [31] proporciona una caracterización general de inconsistencia, donde se analiza el conocimiento inconsistente en el manejo de fuentes heterogéneas del conocimiento.

Frecuentemente la inconsistencia ocurre en noticias acerca del mundo real [36]. Algunas de estas inconsistencias pueden ser más significativas que otras, y algunas pueden contener más inconsistencia que otras. Las posibles acciones en una inconsistencia en un reporte de noticia, incluye ignorar la inconsistencia, resolver la inconsistencia, y rechazar el reporte. Para soportar esto, Hunter extiende y aplica una caracterización general de inconsistencia, basado en la lógica cuarta-valuada de Belnap.

2.3 La Teoría Matemática de la Evidencia

La teoría matemática es una teoría de la evidencia y una teoría de razonamiento probable. Se dice que es una teoría de la evidencia porque trata con pesos de evidencia y con grados numéricos de soporte basado en evidencia. Es una teoría de razonamiento probable porque se centra en la operación fundamental de razonamiento probable: la combinación de evidencia.

Esta teoría empieza porque usa un número entre cero y uno para indicar el grado de soporte de un cuerpo de evidencia provisto por una proposición. Se centra en la combinación de grados de creencia o soporte basado en un cuerpo de evidencia con aquellas basadas en un

cuerpo distinto de evidencia. El corazón de la teoría es la regla de Dempster para efectuar esta combinación. [26].

La teoría de Dempster-Shafer [27] fue introducida en los 70's y desarrollada por Glenn Shafer y después extendida por Arthur Dempster basada en las funciones de creencia (belief functions) y razonamiento plausible (plausible reasoning), la cual se usa para combinar piezas separadas de información (evidencia) para calcular la probabilidad de un evento. Esta teoría fue publicada por la Universidad de Princeton en 1976.

El desarrollo de la teoría fue motivado por la observación de que la teoría de la probabilidad no es capaz de distinguir entre la incertidumbre e ignorancia debido a la información incompleta.

La Teoría de Dempster-Shafer también conocida como de funciones de creencias, es una generalización de la teoría Bayesiana de probabilidades subjetivas. Mientras que la teoría Bayesiana requiere probabilidades para cada pregunta de interés, las funciones permiten grados de creencia para una pregunta en probabilidades. Estos grados pueden o no tener propiedades matemáticas de probabilidades; cuanto más difieran de las probabilidades dependerá de qué tanto las dos preguntas están relacionadas.

Ejemplos de qué podríamos llamar razonamiento de función de creencia [27] puede encontrarse en los siglos XVII y principios del XVIII, antes de que las ideas Bayesianas se desarrollaran. En 1686, George Hooper dio reglas para combinar testimonio que se puede reconocer como un caso especial de la regla de Dempster para combinar las funciones de creencias (Shaffer 1986a). Se formularon reglas similares por Jakob Bernoulli en su *Ars Conjectandi* (Arte de las conjeturas) póstumamente publicado en 1713, y por Jhoann-Heinrich Lambert en su *Neues Organon*, publicado en 1764 (Shafer 1978).

La Teoría de Dempster-Shafer se basa en dos ideas:

1. La idea de obtener grados de creencias para una pregunta desde probabilidades subjetivas, y
2. la regla de Dempster para combinar tales grados de creencia cuando están basados en elementos independientes de evidencia.

La manera más simple de ilustrar estas ideas es regresar a los documentos de George Hooper en 1689, la confiabilidad de testimonio. La aproximación de función de creencia a testimonio se deriva de grados de creencia para sentencias hechas por testimonios de probabilidades subjetivas para la confiabilidad de estos testimonios.

Por ejemplo, se tienen probabilidades subjetivas de la Sra. Betty, donde la probabilidad de que ella es confiable es 0.9, y que no es confiable es 0.1. Ella le dice a su jefe que una rama cayó en su auto. Su testimonio solo justifica que en un 0.9 grado de creencia que la rama cayó en el carro, y solo cero grados de creencia de que no cayó (no un 0.1). El 0.9 y el cero juntos constituyen una función de creencia.

La regla de Dempster para combinar los grados de creencia para el mismo ejemplo supone también que tiene un 0.9 de probabilidad subjetiva para la confiabilidad de Sally, quien también testifica independientemente de Betty, que una rama cayó en el carro. El evento que Betty es confiable es independiente del evento que Sally es confiable. Entonces se puede multiplicar las probabilidades de los dos eventos; la probabilidad de que ambas son confiables es $(0.9)(0.9)=0.81$, la probabilidad de que ninguna es confiable es $(0.1)(0.1)=0.01$, y la probabilidad de que al menos una es confiable es $1-0.01=0.99$. Debido a que ambas dijeron que la rama cayó en el carro, implica que si sucedió, y de aquí se puede asignar a este evento un grado de creencia de 0.99.

Si por otro lado, Betty y Sally se contradicen, es decir, Betty dice que la rama cayó en el carro y Sally dice que no cayó. Las probabilidades anteriores de que solo Betty es confiable, que solo Sally y la de que ninguna lo es son $0.9 \cdot 0.1=0.09$, $0.1 \cdot 0.9=0.09$, y $0.1 \cdot 0.1=0.01$ respectivamente. Las probabilidades posteriores (dado que ambas no son confiables) son $(9/(19))$, $(9/(19))$, y $(1/(19))$ respectivamente. Ahora se tiene un grado de creencia de $(9/(19))$ de que una rama cayó en el carro (porque Betty es confiable) y un grado de creencia de $(9/(19))$ no ha caído en el carro (porque Sally es confiable).

Se pueden derivar las siguientes fórmulas [27]:

Si Betty y Sally dicen exactamente lo mismo, el grado de creencia en lo que ellas dicen será $1 - (1 - s_1)(1 - s_2)$.

Si ellas conforman diferentes pero aseveraciones consistentes, el grado de creencia en ambas aseveraciones siendo verdad será $s_1 s_2$.

Si ellas forman aseveraciones contradictorias, el grado de la afirmación de Betty será $\frac{s_1(1-s_2)}{1-s_1s_2}$ y el grado de creencia de la afirmación de Sally será $\frac{s_2(1-s_1)}{1-s_1s_2}$.

Para entender mejor el ejemplo antes mencionado, se presentan algunas definiciones y propiedades de la Teoría Matemática de la Evidencia detallada por Shafer.

Suponga que θ es un conjunto finito, y sea 2^θ el conjunto que denota a todos los subconjuntos del conjunto θ . Suponga que la función $Bel: 2^\theta \rightarrow [0,1]$ satisface las siguientes condiciones:

- 1) $Bel(\emptyset) = 0$.
- 2) $Bel(\theta) = 1$.
- 3) $\forall n \in \mathbb{Z}$ y cada colección A_1, \dots, A_n de subconjuntos de θ ,

$$Bel(A_1 \cup A_2 \cup \dots \cup A_n) \geq \sum_i Bel(A_i) - \sum_{i < j} Bel(A_i \cap A_j) + \dots + (-1)^{n+1} Bel(A_1 \cap \dots \cap A_n).$$

Bel es llamada una función de creencia sobre θ . Aquí se trata de explorar la posibilidad de usar tales funciones para representar creencias parciales.

Tal posibilidad surge cuando un conjunto θ es interpretado como un conjunto de posibilidades, exactamente uno de los cuales corresponde a la verdad. $\forall A \in \theta$, el número $Bel(A)$ se puede interpretar como un grado de creencia que la verdad se encuentra en A . Las reglas 1, 2 y 3 se entienden como las reglas que gobiernan esos grados de creencia. Por ejemplo, el vaso de Ming. Se tiene un vaso que ha sido representado como un producto de la dinastía Ming. ¿El vaso es genuino o es falsificado?

Sea ω_1 la posibilidad de que el vaso es genuino, ω_2 la posibilidad que es falso. Entonces $\theta = \{\omega_1, \omega_2\}$ representa al conjunto de posibilidades, y $2^\theta = \{\emptyset, \theta, \{\omega_1\}, \{\omega_2\}\}$ es el conjunto de sus subconjuntos. Una función de creencia Bel sobre θ representa mi creencia si $Bel(\{\omega_1\})$ es mi grado de creencia que el vaso es genuino y $Bel(\{\omega_2\})$ es mi grado de creencia que el vaso es falso. Se denota a $s_1 = Bel(\{\omega_1\})$ y $s_2 = Bel(\{\omega_2\})$. La regla 3) impone restricciones en los valores que s_1 y s_2 pueden tomar.

En el ejemplo de Bety y Sally s_1 y s_2 están en el subconjunto A . Esto se centra en lo que Shafer describe en su libro como las funciones de soporte simple; las cuales, son funciones de creencia basadas en evidencias homogéneas. El efecto de un cuerpo de discernimiento θ es soportar muchas de las proposiciones discernidas por θ , pero variando los grados. Cuando la evidencia apunta con precisión y sin ambigüedades a un subconjunto A no vacío de θ . Si s es un grado de soporte para A , donde $0 \leq s \leq 1$, entonces el grado de soporte para $B \subset \theta$ está dado por,

$$S(B) = \begin{cases} 0 & \text{si } B \text{ no contiene a } A \\ s & \text{si } A \subset B, \text{ pero } B \neq \theta \\ 1 & \text{si } B = \theta \end{cases}$$

La función $S: 2^\theta \rightarrow [0,1]$ se llama función de soporte simple centrada en A . De aquí que, una función de soporte simple es una función de creencia. Si S es una función de soporte simple centrada en A , entonces S es la función de creencia con probabilidades $m(A) = S(A)$, $m(\theta) = 1 - S(A)$ y $m(B) = 0$ para cualquier $B \subset \theta$.

De acuerdo con la regla de combinación de Bernoulli. Suponga que un cuerpo de evidencia tiene efecto preciso para que $A \subset \theta$ para el grado s_1 , mientras que otro cuerpo de evidencia totalmente independiente tiene efecto preciso para soporte A para el grado s_2 . ¿En qué grado los dos organismos de evidencia juntos soportan A ? Se requiere una regla para combinar dos funciones de soporte simple S_1 y S_2 , ambas están en A .

Esta regla fue reconocida por James Bernoulli, su solución trasladada dentro de la metodología de Dempster-Shafer es el conjunto de grados de soporte para A , basada en la evidencia total, como:

$$1 - (1 - s_1)(1 - s_2) = s_1 + s_2(1 - s_1) = s_2 + s_1(1 - s_2).$$

Esta solución asegura que los grados de soporte en la evidencia total de los subconjuntos A es más grande, que en su grado de soporte en cualquiera de las evidencias independientes.

La regla de Bernoulli es un caso especial de la regla de combinación de Dempster. La función de soporte S_1 tiene la probabilidad $m_2(A) = s_1$ y $m_2(\theta) = 1 - s_2$.

Retomando el ejemplo de Bety y Sally; en resumen, se obtienen grados de creencia para una pregunta (Una hoja cayó en el carro) de probabilidades para otra pregunta (¿El testimonio es confiable?). La regla de Dempster empieza con la suposición de que la pregunta para la cual se tienen probabilidades es independiente con respecto a juicios de probabilidades subjetivas pero esta independencia es solo a priori; ésta desaparece cuando el conflicto es discernido entre los diferentes elementos de evidencia.

Implementando la Teoría de Dempster-Shafer en un problema específico generalmente involucra resolver dos problemas relacionados. Primero se deben cortar incertidumbres en el problema, en elementos de evidencia independientes a priori. Segundo, llevar la regla de Dempster computacionalmente.

Dempster-Shafer asigna una probabilidad subjetiva para la credibilidad de cada afirmación sobre el evento que está observando. La metodología que se desarrolló en este trabajo no asigna probabilidades, simplemente todos los observadores tienen igual credibilidad.

Si las afirmaciones en este trabajo se manejaran con porcentajes se podría combinar la Teoría de Dempster-Shafer con la Teoría de la inconsistencia que se trata en esta tesis.

El estudio de detectar la inconsistencia [28] considera el caso de un robot móvil navegando y controlado, pero desconocido, dentro de un ambiente en la presencia de anomalías percibidas. Una anomalía percibida se refiere a los casos en los cuales los sensores físicos están trabajando sin las especificaciones de manufactura pero la lectura podría dejar una incorrecta interpretación del ambiente. Por ejemplo, un sensor de sonar tiene dificultades para detectar muros lisos debido a la reflexión especular y escaners de rangos láser no pueden detectar superficies dulces. La presencia de anomalías percibidas es un indicador de que el sensor elegido o conjunto de sensores, son inadecuados para un ambiente dado. Las características de la métrica de conflicto Con, del peso de Dempster-Shafer son potenciales para el problema de detectar el uso de sensores inadecuados.

2.4 Lógica difusa

La teoría de conjuntos difusos [18, 34] fue iniciada en la década de los 60's por el Dr. Lofti A. Zadeh, profesor Emeritus del Departamento de Ingeniería Eléctrica y Ciencias de Computación de la Universidad de California en Berkeley.

La lógica difusa es una extensión de la lógica tradicional (booleana) que utiliza conceptos de pertenencia de conjuntos más parecidos a la manera de pensar humana.

Un conjunto difuso, a diferencia de un conjunto clásico, es un tipo especial de conjunto que permite membrecía parcial de sus elementos. En conjuntos difusos, un elemento del universo puede pertenecer a uno o más conjuntos con distintos grados de membrecía. Una función de membrecía es una relación que asocia cada elemento en un conjunto con su

grado de membrecía. El grado de membrecía que toma valores en el intervalo de $[0,1]$, es la seguridad o certidumbre de que un elemento del universo pertenezca a un conjunto difuso.

El dominio o soporte de un conjunto difuso es el conjunto de los números reales dentro de la frontera del conjunto difuso. Las palabras asociadas a los conjuntos son variables lingüísticas, es decir, expresiones del sentido común (vacío, medio lleno, lleno); las cuales son utilizadas para describir una condición o situación y cuyos valores son letras en lugar de números. Por ejemplo, una variable numérica para el volumen de un tanque sería “100 lts” y una variable lingüística sería lleno.

En este trabajo se utiliza la Teoría de la Confusión [28] y no la lógica difusa debido a las siguientes diferencias:

1. Para poder resolver un problema con lógica difusa, el primer paso implica identificar las entradas y salidas utilizando variables lingüísticas, que representan valores numéricos.

Las entradas que inicialmente se tienen para dar solución a los casos que se presentan en este trabajo, son **afirmaciones** que los n observadores proporcionan a cerca de un evento en particular. De estas afirmaciones se obtiene lo que se llamará valores cualitativos y no se identifica una correspondencia de los valores cualitativos (de este trabajo) hacia variables numéricas (requeridas por lógica difusa).

3. En la lógica difusa, las variables lingüísticas están representadas en una función de membrecía y en la Teoría de la Confusión, el orden de los valores cualitativos está dado por un árbol jerárquico.
4. En la lógica difusa, el parecido entre dos elementos, es decir, la distancia entre dos elementos del universo $\text{dist}(e_1, e_2)$ es métrica. En la Teoría de la Confusión $\text{CONF}(e_1, e_2)$, no es una métrica ni tampoco es simétrica, aunque obedece a la ley del triángulo.

2.5 Teoría de Kripke

Kripke no ofrece grados de veracidad como en la teoría de la inconsistencia que se está manejando en este trabajo, pero se presenta un breve análisis de su teoría a continuación.

Kripke [35] presenta una teoría semántica acerca del significado y funcionamiento del predicado de la verdad. Utiliza para ello, el apartado formal de la teoría de puntos fijos, es decir, reconstruye al predicado de verdad como un punto fijo. Esto le permite dar solución a algunas paradojas semánticas (específicamente la paradoja del mentiroso) de la verdad compatible con una solución a las paradojas semánticas y recoger, al mismo tiempo, parte de las intuiciones que tenemos sobre las atribuciones de verdad.

La intuición de Kripke era reconstruir el concepto ordinario de verdad, liberándolo de la jerarquía de predicados de verdad a que queda condenado el enfoque tarskiano. Pretende restituir la unicidad teórica del predicado de verdad. Intenta que un solo predicado de verdad haga lo que la jerarquía tarskiano o la teoría de tipos russelliana. Y procura que todo esto se realice a través de un lenguaje que sea lo suficientemente rico como para hablar de su propia sintaxis y para contener su propio predicado veritativo.

Intuiciones de Kripke

Estas son parte de las intuiciones que la teoría de puntos fijos de Kripke pretende rescatar:

1. La oración del Mentiroso no puede ser ni verdadera ni falsa, pero es una oración.
2. Hay afirmaciones riesgosas, afirmaciones tales que si las circunstancias empíricas son suficientemente desfavorables, podrían expresar una afirmación autocontradictoria. Por caso, si Juan afirmara:

- (1) La mayor parte [es decir, una mayoría] de las afirmaciones de Nixon acerca de Watergate son falsas.

Asumamos, ahora, que las afirmaciones de Nixon acerca de Watergate, a su vez, se hayan repartidas por igual entre las verdaderas y las falsas si consideramos todas las que de afirmación realiza salvo:

- (2) Todo lo que dice Juan sobre Watergate es falso

Si suponemos que toda afirmación que Juan hace sobre Watergate es verdadera excepto, tal vez,

En este caso, tanto (1) como (2) son verdaderas si y sólo si son falsas. Dice Kripke [35]: "una teoría adecuada debe permitir que sean riesgosos nuestros enunciados que contienen la noción de verdad; corren el riesgo de ser paradójicos si los hechos empíricos son extremadamente (e inesperadamente) desfavorables". Lograr esto es permitir que una oración del estilo de (1) y (2), en particular (y que cualquier otra oración) pueda "buscar su propio nivel". Nótese que el nivel de una oración como (2) tiene que ser mayor que el nivel de la oración de más alto nivel de las emitidas por Juan sobre Watergate. Cuando se emiten afirmaciones de este estilo, no se tiene una idea precisa acerca del nivel al que pertenece. No obstante lo cual, se está, correctamente en muchos casos, dispuesto a afirmarla, porque alguien como Nixon, con (2), quiere referirse a toda afirmación emitida por Juan sobre Watergate, no importa el nivel al que esta pertenezca.

3. Permita casos de oraciones autorreferenciales.
4. De cuenta de el parecido y la referencia entre El Mentiroso ("esta oración es falsa") y El Honesto ("esta oración es verdadera"), oración no paradójica pero sin condiciones de verdad determinadas.

5. Explicar la diferencia entre las oraciones sin condiciones de verdad determinadas y las que sí las tienen; es decir, dotar de contenido a la idea de "fundamentación".

Puntos fijos

Kripke, entonces, se propone construir lenguajes que, al permitir vacíos de verdad y predicados parcialmente definidos, pueda contener su propio predicado de verdad como uno de tales predicados. A tales predicados, interpretados adecuadamente, los llama "puntos fijos". Todos ellos respetarán las siguientes restricciones: "Dado un dominio no vacío D , un predicado monádico $P(x)$ se interpreta mediante un par (S_1, S_2) de conjuntos disyuntos de D . S_1 es la extensión de $P(x)$ y S_2 es su anti extensión. $P(x)$ ha de ser verdadero de los objetos en S_1 , falso de aquellos en S_2 , de otra manera será indefinido. La generalización para predicados n -ádicos es obvia". El predicado de verdad será un caso de tales predicados monádicos. Por otra parte, la semántica empleada para tal lenguaje será el de la lógica trivalente fuerte de Kleene (aunque nada impide usar otros tipos de semánticas. Kripke considera que una lógica supervaluacionista, por caso, sería igualmente efectiva, en lo esencial). Las constantes lógicas recibirán la interpretación esperada. Así, por caso, " $\neg P$ es verdadera (falsa) si P es falsa (verdadera), y es indefinida si P es indefinida. Una disyunción es verdadera si al menos uno de los disyuntos es verdadero, sin importar si el otro de los disyuntos es verdadero, falso o indefinido; es falsa si ambos disyuntos son falsos, de otra manera es indefinida. (...) $(\exists x) A(x)$ es verdadera si $A(x)$ es verdadera para alguna asignación de un elemento de D a x ; falsa si $A(s)$ es falsa para todas las asignaciones a x , de otra manera será indefinida". El resto de las constantes pueden definirse en términos de las (muy someramente) presentadas.

Lo siguiente da una aproximación a la "idea de punto fijo" Sea ' L ' un lenguaje de primer orden clásico, interpretado, con una lista numerable de predicados primitivos, suficientemente rico como para expresar en L su propia sintaxis. Ampliamos L a L^* , añadiéndole un predicado $T(x)$ cuya interpretación se definirá parcialmente por un conjunto parcial (S_1, S_2) —donde el primer término es la extensión y el segundo la antiextensión. $L^*(S_1, S_2)$: L^* , con $T(x)$ interpretado (parcialmente) por (S_1, S_2) . Sea ahora $S'_1 =$ el conjunto de oraciones verdaderas de $L^*(S_1, S_2)$; sea $S'_2 =$ el conjunto de oraciones falsas y de elementos que no son oraciones de $L^*(S_1, S_2)$. Dice Kripke: "La elección de (S_1, S_2) determina de manera única a S'_1 y a S'_2 ". Es decir, si dentro de S_1 está el correlato de la oración 'la nieve es blanca', dentro de S'_1 estará 'la nieve es blanca' es verdadera'. Ahora bien: un punto fijo es todo par (S_1, S_2) tal que $S_1 = S'_1$ y $S_2 = S'_2$. (Con lo que se ve que un punto fijo es el predicado de verdad de un lenguaje tal que ese predicado de verdad está en el propio lenguaje.)

El criterio significativo oracional expuesto por Kripke

"La significatividad de una oración o el carácter de estar bien formada, radica en el afirmación de que hay circunstancias especificables bajo las que tiene condiciones de verdad determinadas (bajo las que expresa una proposición)..."

¿Qué significa "condiciones de verdad determinadas"? Significa que hay situaciones especificables -en correlatos formales como modelos o puntos fijos- en los que la oración en cuestión es:

1. Verdadera, o falsa. El problema con esta lectura de "condiciones de verdad determinadas" es que El Mentiroso no sería significativo. ¿En qué modelos o puntos fijos sería la oración de El Mentiroso verdadera? ¿En qué situaciones sería falsa?, en ninguna. Pero entonces, ¿en qué sentido puede decirse que eso es una oración? Si entendemos que el párrafo de Kripke establece condiciones necesarias y suficientes de significatividad, o al menos condiciones necesarias, entonces El Mentiroso, esa presunta oración del lenguaje natural, no es una oración. ¿Puede defenderse su carácter oracional, puede replicarse a esta crítica? Por supuesto. ¿Puede decirse, como quiere Kripke, que El Mentiroso sería una oración? Sí. Pero hay que entender 'valor de verdad determinado' de esta otra manera:
2. Verdadera, o falsa, o indeterminada. El Mentiroso sería significativo. Puede, por ejemplo, decirse que es una oración porque su valor de verdad es indeterminado, y de afirmación es el único valor de verdad que puede tener. Esta es una solución que reformula lo que creíamos que significaba la expresión "condiciones de verdad determinadas". Esta es una salida admisible, pero no es la aquella por la que Kripke parece optar.

2.6 Redes semánticas

Aunque las redes semánticas permiten modelar conocimiento, en este trabajo no se utilizan, debido a que en esta tesis se van a utilizar las jerarquías. El punto principal de usar las jerarquías es porque el cálculo de inconsistencia requiere que las variables cualitativas que se están utilizando se modelen en una jerarquía (un árbol con ciertas propiedades) y la posición donde se encuentran en la estructura jerárquica es un valor importante para determinar la inconsistencia. Sin embargo, a continuación se presenta una introducción al tema de las redes semánticas.

Las redes semánticas [29] fueron inventadas por Richard H. Rchens de Cambridge LanguageResearchUnit en 1956 como un lenguaje intermedio entre la máquina y el lenguaje natural. Éstas fueron desarrolladas por Robert F. Simmons en System Development Corporation en los 60's y más tarde por Collins y Loftus.

Los responsables de los primeros esquemas de representación formalizados fueron Quillian (1968) y Shapiro & Woddmanssee (1971).

Una red semántica es una notación gráfica para representar conocimiento en patrones de nodos y arcos interconectados. Implementaciones en computadora sobre redes semánticas fueron desarrolladas primero por inteligencia artificial y traducción de máquinas, pero anteriormente han sido usadas en la filosofía, psicología y la lingüística.

Una red semántica es más intuitiva y cercana al pensamiento humano, los conocimientos se organizan en base a conceptos. Las redes semánticas no siguen estándares, por lo que dos personas distintas pueden hacer diferentes interpretaciones de la misma red.

Hay diversos tipos de relaciones semánticas [51] como la hiponimia, hiperonimia, la meronimia, etc.

Dado un conjunto de conceptos, elementos semánticos o términos relacionados semánticamente mediante alguna relación semántica, una red semántica representa estas relaciones en forma de grafo. Explícitamente, dado un conjunto de términos $\{t_1, t_2, \dots, t_n\}$ y cierta relación semántica simétrica entre ellos se construye un grafo $G = (V, A)$ cumpliendo las siguientes condiciones:

1. El conjunto V es el conjunto de vértices o nodos del grafo. Este conjunto estará formado por n elementos (tantos vértices como términos relacionables). A cada uno de los vértices del grafo representará uno de los términos, por tanto los vértices del grafo se llamarán: t_1, t_2, \dots, t_n .
2. El conjunto A es el conjunto de aristas o líneas del grafo. Dados dos vértices (términos) del grafo t_i y t_j existirá una línea a_{ij} que une los vértices t_i y t_j si y sólo si los términos t_i y t_j están relacionados.

Si la relación no es simétrica, entonces se usan grafos dirigidos para representar la relación (ver fig. 2).

Ejemplo:

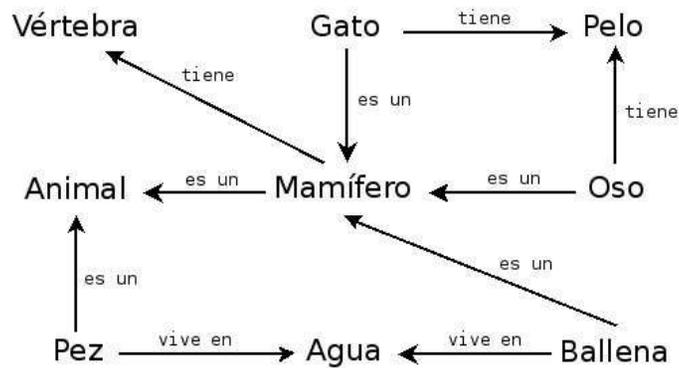


Figura 2. Representación de una red semántica.

Existen tres categorías de redes semánticas:

1. **Redes IS-A**, en las que los enlaces entre nodos están etiquetados.
2. **Grafos conceptuales**: en los que existen dos tipos de nodos: de conceptos y de relaciones.

3. **Redes de marcos:** en los que los puntos de unión de los enlaces son parte de la etiqueta del nodo.

2.7 Teorema de Arrow

El teorema de la imposibilidad de Arrow (TA) constituye un tópico clásico dentro de la economía neoclásica normativa, o Economía del Bienestar. Este sitio le corresponde por haber mostrado que, a partir de supuestos plausibles y de sentido común, que no es posible construir un mapa de elección social a partir de preferencias individuales acerca del conjunto social sin impedir que algún individuo imponga sus preferencias a los demás (esto es, que se constituya en dictador).

El Teorema de Imposibilidad de Arrow (o Paradoja de Arrow), demuestra que no es posible diseñar reglas para la toma de decisiones sociales o políticas que obedezcan a un cierto conjunto de criterios "racionales".

Arrow define una preferencia o criterio "racional" como aquella que cumple con dos axiomas: la reflexividad y la transitividad. Estas propiedades permiten crear una clasificación entre las alternativas, así como aquellas propiedades deseables de los patrones de preferencias, es decir, un orden "racional" de preferencias. Su objetivo final es que las preferencias sociales satisfagan el axioma I y II, y sean reflejadas por una función de bienestar social [36].

Axioma I. $\forall x, y, xRy \vee yRx$.

Una relación R que satisface el axioma I se dirá que está conectada. Este axioma sostiene cuando $x = y$, así como cuando x es distinto de y , ordinariamente se dice que x es indiferente a él mismo para cualquier x , lo cual implica que xRx .

Axioma II. $\forall x, y, z, xRy \wedge yRz$ implica que xRz .

Esta propiedad de consistencia en las preferencias entre diferentes pares de alternativas se puede expresar como; si x es preferido o indiferente a y y y es preferido o indiferente a z , entonces x debe ser preferido o indiferente a z .

Una relación que satisface ambos axiomas se llama de orden débil o simplemente ordenada. Una relación que tiene las dos propiedades, crea una clasificación de varias alternativas. El adjetivo "débil" se refiere a que el orden no excluye indiferencia, es decir, los dos axiomas no excluyen la posibilidad de que para alguna distinta x y y , ambas xRy y yRx . Un orden fuerte, es una clasificación en la cual los lazos no son posibles. Un orden débil se considera una generalización del concepto "mayor que o igual a" aplicado a los números reales; un orden fuerte generaliza el concepto "mayor que".

El Teorema de Imposibilidad de Arrow establece que una sociedad necesita acordar un orden de preferencia entre diferentes opciones. Cada individuo en la sociedad tiene su propio orden de preferencia personal. El problema es encontrar un mecanismo general (una regla de elección social) que transforme el conjunto de los órdenes de preferencia individuales en un orden de preferencia para toda la sociedad, el cual debe satisfacer varias propiedades deseables.

Arrow reafirma la formulación del profesor Bergson de hacer juicios de bienestar, pero con su propia terminología. Los diferentes argumentos de función de bienestar social son los componentes que Arrow denomina el estado social, que esencialmente describe el proceso de asignar una utilidad social numérica a cada estado social, el objetivo de la sociedad descrita, entonces busca maximizar la utilidad social o de bienestar social sujeto a limitaciones tecnológicas o cualquier recurso, o dicho de otro modo, que elige el estado social dando el bienestar social más alto posible en el medio ambiente. La medida de bienestar social no se tiene porque suponer; lo que importa es la existencia de un orden social que satisface los axiomas I y II.

Definición. Por una función de bienestar social se entiende, un proceso o regla que, para cada conjunto de orden individual R_1, \dots, R_n por estados sociales alternativos (un orden para cada individuo), establece un orden social correspondiente de estados sociales alternativos R .

R representa el orden social correspondiente al conjunto de orden individual R_1, \dots, R_n . Aquí el orden individual se refiere a los valores de los individuos.

Un mecanismo político ideal debe tener cinco características:

- **Dominio no restringido o universalidad:** la regla de elección social debería crear un orden completo por cada posible conjunto de órdenes de preferencia individuales (el resultado del voto debería poder ordenar entre sí todas las preferencias y el mecanismo de votación debería poder procesar todos los conjuntos posibles de preferencias de los votantes).

El sistema tiene que ser válido para cualquier posible votación.

Entre todas las alternativas, hay un conjunto S de tres alternativas tales que, para cualquier conjunto de orden individual T_1, \dots, T_n de alternativas en S , hay un conjunto admisible de órdenes individuales R_1, \dots, R_n de todas las alternativas tales que, para cada individuo i , $xR_i y$ si y sólo si $xT_i y$ para $x, y \in S$.

Esta condición es una restricción en la forma de función de bienestar social ya que por definición de un conjunto admisible de orden individual, se requiere que, para un rango suficientemente ancho de orden individual, la función de bienestar social da lugar a un orden social verdadero.

- **Asociación positiva de los valores individuales y sociales o monotonía:** si un individuo modifica su orden de preferencia al promover una cierta opción, el orden de preferencia de la sociedad debe responder promoviendo esa misma opción o, a lo sumo, sin cambiarla, pero nunca degradándola (Un individuo no debería perjudicar a un candidato al promoverlo).

En ningún caso añadir un voto a favor de una determinada opción puede perjudicarla. Se admite, sin embargo, que no varíe el resultado.

Esto es, la función de bienestar social es tal que el orden social responde positivamente a alternancias en valores individuales o al menos no negativas.

- **Independencia de las alternativas irrelevantes:** añadir o considerar nuevas alternativas a las ya existente, por ejemplo, A, B y C, no debe variar la ordenación entre esas tres.

Si se restringe la atención a un subconjunto de opciones y se les aplica la regla de elección social a ellas solas, entonces el resultado debiera ser compatible con el correspondiente para el conjunto de opciones completo. Los cambios en la forma que un individuo ordene las alternativas "irrelevantes" (es decir, las que no pertenecen al subconjunto) no debieran tener impacto en el ordenamiento que haga la sociedad del subconjunto "relevante".

Si se eliminan unas cuantas opciones, la posición relativa del resto no debería variar al volver a aplicar el sistema de voto. Es decir, si A va delante de B seguirá delante aunque se quiten unas cuantas opciones y se vuelva a aplicar el proceso.

La condición de independencia de alternativa irrelevante implica que en un sentido generalizado, todos los métodos de elección social son del tipo de votación.

Esto es, si se considera $C(S)$, la función de elección derivada del orden social R , siendo la opción la cual la sociedad actualmente haría si se en fretara con un conjunto de alternativas S , entonces al igual que para una persona, la elección hecha desde cualquier ambiente fijo S debería ser independiente de cualquier existencia de alternativas fuera de S .

Por ejemplo, suponga que un sistema de elección ha sido ideado, por el cual cada lista enumera todos los candidatos por orden de preferencia, entonces por un procedimiento de pre asignación, el candidato ganador resulta de esas listas. Suponga se tiene una elección con cierto número de candidatos, cada individuo presenta su lista de preferencias, y uno de los candidatos muere.

La elección social debe hacerse teniendo cada una de las listas de preferencias individuales, tapando el nombre del candidato muerto, considerando sólo los ordenamientos de los nombres restantes a través del procedimiento para determinar al ganador. Esto es, la elección debe hacerse entre el conjunto S de candidatos

sobrevivientes e independiente de las preferencias de los individuos de los candidatos que no están en S . Asumir otro caso, sería hacer el resultado de la elección dependiente de la circunstancia accidental de si un candidato muere antes o después de la fecha de votación. Por lo tanto, se requiere de la función de bienestar social que la elección realizada por la sociedad forma un ambiente determinado dependiente sólo de los ordenes individuales entre las alternativas de ese ambiente.

- **No imposición o criterio de Pareto débil (soberanía del ciudadano):** Cada orden de preferencia de la sociedad debe ser realizable por algún conjunto de órdenes de preferencia individuales. (Cada resultado debe ser realizable de alguna forma). Esto quiere decir, que el sistema debe permitir que cualquier posible resultado sea en efecto alcanzable. Es decir, no puede haber ningún resultado prohibido por la naturaleza del sistema.

Si A resulta socialmente preferido a B , debe existir al menos un individuo para el cual A sea preferido a B . Esto implica que la regla no va contra el criterio de unanimidad.

Se desearía asumir que los individuos en la sociedad son libres de elegir, pero variando sus valores entre las alternativas disponibles. Es decir, no se quiere que la función de bienestar social sea tal que impida de expresar una preferencia de alguna alternativa dada sobre otra.

Una función de bienestar social sería dicha para ser impuesta si, para algún par de alternativas distintas x y y , xRy para cualquier conjunto de orden individual R_1, R_2, \dots, R_n , donde R es el orden social correspondiente a R_1, R_2, \dots, R_n .

La función de bienestar social no será impuesta.

- **ausencia de dictadura:** la regla de elección social no debería limitarse a seguir el orden de preferencia de un único individuo ignorando a los demás.

Ningún ciudadano puede tener la última palabra en la decisión final.

Una segunda forma de elección social no de carácter colectivo es la elección por dictadura. Esto significa que las elecciones sociales están basadas solamente en las preferencias de un hombre. Esto es, cuando el dictador prefiere x a y , también lo hace la sociedad.

Una función de bienestar social se dice dictatorial, si existe un individuo i tal que, $\forall x$ y y , $xP_i y$ implica que $xP y$ independientemente del orden R_1, R_2, \dots, R_n de todos los individuos i , donde P es la correspondiente relación de preferencia social R_1, R_2, \dots, R_n .

La función de bienestar social no será dictatorial.

El teorema de Arrow dice que si el cuerpo que toma las decisiones tiene al menos dos integrantes y al menos tres opciones entre las que debe decidir, entonces es imposible diseñar una regla de elección social que satisfaga simultáneamente todas estas condiciones.

El Teorema de Arrow no se ajusta al trabajo realizado en esta tesis, debido a los siguientes aspectos:

- El teorema de Arrow se utiliza para votaciones donde existen propiedades que ese criterio debe satisfacer. Las votaciones se expresan como una lista de preferencias sin igualdad.

Por ejemplo. Si se quiere elegir sobre la popularidad de Obama, McCain y Castro, se tienen las siguientes votaciones:

Boleta 1: (Juan Pérez) obama>mcCain> Castro > Hitler. Significa que el votante 1 prefiere a Obama más que a todos, en segundo lugar prefiere a McCain, y en último lugar a Hitler.

Boleta 2: (Ana Rodríguez) McCain > Obama > Hitler > Castro

.

.

.

Boleta n.

Cuando los votos se expresan de la manera anterior, entonces ocurre necesariamente uno de los criterios arriba mencionados ocurre.

1. Se escoge a alguien decididamente impopular.
2. En ningún caso añadir un voto a favor de una determinada opción puede perjudicarla.
3. Agregar o considerar nuevas alternativas no debe variar el orden que se esté llevando a cabo.
4. Un cambio sin consecuencias (por ejemplo, la boleta 1 cambia su voto, ahora prefiere a Castro sobre Obama, antes era al revés) hace que McCain gane.
5. Hay un dictador que tiene la última palabra, es decir, siempre impone su voluntad.

Si la inconsistencia se utilizara para votaciones, las boletas serían de la siguiente manera:

Boleta 1. (bicicleta) bicicleta = 100 triciclo = 90 patín = 90 submarino = 15

Boleta 2. (triciclo) triciclo = 100bicicleta = 85

.

.

.

Boleta n (submarino)

La figura 3 representa una jerarquía de algunos valores cualitativos que representan transportes, donde se puede observar que los datos de las boletas arriba mencionados están en la jerarquía Transporte.

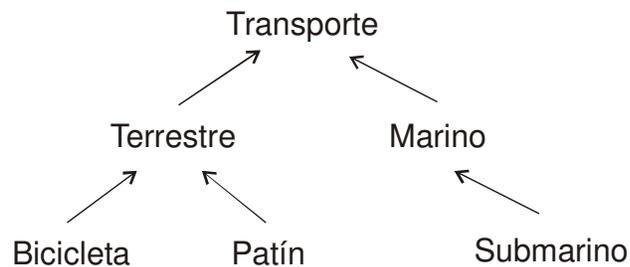


Figura 3.Jerarquía de Transporte.

Los valores de confusión y de inconsistencia se obtienen de manera diferente a las votaciones y para ello se utilizan forzosamente jerarquías de valores cualitativos. En esta teoría todos los observadores tienen la misma credibilidad y de estos se obtiene la inconsistencia por lo que no existen un valor que se imponga por sí solo sin tomar en cuenta a los demás. Además el Teorema de Arrow no se aplica para “votaciones” que usan la inconsistencia.

2.8 Análisis de Cluster o Reconocimiento de Patrones

El análisis de cluster, conglomerados o reconocimiento de patrones tiene como objetivo agrupar individuos o muestras en grupos que sean lo más homogéneos o similares, es decir agrupar individuos similares en un mismo grupo, pero heterogéneos o disímiles con los otros grupos formados².

Es una técnica de análisis exploratorio, es decir no tiene propiedades de inferencia, por tanto los resultados obtenidos sirven solo para la muestra de diseño. Se la puede clasificar como una técnica de aprendizaje no supervisado que detecta estructuras sin previamente imponer restricciones por parte del experto o analista.

Existen dos grandes tipos de cluster:

Jerárquicos: Para muestras más pequeñas. El algoritmo clasifica a los individuos en un grupo, una vez que un individuo entra a ese grupo no salen más de él, aunque el algoritmo sigue agrupando con el resto de los individuos u objetos que no se han agrupado aún.

No Jerárquicos (K medias): Utilizados cuando la muestra es muy grande o para refinar algún resultado obtenido mediante un método jerárquico. En el método de K medias los

² <http://egkafati.blogoo.com/content/view/195004/Analisis-de-cluster-o-reconocimiento-de-patrones.html>
“Clustering o Análisis de Patrones”

expertos deben definir el número de grupos ya sea de acuerdo al problema por expertiz o de acuerdo a algún análisis previo. Aquí los individuos que ingresan a un grupo según el algoritmo pueden moverse hasta que se obtenga la mejor solución.

¿Cómo se analizan?

Se construye unos datos con una serie de variables para cada sujeto u objeto y de acuerdo a estas variables se mide la similitud o disimilitud entre ellos.

Etapas de un análisis de cluster

- Selección de la muestra de datos
- Selección y transformación de variables a utilizar
- Selección del concepto de distancia o similitud y medición de las mismas.
- Selección y aplicación del criterio de agrupación
- Determinación de la estructura correcta (Número de grupos)

¿Qué se obtiene?

Se obtienen grupos internamente homogéneos con un centroide o perfil medio del grupo.

Sus aplicaciones podrían servir para responder ciertas preguntas tales como:

¿Es posible identificar grupos de clientes que les pueda interesar obtener ciertos productos que se van a lanzar al mercado?

¿Es posible clasificar a los consumidores en función de las percepciones que tienen sobre los atributos de una marca por ejemplo calidad global, precio, postventa, nivel de servicio, variedad, etc?

¿Es posible agrupar clientes de una cartera para identificar focos de riesgo?

En este trabajo se especifican dos métodos para crear clusters de un conjunto de afirmaciones y se calcula el centroide o centroides que el cluster genera. Esto es lleva a cabo con la finalidad de obtener la mejor solución al evento que se está observando y si el evento pudiera tener uno o más centroides como resultado.

Capítulo 3. Fundamentos teóricos

En este capítulo se introduce a los temas de teoría de la medida, inconsistencia, jerarquías y confusión que son las áreas temáticas que se van a utilizar.

3.1 Teoría de la medida

La medición [45, 46, 48] es una de las nociones que la ciencia moderna ha tomado al sentido común. El uso común de la idea de medida es tan natural en la conducta del hombre que a menudo pasa inadvertida. ¿Qué es este “sentido común” que nos lleva al concepto de la medida?

El lenguaje de la medida es el lenguaje de la comparación, y la medida surge de la comparación. Conscientemente o no, siempre estamos comparando cosas presentes a nuestra conciencia.

Medir es algo que todos hacemos a diario muchas veces. Lleva consigo mucho más que la estrecha actividad de hacer mediciones numéricas de longitud, área o volumen.

Manuel pone pasta a su cepillo de dientes y llega un momento en que deja de hacerlo porque ya es demasiada. Daniela despierta y mira hacia la ventana y exclama ¡Cuánta luz, es de día!

Los ejemplos anteriores no constituyen necesariamente el concepto común que se tiene de lo que es medir. Sin embargo, en cada uno de estos casos se ha efectuado cierto tipo de comparación.

Manuel usó su cepillo de dientes como unidad de medida, Daniela se dio cuenta que ya había amanecido por la intensidad de la luz.

Comparar unas cosas con otras es tan natural para el ser humano como la acción de respirar. La comparación es la base de la medida. Hacemos comparaciones tan sencillas como la liebre se mueve más rápido que la tortuga hasta comparaciones expresadas en términos de medidas numéricas precisas.

A medida que analizamos las cosas implica una acción de comparación. Además la mayoría de estas comparaciones son de naturaleza aproximada.

Procedimientos para hacer comparaciones.

¿Podemos identificar las etapas fundamentales incluidas en el proceso de medir? A menudo no tenemos conciencia de las cosas que hacemos cuando comparamos, pero el entendimiento del proceso es importante porque los mismos pasos se repiten una y otra vez. A continuación se toca el proceso de cómo se hacen las comparaciones cualitativas y cuantitativas.

Comparaciones cualitativas

Al hacer una comparación de dos objetos, se debe identificar alguna propiedad común que nos proporcione una base de comparación. Por ejemplo, se quisiera comparar la belleza de una flor, en este caso se está utilizando la belleza de la rosa como base de comparación.

Comparaciones cuantitativas

Una propiedad física que se desea medir, primero debe observarse e identificarse. Por ejemplo, la sensación de “frío” en una nieve y “caliente” en un café. Así se desarrolla una conciencia de temperatura como unidad de medida.

Otras propiedades físicas que se pueden presentar para su medición incluyen el peso, la longitud, el área, el volumen, la densidad, la viscosidad, etc.

Después de identificar alguna propiedad común a dos cosas que se desean comparar, se intenta medir en alguna manera el grado de semejanza y el de diferencia.

Definición de **medir**. “Medir es asignar números a los objetos según cierta regla” (Stevens, 1951).

De manera que “los números asignados en la medición, no representan propiamente cantidades, sino relaciones” (Jáñez, 1989, p. 402).

Tipos de medidas

En la teoría de escalas de medición (1946), Stevens presenta una jerarquía de escala de datos basados en su significado sobre diferentes clases de transformación. Por ejemplo, asumir una escala, s , usada para asignar números reales en \mathbb{R} a los elementos de un conjunto P , de juicios observados de modo que para toda i y j en P , $s(i) > s(j)$, sí y sólo si i se prefiere a j . Esto es, si “ $>$ ” significa “es preferido a”, entonces

$$p \xrightarrow{s} \mathbb{R} \text{ tal que } i > j \leftrightarrow s(i) > s(j), \forall i, j \in P. \quad (1)$$

Cualquier transformación monótona de los valores $s(i)$, $s(j)$ se permite para datos ordinales.

- a) Escala ordinal. Si cualquier transformación de los valores de la escala que conserva su orden numérico produce otra escala que comparte la misma relación uno a uno en la comparación entre objetos (usando $>$) y la comparación entre correspondientes escala de valores (usando $>$). Stevens utilizó el término aceptable para describir el

conjunto de transformaciones que conservan la correspondencia ordinal en (1). La escala ordinal pone a los elementos en fila. Por ejemplo, por orden de tamaño; en los deportes existe primer lugar, segundo lugar, tercer lugar; lugar que ocupa un país con respecto al número de medallas ganadas; bello, feo, etc. Las escalas ordinales son discontinuas, la variable tiene solo valores discretos, pero no valores intermedios entre ellos. Una transformación f es aceptable para una escala ordinal, sí y solo si

$$s(i) > s(j) \Rightarrow f[s(i)] > f[s(j)]$$

- b) La escala de intervalo involucra una diferencia (-) en lugar del operador de orden (>), así el conjunto de transformaciones aceptables para las escalas de intervalo acepta diferencias relativas. Esta escala carece de cero absoluto, de modo que no tiene sentido dividir o multiplicar los valores medidos con ella, ni calcular la proporción de dos valores. En lugar de ello, las diferencias o las distancias entre valores son conceptos de apreciación. Ejemplos de escalas de intervalo son la escala (continua) de un termómetro y la escala (discontinua) de años, que de hecho tienen alguna forma de punto cero, pero arbitraria. Del mismo modo, cuando medimos personas, el valor cero raramente es razonable: no podríamos decir que "Diana es dos veces más inteligente que Carlos", incluso si sus resultados en un test de inteligencia fuesen de 150 y 70 respectivamente. Especialmente, la transformación f es aceptable para escalas de intervalo, sí y sólo si, hay una constante c tal que:

$$s(i) - s(j) \Rightarrow c\{f[s(i)] - f[s(j)]\}$$

Por ejemplo, hay instituciones que manejan un intervalo para las calificaciones aprobatorias (de ocho a diez) [12, 14].

- c) La escala de razón conserva proporciones relativas incluye el punto de cero absoluto, mientras que raramente hay valores negativos. La edad, altura y peso de una persona son ejemplos de esto. A las mediciones les pueden ser aplicadas la razón por la que es llamada escala de proporción. Así las transformaciones aceptables satisfacen:

$$\frac{s(i)}{s(j)} = \frac{cf[s(i)]}{f[s(j)]}$$

Para alguna constante c . Por ejemplo, defino sistemas numéricos semi abiertos y les pongo números.

- d) Las escalas nominales se encuentran en el otro extremo de la jerarquía. No siempre requieren la asignación de valores numéricos, sino solo de identificadores únicos (cifras, letras, colores, etc.). Estas escalas son invariantes sobre cualquier

transformación que acepte la relación entre individuos y sus identificadores. En esta escala se le dan nombres a las cosas. Ejemplo a azul, rojo, verde, etc. Se le asigna un número ya sea de acuerdo a la frecuencia del color. Otro ejemplo, al estudiar la productividad en un taller dado, la producción se puede medir como número de artículos acabados por mes, y cantidad de trabajo que puede ser medido en horas y hombres por mes. Ahora podemos utilizarlas para definir nominalmente un tercer concepto: $\text{productividad} = \text{cantidad de productos} / \text{cantidad de trabajo}$.

Computacionalmente se les asigna un número.

En la presente tesis se utiliza la escala nominal porque hay identificadores a los cuales se les llama variables cualitativas y para poder calcular la inconsistencia se les asigna un número.

3.2 La inconsistencia

En el área de Ciencias de la Computación la inconsistencia no es deseable. En las bases de datos, bases del conocimiento y especificaciones de software se quiere que estén libres de inconsistencia, por lo que tratan de eliminarla de cualquier forma posible. Otros tratan de aislarla y resolverla localmente. Datos de la forma q y $\neg q$ para cualquier proposición q no pueden existir juntas y se debe resolver. Existen casos donde q y $\neg q$ pueden ser aceptables juntos y de aquí la necesidad de no ser resueltos.

El desarrollo de sistemas grandes y complejos envuelve el manejo de la inconsistencia [19]. Las inconsistencias pueden surgir en las etapas del desarrollo del software como cuando existen requerimientos contradictorios, en el diseño o también en la implementación. Existe un amplio rango de posibles causas de inconsistencia y conflictos en el desarrollo del software. Muchas de ellas se deben a la heterogeneidad de productos que se están desarrollando. En el desarrollo de software la inconsistencia puede surgir entre los participantes del desarrollo debido a:

- Las diferentes vistas que tiene,
- los diferentes lenguajes que hablan,
- las diferentes estrategias de desarrollo que usan,
- las diferentes etapas de desarrollo que dirigen, y
- los diferentes objetivos técnicos, económicos y políticos que quieren alcanzar.

Definiciones de inconsistencia es "Una inconsistencia ocurre si y sólo si una regla (consistencia) se ha roto". Así una regla describe alguna forma de relación o afirmación que es requerido para llevarse a cabo. (Nuseibeh). Otra definición es "la falta de uniformidad entre cosas y partes" [13].

Se han examinado tres usos de tales reglas de inconsistencia:

1. Pueden describir relaciones sintácticas entre desarrollo de artefactos prescritos por un método de desarrollo [15].
2. Se pueden utilizar para prescribir relaciones entre los subprocesos en un proceso de desarrollo total, el cual también es una manera de coordinar las actividades de los desarrolladores creando diferentes estrategias de desarrollo [43].
3. Las reglas de consistencia también se pueden usar para describir relaciones definidas por el usuario que surgen como desarrollo de una especificación de un producto de software [42]. Esto es útil para capturar relaciones ontológicas entre productos de un proceso de desarrollo (por ejemplo, dos desarrolladores especificando un sistema de librería pueden utilizar el término “user” y “borrower” para referirse a la misma persona).

Una de las dificultades en el manejo de inconsistencia una vez que ha sido detectada, es identificar el tipo de inconsistencia. El proyecto CONMAN (configuration management) [19] intenta clasificar la consistencia en programas dentro de seis clases para facilitar el manejo de la inconsistencia:

1. Consistencia completa. Donde un sistema satisface las reglas que un lenguaje de programación específica para programas legales.
2. Consistencia de tipo. Donde un sistema satisface el tipo estático revisando reglas del lenguaje de programación
3. Consistencia de la versión. Cada sistema se construye usando exactamente una versión de cada archivo de código fuente lógico.
4. Consistencia de derivación. Donde un sistema es operacionalmente equivalente a alguna versión del sistema consistente.
5. Consistencia de enlace. Donde cada unidad de compilación es libre de tipo de errores estáticos, y cada referencia simbólica entre unidades de compilación es un tipo seguro de acuerdo a las reglas del lenguaje de programación.
6. Consistencia alcanzable. Donde todo el código y datos que pudieran ser accedidos o ejecutados invocando el sistema a través de sus puntos de entrada son seguros.

El sistema CONMAN checa para los seis tipos de consistencia automáticamente, y reacciona diferente dependiendo del tipo de inconsistencia detectada. Esto es apropiado para identificar un conjunto de inconsistencias que surgen a lo largo del desarrollo del software.

Blazer [37] propuso la noción de "toleratingin consistency" (tolerando inconsistencia), y lo hace con una técnica para crear formalismos que permitan a sistemas de software tolerar y manipular la inconsistencia. Blazer creó dos implementaciones para suavizar las restricciones de primer orden. La primera convierte la restricción original en un par de restricciones. La segunda implementación reemplaza la restricción original por una regla de inferencia la cual deduce el software si y sólo si el predicado de la restricción original ha sido violado.

Gabbay y Hunter sugieren "hacer la inconsistencia respetable" proponiendo que la inconsistencia sea vista como una señal para tomar acciones externas, o como señales para tomar acciones internas que activan o desactivan otras reglas [19, 20].

Narayanaswamy y Goldman [44] proponen "Lazyconsistency" como la base para el desarrollo de software cooperativo.

Actuando en presencia de la inconsistencia

Las aproximaciones para el manejo de inconsistencia, dirigen ésta en diferentes caminos. Éstas se describen a continuación [13].

- Ignorar la inconsistencia y continuar el desarrollo sin tomarla en cuenta.
- Engañar las partes inconsistentes del sistema siendo desarrolladas y continuar el desarrollo. Se puede alcanzar esto haciendo porciones inconsistentes del sistema o continuar el desarrollo en ciertas direcciones dependiendo del tipo de inconsistencia definido.
- Remover la inconsistencia en conjunto corrigiendo cualquier error o conflictos. Ésta depende de la identificación clara de la inconsistencia y asumir que las acciones requeridas para arreglar se conocen. Restaurando la consistencia completamente puede ser difícil de alcanzar, y es imposible automatizar completamente sin intervención del humano.
- Mejorar situaciones inconsistentes ejecutando acciones que perfeccionan esas situaciones e incrementar la posibilidad de una resolución futura.

Las aproximaciones basadas en lógica ofrecen contribuciones para el manejo de la inconsistencia y técnicas que calculan subconjuntos de inconsistencia de una especificación o una base de datos inconsistente. Éstas permiten a los desarrolladores continuar el desarrollo (para evitar información inconsistente), y aislar ésta información que puede ser analizada libremente. Las aproximaciones que están basadas en la lógica también facilitan el razonamiento en presencia de la inconsistencia.

Ignorar, resolver o rechazar la inconsistencia

Hunter [8] trata con la inconsistencia en reportes de noticias. Algunos toleran la inconsistencia. Sin embargo, algunas veces es necesario rechazarlas en reportes de noticias; otras veces las noticias son aceptadas con inconsistencias, pero tratadas con precaución. Si se tiene un grado de inconsistencia de un reporte de noticia puede ayudar a decidir cómo actuar en éste. Para analizar y razonar con información en noticias, toman los reportes en forma de reportes de noticias estructurados. Éstos son documentos en XML, donde los textos de entrada son restringidos a palabras individuales o frases sencillas, tales como nombres y terminología específica del dominio, y números y unidades. Por lo que los reportes de noticias no requieren de procesamiento del lenguaje natural. Mucha información se puede representar en la forma de reportes de noticias estructuradas incluyendo reportes del clima, reportes de negocios, resúmenes de artículos científicos, resultados de pruebas clínicas, bolsa de valores, reportes de operaciones en organizaciones, etc. La tarea inteligente basada en los reportes de noticias estructurados incluye:

- Formar la fusión de un reporte de noticias estructurado de un conjunto de reportes de noticias heterogéneos,
- buscar en reportes de noticias violaciones de expectativas, y;
- construir argumentos para y contra conclusiones basados en reportes de noticias conflictivas.

Un aspecto importante de analizar la inconsistencia es evaluar su significado. Por ejemplo, se tienen dos reportes de noticias que tratan del torneo de la copa del mundo, donde el primer reporte dice que ganó Brasil por dos goles a Alemania, y un segundo reporte dice lo contrario. Ésta es una clara y significativa inconsistencia. Ahora bien, se tienen dos reportes de noticias del mismo partido, en uno dice que el árbitro fue PierluigiCollina y el segundo reporte dice que fue Ubaldo Aquino. Esta inconsistencia se podría tomar como relativamente insignificante.

Las inconsistencias entre información en un reporte de noticia y un dominio del conocimiento puede decir cosas importantes a cerca del reporte de noticia. Por eso Hunter utiliza funciones significativas para dar un valor por cada posible inconsistencia que puede surgir en un reporte de noticia en un dominio dado. Por lo que usan 4 maneras:

- Rechazar los reportes que son muy inconsistentes,
- resaltar noticias inesperadas,
- enfocarse en reparar inconsistencias significativas, y
- monitorear fuentes de información para identificar fuentes que no son confiables.

3.3 Jerarquías y confusión

Las reglas que se mencionan en seguida serán las que se utilicen en jerarquías de conceptos para medir la inconsistencia. Se debe tener conocimiento primero de cómo representar los conceptos en jerarquías, por lo que se van a utilizar las siguientes definiciones y propiedades de jerarquías [39].

Una jerarquía es un conjunto ordenado parcialmente, es una colección de partes con relaciones asimétricas ordenadas en un todo. Es decir, los niveles superiores son los anteriores a los niveles altos, y la relación ascendente es asimétrica con respecto a la relación descendente.

Concepto de jerarquía

Definición 1. Conjunto de elementos. Es un conjunto E cuyos elementos están definidos explícitamente. Ejemplo {libro, zapato, pantalón, manzana}

Definición 2. Conjunto ordenado. Un conjunto de elementos cuyos valores están ordenados en una relación de < "menor que". {frío, tibio, caliente}.

Definición 3. Conjunto cubierto. K está cubierto por el conjunto E , si K es un conjunto de los subconjuntos $e_i \subset E$, tal que $\cup e_i = E$.

Cada elemento de E está en algún subconjunto $e_i \in K$. Si K no es conjunto cubierto de E , se puede añadir a un nuevo e_j , llamado "otros", que contiene todos los elementos de E y que no pertenecen a cualquiera de los e_j previos.

Definición 4. Conjunto exclusivo. K es un conjunto exclusivo si $e_i \cap e_j = \phi$, $\forall e_i, e_j \in K$. Estos elementos son mutuamente exclusivos, si K no es un conjunto exclusivo, se puede reemplazar éste cada dos traslapes $e_i, e_j \in K$ con tres: $e_i - e_j$, $e_j - e_i$ y $e_i \cap e_j$.

Definición 5. Partición. K es una partición del conjunto E si éste es ambos un conjunto cubierto de E y un conjunto exclusivo. Los miembros de K son mutuamente exclusivos y colectivamente exhaustivos a E . Cada elemento de E está en exactamente uno de e_j .

Definición 6. Variable cualitativa. Una variable simple-valuada que toma valores simbólicos. Tal como opuesto a numérico, vector o variable cualitativa. Es un valor que no puede ser un conjunto, aunque tal valor simbólico pueda representar un conjunto. Por ejemplo las variables cualitativas color, país; donde los valores simbólicos de estas variables pueden ser azul, México.

Definición 7. Para un nodo n en un árbol, las relaciones $\text{father_of}(n)$, $\text{son_of}(n)$, $\text{brother_of}(n)$, ascendant_of se definen como se espera.

Definición 8. Variable jerárquica. Una variable jerárquica es una variable cualitativa cuyos valores pertenecen a una jerarquía (el tipo de dato de una variable jerárquica es una jerarquía).

Tipos de jerarquías

Una jerarquía describe la estructura de valores cualitativos en un conjunto E . A continuación se definen las jerarquías simple, ordenada, de porcentaje y mixta.

Definición 8. Jerarquía simple. Una jerarquía simple (normal) es un árbol con una raíz E y si un nodo tiene hijos, éste forma una partición del padre.

Definición 9. Jerarquía ordenada. En una jerarquía ordenada, los nodos de algunas particiones obedecen una relación de orden.

Definición 10. Jerarquía de porcentaje. En una jerarquía de porcentaje, el tamaño de cada conjunto es conocido.

Definición 11. Jerarquía mixta. Una jerarquía mixta combina los tipos de jerarquía anteriores.

Propiedades y funciones en jerarquías

Las jerarquías de valores simbólicos permiten medir similitud entre estos valores, y el error cuando un valor es utilizado en lugar de otro.

Confusión no normalizada en utilizar r en lugar de s para jerarquías simples

Definición 12. Si $r, s \in H$, entonces la confusión de utilizar r en lugar de s, escrita en este trabajo como $CONF(r, s)$, es :

- $CONF(r, r) = CONF(r, s) = 0$, donde s es cualquier ascendente de r;
- $CONF(r, s) = 1 + CONF(r, father_of(s))$.

La medida confusión, cuenta las ligas descendentes desde r a s. A esta medida se le llama confusión y la función con la que se representa es CONF, la cual no es una medida de distancia, ni una ultra distancia. Sin embargo, confusión obedece a la ley del triángulo.

Por ejemplo, en la figura 4 se puede observar que $CONF(gato, animal) = 0$ porque el trayecto de gato hacia animal es ascendente y no genera confusión, debido a que, si utilizo gato en lugar de animal, un gato es un animal y no genera confusión.

Pero si hallo $CONF(animal, gato) = 3$ la confusión es grande, pues el recorrido de animal a gato son tres niveles en la jerarquía y por cada nivel hacia abajo cuenta como confusión 1.



Figura 4.Jerarquía de algunos animales.

Capítulo 4. Modelo para medir la inconsistencia de una bolsa de valores cualitativos

En la vida se presentan eventos³ como pueden ser sociales, físicos, matemáticos, etc. Cada ciencia analiza estos sucesos de acuerdo a su propia metodología.

En este trabajo se hace un intento por analizar los eventos particulares de la vida cotidiana como por ejemplo, en qué se transportó un individuo de su casa al trabajo, etc.

Estos eventos son descritos por observadores. Los **observadores** también llamados reporteros o informadores son personas que proporcionan información sobre el hecho ocurrido.

Ahora bien, la información sobre el suceso acontecido se reúne a través de las observaciones que para este trabajo se llamarán afirmaciones o afirmaciones atómicas. Una **afirmación** es un enunciado sobre el evento que expresa una medición o una observación simbólica de un aspecto (característica o propiedad) de la vida. Por ejemplo, de la información que se tiene sobre el cabello de Juan, pueden generarse varias afirmaciones como Juan tiene el cabello pelirrojo, Juan tiene el cabello castaño, Juan se pintó el cabello de rubio, etc.

Debido a que estas afirmaciones se toman como verdaderas, lo importante es saber cómo medir su aproximación a la descripción real del suceso. ¿Se puede tener grados de veracidad sobre estas afirmaciones?

Lo anterior se logrará encontrando la afirmación que menor contrariedad genere entre los observadores.

Hay que tomar en cuenta que el número de afirmaciones no es infinito; es decir, que están limitadas por el espacio y tiempo en que ocurrió el evento; y por el total de observadores que estuvieron presentes al haber ocurrido ese hecho.

Para poder calcular la discrepancia o inconsistencia entre las afirmaciones, se creó un modelo de inconsistencia MI, donde estas afirmaciones estarán representadas en una jerarquía a través de valores cualitativos. Los observadores crean la estructura jerárquica de valores cualitativos antes que las afirmaciones. Una vez que se tiene la jerarquía, los observadores utilizan los datos llamados valores cualitativos que existen en la estructura para la construcción de las afirmaciones.

Puede suceder que un valor genere una sola afirmación o que un valor tenga correspondencia con varias afirmaciones. Por ejemplo, de el valor cualitativo cabello

³Evento. Del latín eventos, con el mismo significado. Suceso de importancia social o personal. Hecho que ocurre en momento definido.

pelirrojo, se crea la afirmación Juan tiene el cabello pelirrojo, del valor cualitativo cristiano puede aparecer la afirmación Pedro fue cristiano, etc.

Las observaciones sobre cada afirmación van a construir una bolsa, donde por ser bolsa entiende un conjunto en el que pueden existir elementos repetidos. La bolsa permite que existan afirmaciones que aseveren el mismo valor; es decir, que contienen el mismo valor. Para el caso de la aplicación se le llamará bolsa de valores cualitativos. Para poder encontrar el valor que representa el menor descontento total, se calcula el descontento de cada valor con respecto a los demás obteniendo la confusión $conf(r, s)$, pero tomando en cuenta un valor llamado h que representa la altura del árbol jerárquico con el fin de normalizar al final la inconsistencia entre $[0,1]$. Por cada valor cualitativo existirá un valor de confusión total y sobre este último valor se va hallar el centroide de los valores cualitativos.

El **centroide** denotado por r^* , es un término que se utilizará en la jerarquía para representar a la afirmación cuyo cálculo de confusiones totales resulta ser la menor. Por lo tanto producirá la inconsistencia.

El centroide⁴ representa el consenso más aceptable entre los diferentes observadores. También se le puede llamar el valor más plausible o creíble sobre la afirmación. (Más adelante en este capítulo se detalla cómo se calcula el centroide).

Se puede decir que cada observador no tiene desacuerdo (está totalmente de acuerdo) con su propia afirmación reportada (confusión 0). Si un observador reporta una afirmación p y luego resulta que su periódico o jefe reporta la afirmación q , entonces ese observador estará en desacuerdo con q en un valor dado por $conf(q,p)$, la confusión originada por usar q en vez de p (p fue lo que ese observador reportó). Pues bien, r^* es la afirmación q que minimiza el descontento total o desacuerdo entre los observadores (la suma de los desacuerdos individuales), o más precisamente, entre las afirmaciones reportadas por los observadores.

La confusión promedio es el cociente de la confusión total dividida por el número de observaciones en la bolsa. Esto da idea del descontento o desacuerdo promedio que tienen los observadores cuyas afirmaciones se han "resumido" reportando en vez de ellos la afirmación q . Estos observadores reportaron afirmaciones p que difieren algo de q , por lo que cada uno tiene un cierto descontento expresado o medido por $conf(r^*, p)$. Habrá un valor q que minimice tal confusión promedio.

De lo anterior, se deduce que va haber un valor que sea el centroide y a su vez el que genere la inconsistencia menor sobre la bolsa de afirmaciones. Aunque no se descarta el hecho de que aparezca más de un centroide, debido a que presentan el mismo valor de confusión total.

⁴Hay un solo centroide (de una bolsa).

A partir de una observación se puede realizar el análisis de inconsistencia.

La figura 5, presenta un esquema de cómo se calcula la inconsistencia sobre una bolsa de valores cualitativos.

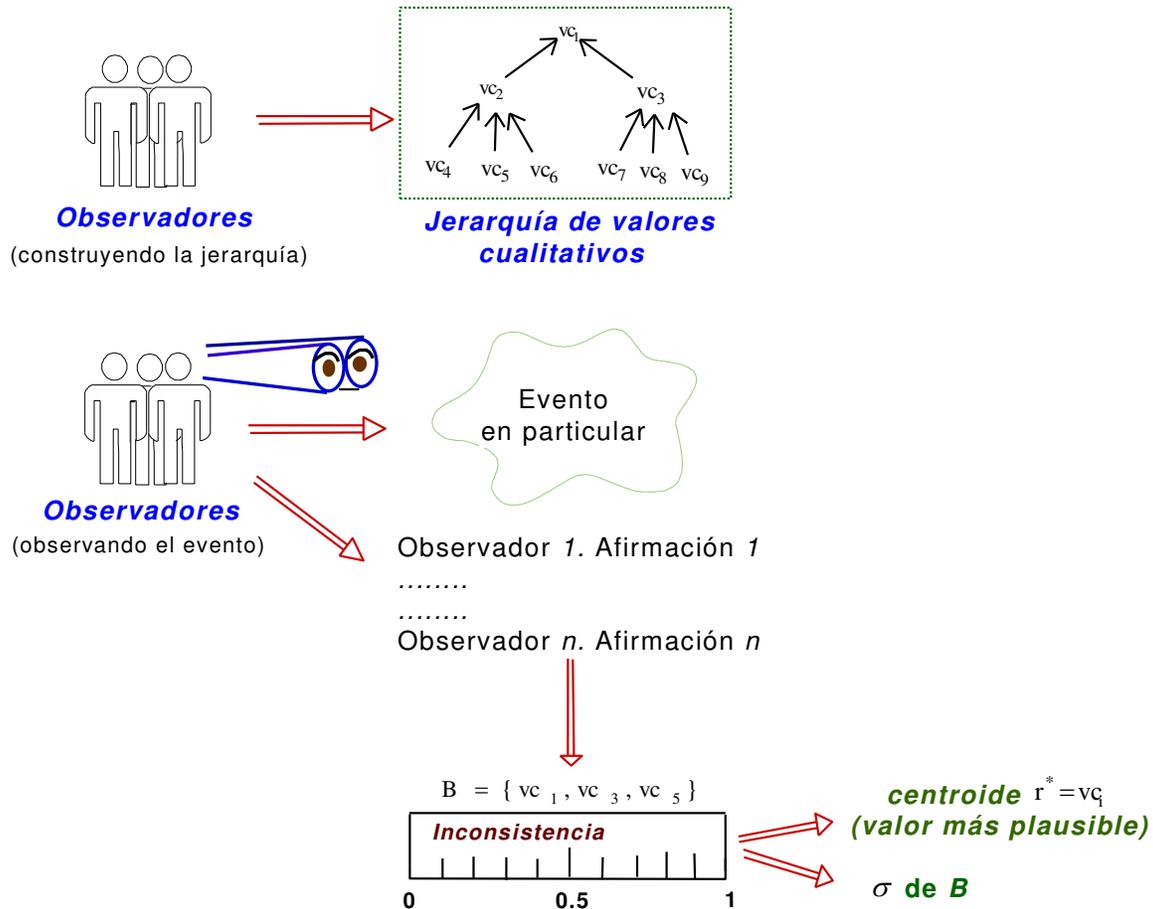


Figura 5. Esquema del cálculo de inconsistencia de una bolsa de valores cualitativos.

La figura anterior muestra los elementos esenciales para realizar el cálculo de inconsistencia como son los observadores, la jerarquía de valores cualitativos, el evento de donde resultan las afirmaciones de las cuales se obtendrá la inconsistencia. La regla en la figura simula la representación simbólica de la inconsistencia sobre una bolsa de valores cualitativos, cuyo valor estará en un intervalo de $[0,1]$.

4.1 Descripción formal del modelo de inconsistencia (MI)

Definición 1. Sea E un evento en particular el cual ocurre en un espacio y tiempo definido modelado por un número finito de afirmaciones $\{a_1, a_2, \dots, a_n\}$.

Definición 2. Sea a_i una afirmación que pertenece a $\{a_1, a_2, \dots, a_n\}$ y representa una observación sobre el evento.

Definición 3. Sea $I = \{i_1, i_2, \dots, i_n\}$ un conjunto de observadores o informantes que describe el conocimiento que se tiene sobre E.

Definición 4. Sea J la relación jerárquica de valores cualitativos, donde los elementos que pertenecen a la relación que son de la forma (h_a, h_b) y cumplen que h_a es ascendente de h_b . J' es la relación que cumple la condición h_a es descendente de h_b . Se utilizará el operador \succ para denotar la ascendencia y el operador \prec para denotar la descendencia (ver figura 6). La jerarquía va a ser tan especializada de acuerdo a los conocimientos de todos los observadores que están presenciando el evento a modelar [2].

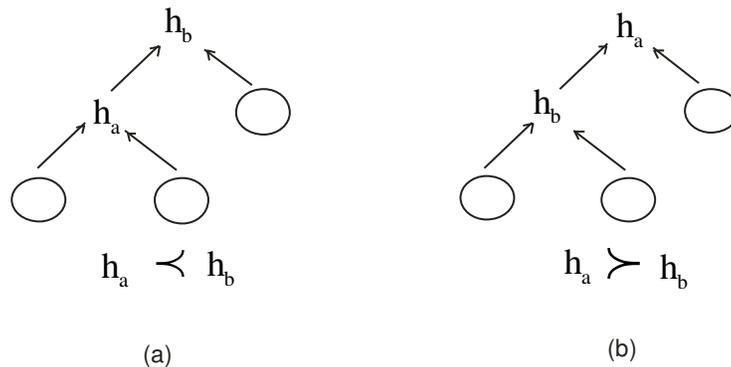


Figura 6. En el inciso (a) se muestra que h_a es descendente de h_b y $CONF(h_a, h_b) = 0$. En (b) se puede observar que h_a es ascendente de h_b y $CONF(h_a, h_b) = 1$.

Sea $J^T = J \cup J'$, se define la función de confusión $CONF: J^T \rightarrow \{0, 1\}$ como:

$$CONF(h_a, h_b) = \begin{cases} 0 & \text{si } h_a \succ h_b \\ 1 & \text{si } h_a \prec h_b \end{cases}$$

\cup , representa la unión. Se incrementa en una unidad la confusión (cuando $h_a \prec h_b$) por cada nivel que se desciende en la jerarquía.

La función $CONF(h_a, h_b)$ es la confusión no normalizada análoga a la ecuación $CONF(r, s)$ de la definición 12 detallada en la página 57.

Entonces, la **confusión normalizada** se obtendrá como sigue:

$$conf(r, s) = \frac{CONF(h_a, h_b)}{h} \dots\dots\dots(1)$$

Ésta representa el descontento o disconformidad que se observa o se produce, cuando se da un valor h_a , siendo que el valor deseado era h_b .

La h , representa **la profundidad de la estructura jerárquica** J^T . Es decir, es el número de niveles totales que tiene la jerarquía. Por ejemplo, la jerarquía de la figura 4 tiene 4 niveles por lo que $h=4$.

Se realiza esta división para normalizar la inconsistencia en el intervalo $[0,1]$.

Por ejemplo, $\text{conf}(\text{perro,animal})$ y $\text{conf}(\text{animal,perro})$ utilizando la jerarquía de la figura 4 como $h=4$ es:

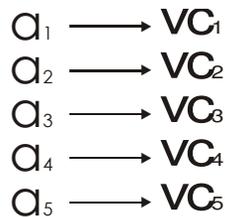
$$\begin{aligned} \text{conf}(\text{perro,animal}) &= \frac{\text{CONF}(\text{perro,animal})}{h} \\ &= \frac{0}{4} \\ &= 0 \end{aligned} ,$$

$$\begin{aligned} \text{conf}(\text{animal, perro}) &= \frac{\text{CONF}(\text{animal,perro})}{h} \\ &= \frac{3}{4} \\ &= 0.75 \end{aligned} .$$

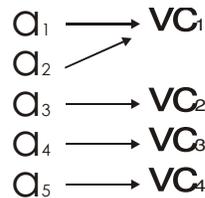
Definición 5. Se define a B como una bolsa de valores cualitativos

$$B = \{vc_1, vc_2, \dots, vc_{n-1}, vc_n\},$$

donde existe un vc_i que representa a una y solo una a_i (caso 1) o que representa a una o más a_i (caso 2). Por ejemplo:



Función biyectiva⁵
Caso 1.



Función suprayectiva⁶
Caso 2.

⁵ También llamada correspondencia uno a uno.

⁶ También llamada función sobre.

Para el **caso 1**, $f : A \rightarrow B$ que es uno a uno y sobre B se llama correspondencia uno a uno entre A y B, debido a que para cada vc_i que pertenece a B hay exactamente una $a \in A$.

Para el **caso 2**, se tiene que dada $f : A \rightarrow B$, se tiene que $\forall a$, $f(a)$ representa el valor cualitativo que se le ha asignado. La función transforma a A sobre B, si cada vc_i en B se ha asignado a al menos una afirmación. Es decir, un vc_i puede tener asociadas una, dos o más afirmaciones.

Al número de repeticiones sobre las afirmaciones que corresponden con el vc_i , se le llama número de observaciones $\#O_{vc_i}$ que existen en vc_i . Por lo tanto, para el caso 1, la obtención de #O es el siguiente:

$$\begin{aligned} \exists \#O_{vc_1} &= 1 \text{ en } vc_1, \\ \exists \#O_{vc_2} &= 1 \text{ en } vc_2, \\ \exists \#O_{vc_3} &= 1 \text{ en } vc_3, \\ \exists \#O_{vc_4} &= 1 \text{ en } vc_4, \\ \exists \#O_{vc_5} &= 1 \text{ en } vc_5. \end{aligned}$$

Para el caso 2, se tiene:

$$\begin{aligned} \exists \#O_{vc_1} &= 2 \text{ en } vc_1, \\ \exists \#O_{vc_2} &= 1 \text{ en } vc_2, \\ \exists \#O_{vc_3} &= 1 \text{ en } vc_3, \\ \exists \#O_{vc_4} &= 2 \text{ en } vc_4. \end{aligned}$$

Debido a que caso 1 \subseteq caso 2 se generalizará el análisis de confusión en un solo caso.

En seguida, se realiza el análisis de la confusión total por cada vc_i , donde $\forall vc_i$ en la bolsa B se calcula la confusión de $vc_1 \times B, vc_2 \times B, \dots, vc_{n-1} \times B, vc_n \times B$, es decir, $B \times B \Rightarrow B^2$ como sigue:

Caso 1 y Caso 2. Si $\forall vc_i \in B \exists$ una o más $a \in A$ tal que $(a, vc_i) \in f$. Cada vc_i tiene un número de observación que puede ser diferente y se denota como $\#O_{vc_i}$, donde $\#O_{vc_i}$, representa el número de observaciones sobre el valor cualitativo vc_i . Es decir, el total de veces que se repite el vc_i en las a_i afirmaciones.

El subíndice i, indica el número de valor cualitativo sobre el cual se está trabajando. Entonces la confusión total se calcula como:

Para vc_1 con $\#O_{vc_1}$ observaciones,

$$\text{conf}(vc_1,vc_1) + \sum_{\#O_{vc_2}=1}^{\#OT_{vc_2}}(\text{conf}(vc_1,vc_2)) + \dots + \sum_{\#O_{vc_n}=1}^{\#OT_{vc_n}}\text{conf}(vc_1,vc_n) \dots\dots\dots(2a)$$

Para vc_2 con $\#O_{vc_2}$ observaciones,

$$\sum_{\#O_{vc_1}=1}^{\#OT_{vc_1}}\text{conf}(vc_2,vc_1) + \text{conf}(vc_2,vc_2) + \dots + \sum_{\#O_{vc_n}=1}^{\#OT_{vc_n}}\text{conf}(vc_2,vc_n) \dots\dots\dots(2b)$$

·
·
·
·
·

Para vc_{n-1} con $\#O_{vc_{n-1}}$ observaciones,

$$\sum_{\#O_{vc_1}=1}^{\#OT_{vc_1}}\text{conf}(vc_{n-1},vc_1) + \sum_{\#O_{vc_2}=1}^{\#OT_{vc_2}}\text{conf}(vc_{n-1},vc_2) + \dots + \text{conf}(vc_{n-1},vc_{n-1}) + \sum_{\#O_{vc_n}=1}^{\#OT_{vc_n}}\text{conf}(vc_{n-1},vc_n) \dots\dots\dots(2y)$$

Para vc_n con $\#O_{vc_n}$ observaciones,

$$\sum_{\#O_{vc_1}=1}^{\#OT_{vc_1}}\text{conf}(vc_n,vc_1) + \sum_{\#O_{vc_2}=1}^{\#OT_{vc_2}}\text{conf}(vc_n,vc_2) + \dots + \text{conf}(vc_n,vc_n) \dots\dots\dots(2z)$$

La **confusión total** que un vc_i produce en B es

$$\sum_{\#O_{vc_1}=1}^{\#OT_{vc_1}}\text{conf}(vc_i,vc_1) + \sum_{\#O_{vc_2}=1}^{\#OT_{vc_2}}\text{conf}(vc_i,vc_2) + \text{conf}(vc_i,vc_i) + \dots + \sum_{\#O_{vc_n}=1}^{\#OT_{vc_n}}\text{conf}(vc_i,vc_n) \dots\dots\dots(3)$$

Es el descontento total de los elementos de la bolsa, la suma de los descontentos de cada uno de los miembros vc_1, vc_2, \dots, vc_n cuando se escoge vc_i en vez de cada uno de ellos.

De $(2a, 2b, \dots, 2z)$ se halla la confusión total mínima, cuyo valor cualitativo que produce esta confusión se denota por r^* :

$$\min[2a, 2b, \dots, 2z] \dots\dots\dots(4)$$

Por lo tanto, el valor r^* que minimizó la confusión total se define como el **centroide** de la bolsa.

La **confusión promedio** es la confusión total dividida por el número de elementos (O_T) de la bolsa. El elemento r^* hará que la confusión promedio sea mínima. Lo anterior se calcula en la ecuación 5.

$$r^* = \frac{\min[2a, 2b, \dots, 2z]}{O_T} \dots\dots\dots(5)$$

La confusión promedio para el r^* , cuyo valor será el vc_i que nos dio la confusión total mínima, se interpretará como vc_i que representa a la a_i afirmación que mejor modela el evento E.

Lo cual quiere decir que r^* produce el menor desacuerdo de todos los observadores.

Por lo tanto, la **inconsistencia** de $B = \{vc_1, vc_2, \dots, vc_{n-1}, vc_n\}$ denotada por σ está representada por el valor de confusión promedio del centroide r^* calculado en la ecuación 11, donde $\sigma \in [0,1]$.

A continuación se muestra como se calculan las n confusiones promedio de cada vc_i incluyendo el r^* .

$\forall vc_i$ en B, las confusiones promedio son:

Para vc_1 ,

$$\sigma_1 = \frac{\text{conf}(vc_1, vc_1) + \sum_{\#O_{vc_2}=1}^{\#OT_{vc_2}} \text{conf}(vc_1, vc_2) + \dots + \sum_{\#O_{vc_n}=1}^{\#OT_{vc_n}} \text{conf}(vc_1, vc_n)}{O_T} \dots\dots\dots(6a)$$

Para vc_2 ,

$$\sigma_2 = \frac{\sum_{\#O_{vc_1}=1}^{\#OT_{vc_1}} \text{conf}(vc_2, vc_1) + \text{conf}(vc_2, vc_2) + \dots + \sum_{\#O_{vc_n}=1}^{\#OT_{vc_n}} \text{conf}(vc_2, vc_n)}{O_T} \dots\dots\dots(6b)$$

.

.

Para vc_{n-1} ,

$$\sigma_{n-1} = \frac{\sum_{\#O_{vc_1}=1}^{\#OT_{vc_1}} \text{Conf}(vc_{n-1}, vc_1) + \sum_{\#O_{vc_2}=1}^{\#OT_{vc_2}} \text{Conf}(vc_{n-1}, vc_2) + \dots + \text{Conf}(vc_{n-1}, vc_{n-1}) + \sum_{\#O_{vc_n}=1}^{\#OT_{vc_n}} \text{Conf}(vc_{n-1}, vc_n)}{O_T} \dots(6y)$$

Para vc_n ,

$$\sigma_n = \frac{\sum_{\#O_{vc_1}=1}^{\#OT_{vc_1}} \text{Conf}(vc_n, vc_1) + \sum_{\#O_{vc_2}=1}^{\#OT_{vc_2}} \text{Conf}(vc_n, vc_2) + \dots + \text{Conf}(vc_n, vc_n)}{O_T} \dots\dots\dots(6z)$$

Donde $O_T = \#O_{vc_1} + \#O_{vc_2} + \dots + \#O_{vc_{n-1}} + \#O_{vc_n}$ y se interpreta como el número de observaciones totales que existen sobre cada vc_i , que en el Caso 2, cada vc_i puede tener una o más observaciones.

De (6a, 6b, ..., 6y, 6z), resultaron n confusiones promedio individuales de cada vc_i , por lo que se tiene un conjunto de

$$\Sigma = \{\sigma_1, \sigma_2, \dots, \sigma_{n-1}, \sigma_n\}. \dots\dots(7)$$

En la ecuación (7) cada σ_i puede interpretarse como la confusión promedio de cada vc_i .

El mínimo absoluto de (7) será cuando $\sigma = 0$, entonces se dice que no hay inconsistencia sobre la afirmación a_i .

El máximo absoluto sobre (7) será cuando $\sigma = 1$, entonces se dice que se halló la mayor inconsistencia sobre la afirmación a_i .

La automatización del modelo de inconsistencia MI, se construyó a través de dos aplicaciones desarrolladas bajo la plataforma Java y se explican en el capítulo 9.

4.2 Análisis experimental

En seguida se analizan algunos eventos con el modelo de inconsistencia.

Experimento 1

A continuación, se muestran algunos ejemplos para determinar la inconsistencia en una bolsa de valores cualitativos que describen con un evento en particular.

Este experimento está relacionado con la epidemia del virus de la influenza porcina cuya información se dio a conocer el 26 de abril de 2009. Cuando inició esto se tenían varias versiones del lugar donde el virus se originó. Cada medio de información tenía su propia versión, para determinar el posible origen de esta epidemia se va a analizar toda esta documentación específicamente obtenida de ciertos periódicos y direcciones de páginas web relacionados con el tema.

Los primeros nueve documentos son periódicos de determinados estados de la República Mexicana. Los restantes se tratan de páginas en la web, el periódico The New York Times y Univisión. En total fueron 15 fuentes de donde se recopiló la información y se muestran a continuación:

1. La Jornada

<http://www.jornada.unam.mx/2009/05/15/index.php?section=ciencias&article=a02n1cie>

La cepa A/H1N1 se originó en California: biólogo de la UNAM

2. El Universal

<http://www.eluniversal.com.mx/nacion/167576.html>

El virus mutó en mujer de Oaxaca.

3. El Diario Sin Secretos (de Puebla).

www.DiarioSinSecretos.com - noticias - puebla - columnas - La información es poder

El pasado 2 de abril un niño de 4 años originario de Perote, Veracruz contrajo el mal (virus de la influenza porcina).

4. El Diario de Chihuahua

<http://www.eldiariodechihuahua.com/notas.php?IDNOTA=151592>

El gobierno de Veracruz puso en marcha un programa de promoción turística de la comunidad de La Gloria, donde presuntamente surgió el primer caso de influenza humana.

5. Diario Despertar de Oaxaca.

www.diariodespertar.com.mx/Agenda/9367-zona-cero-era-problema-salud-publica.html

29 Abr 2009 ... La firma estadounidense Granjas Carroll se expande a costa del agua y la ... habitantes de la comunidad de La Gloria, municipio de Perote, **Veracruz**. ... de donde se **originó** la epidemia de **influenza en México**.

6. El Semanario

http://www.elsemanario.com.mx/news/news_display.php?story_id=19308

NUEVA YORK, abril 28, 2009.- El primer caso de influenza porcina en mundo ocurrió en Texas (EU) durante septiembre de 2008, y la primera persona afectada fue un niño de 10 años, aseguró Laurie Garrett, experta en políticas internacionales de salud, epidemias y seguridad del Consejo de Relaciones Exteriores.

7. <http://www.elgolfo.info/web/tiemporeal/39502-primer-caso-de-influenza-no-se-dio-en-perote-cordova.html> (Veracruz).

"El primer caso, que haciendo el estudio de todas las muestras que el InDRE (Instituto de Diagnóstico y Referencia Epidemiológica) teníamos informado, fue del 11 de marzo y lo presentó un paciente de aquí del Distrito Federal", dijo Córdova.

8. El Diario de Yucatán

[http://www.yucatan.com.mx/noticia.asp?cx=9\\$1051040000\\$4065697&f=20090502](http://www.yucatan.com.mx/noticia.asp?cx=9$1051040000$4065697&f=20090502)

Edgar Hernández, de cinco años, fue identificado como el primer caso de la enfermedad.

9. Reforma

<http://www.reforma.com/influenza/articulo/496/990332/>

México (27 de abril de 2009).- Veratect, una empresa estadounidense dedicada a la biovigilancia, advirtió a la Organización Mundial de la Salud (OMS), desde el 2 de abril, de una alerta sanitaria por influenza en una zona de granjas de cerdos en la comunidad de La Gloria, en Perote, en el Estado de Veracruz.

10. <http://www.adnsureste.info/index.php?news=11979>

Confirma Salud federal influenza empezó en Oaxaca; Aquí se dijo que se trató de una neumonía atípica. (26 abril, 2009).

11. <http://www.oaxacaenpiedelucha.com/2009/04/primer-caso-de-influenza-porcina-en-el.html>

La tarde de hoy desde la residencia oficial de Los Pinos, en conferencia de prensa el Secretario de Salud Federal, José Ángel Córdova informó que el primer caso de influenza porcina se registró en Oaxaca.

12. <http://vivirmexico.com/2009/05/el-primer-caso-de-influenza-porcina-fue-en-california>

El primer caso de influenza porcina se registró en Perote, Ver.

13. http://nomas_por_chingar.espacioblog.com/post/2009/04/30/encuentran-aldea-donde-se-origino-influenza

La aldea de La Gloria en México ha sido identificada como el posible origen del virus de influenza porcina que asola el mundo.

14. The New York Times

<http://thelede.blogs.nytimes.com/2009/04/28/following-swine-flu-chatter-online/?scp=2&sq=influenza%20in%20veracruz%20mex&st=cse>

El diario New York Times el día 28 de abril, donde se relata cómo inició el brote de influenza porcina en la Gloria, municipio de Perote, estado de Veracruz.

15. <http://foro.univision.com/univision/board/message?board.id=88659421041&message.id=367072>

“La OMS confirmó que la nueva cepa porcina de Influenza viene de Estados Unidos” Corroborado con lo que dice la CentersforDisease Control and Prevention.

La información anterior se toma como observaciones sobre el suceso que se analizará. Cada medio de información será el observador y lo que informan será la observación.

Cada reporte de noticia se considera como una afirmación sobre el hecho donde se creó la cepa.

En seguida se presentan los valores cualitativos que se extrajeron de cada noticia una para poder ser procesados por la aplicación que calculará la inconsistencia de los datos.

- $vc_1 = \text{Distrito_Federal}$, con $\#O_{vc_1} = 1$ observaciones,
- $vc_2 = \text{Oaxaca}$, con $\#O_{vc_2} = 3$ observaciones.
- $vc_3 = \text{Texas}$, con $\#O_{vc_4} = 2$ observaciones,
- $vc_4 = \text{Estados_Unidos}$, con $\#O_{vc_5} = 1$ observaciones,
- $vc_5 = \text{La_Gloria}$, con $\#O_{vc_3} = 6$ observaciones,
- $vc_6 = \text{California}$, con $\#O_{vc_6} = 1$ observaciones,
- $vc_7 = \text{Perote}$, con $\#O_{vc_7} = 2$ observaciones.

La bolsa de valores cualitativos queda conformada de la siguiente manera:

$$B = \{vc_1, vc_2, vc_3, vc_4, vc_5, vc_6, vc_7\}$$

Para poder determinar la inconsistencia de B , se requiere de una jerarquía que involucra ciertos países del mundo para señalar por cuál lugar optó cada medio de información. Cabe mencionar que en esta metodología se considera que todos los informantes dicen la verdad.

La figura 7, muestra una jerarquía J donde cada asterisco (*) en la figura representa el número de observaciones sobre el valor cualitativo indicado. Es decir, en Distrito Federal solo se presenta un asterisco, lo cual significa que tiene una observación; pero en Oaxaca hay tres observaciones.

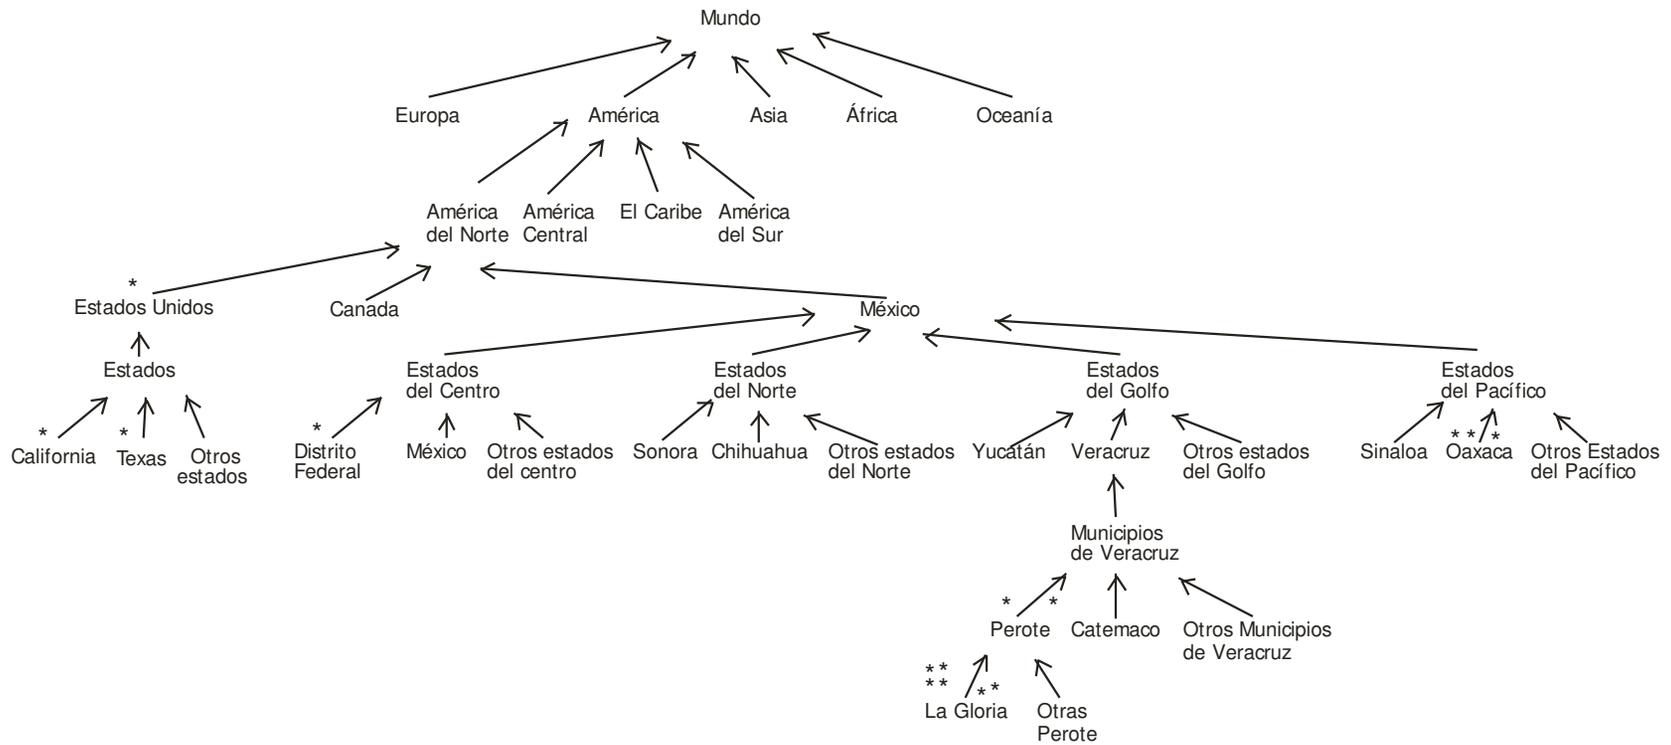


Figura 7. Jerarquía de algunos lugares del mundo donde cada asterisco representa una observación sobre el sitio indicado.

A continuación se presenta la forma en que se realizan los cálculos para encontrar el centroide y la inconsistencia de una bolsa de afirmaciones de forma manual:

Para $vc_1 = \text{Distrito_Federal}$ la manera de encontrar la confusión total de $vc_i \times B$ es:

$$\sum_{i=1}^{15} \text{conf}(\text{Distrito_Federal}, vc_i) = \text{conf}(\text{Distrito_Federal}, \text{Distrito_Federal}) + [\text{conf}(\text{Distrito_Federal}, \text{Oaxaca}) + \text{conf}(\text{Distrito_Federal}, \text{Oaxaca}) + \text{conf}(\text{Distrito_Federal}, \text{Oaxaca})] + \text{conf}(\text{Distrito_Federal}, \text{Texas}) + \text{conf}(\text{Distrito_Federal}, \text{Estados_Unidos}) + \text{conf}(\text{Distrito_Federal}, \text{La_Gloria}) + \text{conf}(\text{Distrito_Federal}, \text{California}) + [\text{conf}(\text{Distrito_Federal}, \text{Perote}) + \text{conf}(\text{Distrito_Federal}, \text{Perote})] = 0 + [0.25 + 0.25 + 0.25] + 0.375 + 0.125 + [0.625 + 0.625 + 0.625 + 0.625 + 0.625 + 0.625] + 0.375 + [0.5 + 0.5] = 6.375$$

Como se puede ver en la jerarquía Mundo, existen 3 asteriscos en Oaxaca, 6 en La Gloria y 2 en Perote. Lo cual quiere decir que hubo tres, seis y dos observaciones sobre esas afirmaciones. Por lo que, las confusiones de Distrito_Federal en lugar de Oaxaca; Distrito_Federal en lugar de La_Gloria; y Distrito_Federal en lugar de Perotese repitentes, seis y dos veces. La confusión total para Distrito_Federal fue 6.375.

De la misma manera, se obtiene para cada valor cualitativo (Oaxaca, Texas, Estados_Unidos, La_Gloria, California y Perote), el valor de confusión total $vc_i \times B$ para $i = 1, 2, \dots, n$.

En la tabla 1 se muestra la confusión total que se obtiene si se usala fila r en vez del valor real o deseado que es la columna s y la confusión total por cada vc_i .

	Distrito_Federal	Oaxaca	Texas	Estados_Unidos	La_Gloria	California	Perote	Confusión total
Distrito_Federal	0	0.75	0.375	0.125	3.75	0.375	1	6.375
Oaxaca	0.25	0	0.375	0.125	3.75	0.375	1	5.875
Texas	0.375	1.125	0	0	4.5	0.125	1.25	7.375
Estados_Unidos	0.375	1.125	0.25	0	4.5	0.25	1.25	7.75
La_Gloria	0.25	0.75	0.375	0.125	0	0.375	0	1.875
California	0.375	1.125	0.125	0	4.5	0	1.25	7.375
Perote	0.25	0.75	0.375	0.125	0.75	0.375	0	2.625

Tabla 1. Matriz de $\text{Conf}(r,s)$ y confusiones totales por cada vc_i .

En el renglón 5, columna 9 se puede ver que la mínima confusión total es 1.875, causada por La_Gloria, por lo que será el centroide de la bolsa {Distrito_Federal, Oaxaca, Texas, Estados_Unidos, La_Gloria, California, Perote}.

Enseguida se calcula la inconsistencia de B hallando la confusión promedio del r^* (en este caso de estudio fue La_Gloria) y esto se logra dividiendo su confusión total por el número de observaciones, como se enuncia a continuación:

$$\sum_{i=1}^{15} \frac{\text{conf}(La_Gloria, vc_i)}{O_T} = \frac{1.875}{15} = 0.12$$

Por lo tanto, la inconsistencia de la bolsa de afirmaciones es 0.12 y el centroide de la bolsa es La_Gloria al presentarla confusión promedio mínima de B.

Por lo tanto, de acuerdo a los 15 reportes de noticias de diferentes diarios y páginas web, se llegó al consenso en que el virus de la influenza pudo haberse originado en La_Gloria.

Ahora bien, para llevar a cabo el proceso de cálculo de inconsistencia sobre una bolsa de afirmaciones de forma automatizada, se realizó un software bajo la plataforma Java.

A continuación se explica cómo se puede llevar a cabo el análisis de inconsistencia a través de la aplicación.

El software requiere que la jerarquía mostrada en la figura 7, esté en formato XML como lo muestra la figura 8.

```

<?xml version="1.0" encoding="UTF-8"?>
<nodo>Mundo
  <nodo>Europa
  </nodo>
  <nodo>America
    <nodo>America del Norte
      <nodo>Estados Unidos
        <nodo>Estados
          <nodo>California
          </nodo>
          <nodo>Texas
          </nodo>
          <nodo>Otros estados
          </nodo>
        </nodo>
      <nodo>Mexico
        <nodo>Estados del Centro
          <nodo>Distrito Federal
          </nodo>
          <nodo>Aguascalientes
          </nodo>
        </nodo>
      </nodo>
    </nodo>
  <nodo>Canada
  </nodo>
</nodo>
  </nodo>
</nodo>

```

Figura 8. Especificación en XML que representa la jerarquía de mascotas.

Para realizar el análisis de inconsistencia sobre la bolsa de valores cualitativos con la aplicación, se realizan los pasos siguientes sobre la pantalla que se muestra en la figura 9.

1. Elegir la jerarquía con el componente lista que tiene la leyenda “Nombre de la jerarquía” se da clic al botón **Elegir** y aparecerá en una ventana la jerarquía que se utilizó.
2. Se marca el valor cualitativo sobre la lista que presenta el título “Valores cualitativos”, donde el valor seleccionado aparecerá el componente de texto que tiene el nombre de “Valor”.
3. Escoger el número de observaciones de ese valor cualitativo con el componente lista que aparece enfrente de la leyenda “No. observaciones”, el número elegido tiene que quedar marcado.
4. Dar clic en el botón **Agregar valor**.

Los pasos del 2 al 4 se repiten por cada valor cualitativo introducido. Una vez que se han introducido los valores cualitativos de la bolsa se da clic sobre el botón **Salir**.

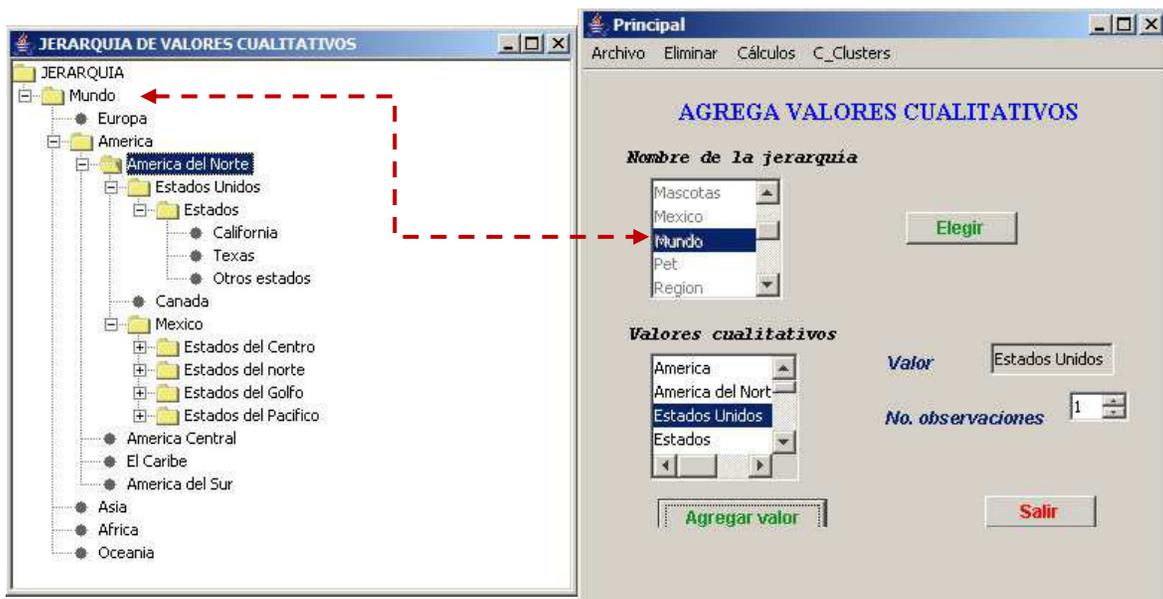


Figura 9. Jerarquía elegida y pantalla de captura para elegir jerarquía, valores cualitativos y número de observaciones.

El siguiente paso es determinar la confusión total de cada valor cualitativo. En el menú de la aplicación se elige Cálculos, donde se desplegará una pantalla como la que se muestra en la figura 10.

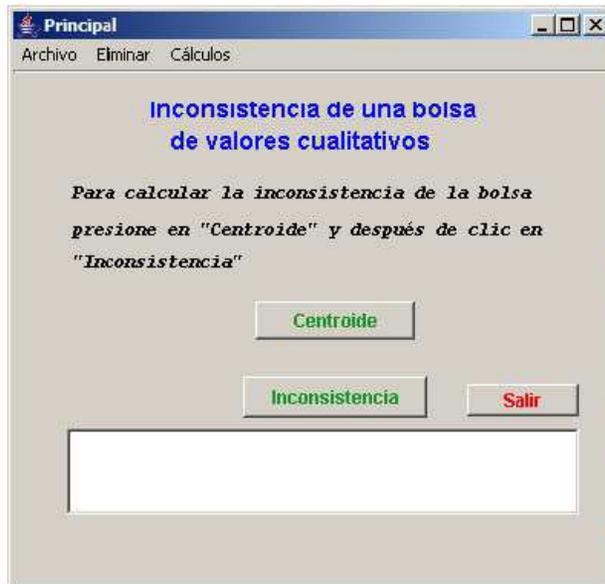


Figura 10. Pantalla para calcular el valor más plausible de una bolsa de afirmaciones.

Enseguida se presiona el botón “Centroide” y la aplicación desplegará una tabla con las confusiones totales y el centroide de los valores cualitativos como se muestra en la figura 11.

Valor cualitativo	Distrito Federal	Oaxaca	Texas	Estados Unidos	La Gloria	California	Perote	Confusión Total
Distrito Federal	0	0.75	0.375	0.125	3.75	0.375	1	6.375
Oaxaca	0.25	0	0.375	0.125	3.75	0.375	1	5.875
Texas	0.375	1.125	0	0	4.5	0.125	1.25	7.375
Estados Unidos	0.375	1.125	0.25	0	4.5	0.25	1.25	7.75
La Gloria	0.25	0.75	0.375	0.125	0	0.375	0	1.875
California	0.375	1.125	0.125	0	4.5	0	1.25	7.375
Perote	0.25	0.75	0.375	0.125	0.75	0.375	0	2.625

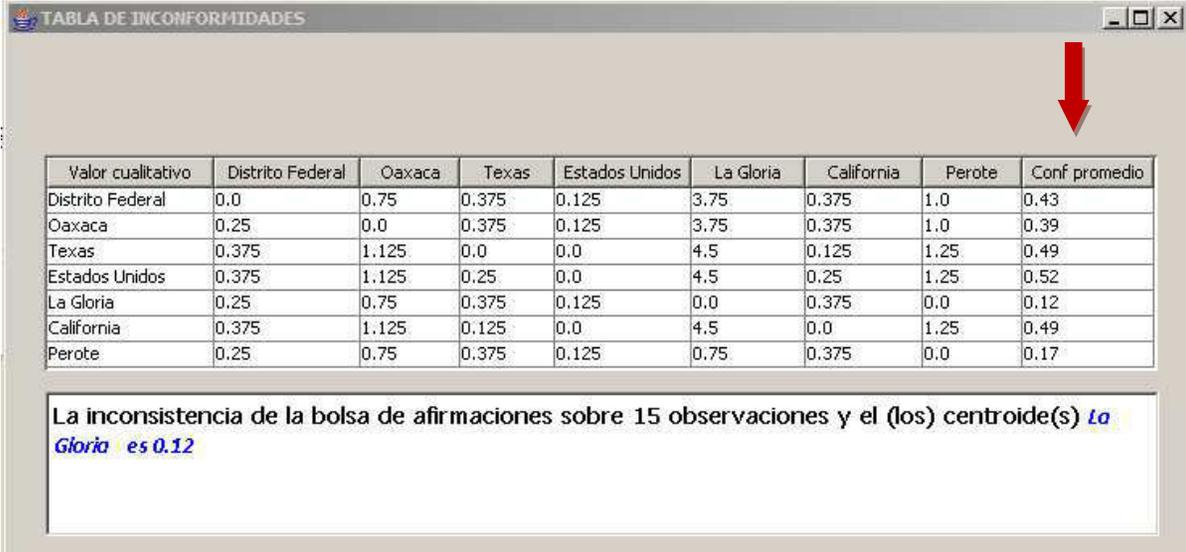
CENTROIDES (*)
La Gloria con una confusión total de 1.875

Figura 11. Matriz que muestra la $conf(r,s)$ y la confusión total, donde r representa a la fila y s a la columna.

La figura anterior muestra en la última columna la confusión total que la fila r produce en la bolsa B si escogiéramos a esa fila r como centroide de la bolsa. La confusión total es la suma de las confusiones de cada elemento de la bolsa. El resto de la figura expresa qué se obtiene si usamos la fila r en vez de la columna s .

El valor de confusión total mínimo es 1.875 generado por el valor cualitativo La_Gloria, por lo que el posible r^* de la bolsa es La_Gloria.

En la figura 12 se presenta la confusión promedio que cada valor cualitativo genera, ésta se obtiene sacando el promedio de la confusión total de cada valor.



Valor cualitativo	Distrito Federal	Oaxaca	Texas	Estados Unidos	La Gloria	California	Perote	Conf promedio
Distrito Federal	0.0	0.75	0.375	0.125	3.75	0.375	1.0	0.43
Oaxaca	0.25	0.0	0.375	0.125	3.75	0.375	1.0	0.39
Texas	0.375	1.125	0.0	0.0	4.5	0.125	1.25	0.49
Estados Unidos	0.375	1.125	0.25	0.0	4.5	0.25	1.25	0.52
La Gloria	0.25	0.75	0.375	0.125	0.0	0.375	0.0	0.12
California	0.375	1.125	0.125	0.0	4.5	0.0	1.25	0.49
Perote	0.25	0.75	0.375	0.125	0.75	0.375	0.0	0.17

La inconsistencia de la bolsa de afirmaciones sobre 15 observaciones y el (los) centroide(s) **La Gloria** es 0.12

Figura 12. Estos datos representan la confusión promedio por cada valor cualitativo.

En la columna “Conf. Promedio” el valor mínimo es de 0.12 que La_Gloria produce, por lo que la inconsistencia de la bolsa es de 0.12 y su centroide es La_Gloria. Este valor se calculó sacando el promedio del centroide, como se muestra enseguida:

$$\sigma = \frac{\sum_{i=1}^n \text{conf}(\text{La_Gloria}, v_{c_i})}{15} = 0.12$$

El número 15 representa el total de observaciones sobre las afirmaciones.

Pudiera darse el caso en que la misma inconsistencia se obtenga con dos valores r^* distintos, en este caso se toma uno de ellos arbitrariamente como el centroide.

Experimento 2

Juan tiene una mascota, pero no se sabe con certeza cuál es. Algunos observadores dan cierta información sobre la mascota de Juan, a través de las siguientes afirmaciones:

- a_1 = Juan tiene un felino,
- a_2 = Juan tiene un gato doméstico,
- a_3 = La mascota de Juan es un gato siamés,
- a_4 = Juan tiene un gato siamés,
- a_5 = Juan tiene un perro,
- a_6 = Juan tiene un canino,
- a_7 = Juan tiene un xoloitzcuintle,
- a_8 = Juan tiene un perro chihuahueño,
- a_9 = Juan tiene un águila.

Los valores cualitativos que se extrajeron de las 9 afirmaciones son: gato siamés, gato siamés, felino, perro chihuahueño, perro, canino, xoloitzcuintle, gato doméstico, águila.

Asignando las afirmaciones a cada valor cualitativo la correspondencia queda de la siguiente manera:

- vc_1 = Felino , con $\#O_{vc_1} = 1$ observaciones,
- vc_2 = Gato_domestico , con $\#O_{vc_2} = 1$ observaciones.
- vc_3 = Gato_siames , con $\#O_{vc_3} = 2$ observaciones,
- vc_4 = Canino , con $\#O_{vc_4} = 2$ observaciones,
- vc_5 = Xoloitzcuintle , con $\#O_{vc_5} = 1$ observaciones,
- vc_6 = Chihuahua , con $\#O_{vc_6} = 1$ observaciones,
- vc_7 = aguila , con $\#O_{vc_7} = 1$ observaciones.

Entonces, la bolsa de estos valores queda conformada de la siguiente manera:

$$B = \{vc_1, vc_2, vc_3, vc_4, vc_5, vc_6, vc_7\}.$$

Los valores arriba mencionados se extrajeron de las afirmaciones. Por ejemplo de la afirmación “Juan tiene un gato siamés” se extrae el valor cualitativo gato siamés. Estos valores se encuentran en una jerarquía de valores cualitativos.

La figura 13, muestra una jerarquía J donde cada asterisco (*) en la figura representa el número de observaciones sobre el valor cualitativo indicado. Es decir, en Felino solo se presenta un asterisco, lo cual significa que tiene una observación; pero en Canino (perro) se presentan dos observaciones.

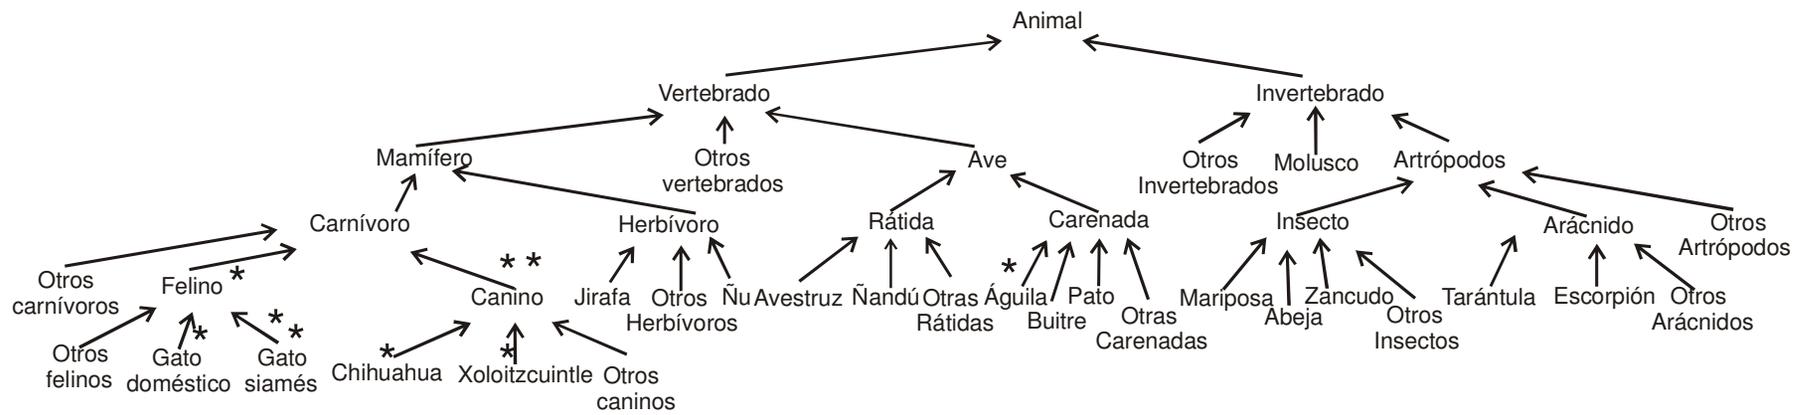


Figura 13. Jerarquía de algunos animales.

El software requiere que la jerarquía mostrada en la figura 12, esté en formato XML como lo muestra la figura 14.

```

Mascota.xml
<?xml version="1.0" encoding="UTF-8"?>
<nodo>Animal
  <nodo>Vertebrado
    <nodo>Otros Vertebrados
    </nodo>
    <nodo>Mamifero
      <nodo>Carnivoro
        <nodo>Otros_carnivoros
        </nodo>
        <nodo>Felino
          <nodo>Gato_domestico
          </nodo>
          <nodo>Gato_siames
          </nodo>
          <nodo>Gato_montes
          </nodo>
          <nodo>Tigre
          </nodo>
          <nodo>Otros_felinos
          </nodo>
        </nodo>
      <nodo>Canino
        <nodo>Zorro
        </nodo>
        <nodo>Lobo
        </nodo>
        <nodo>Pastor_aleman
        </nodo>
        <nodo>Xoloitzcuintle
      </nodo>
    </nodo>
  </nodo>
</pre>

```

Figura 14. Especificación en XML que representa a la jerarquía de mascotas.

Ahora, se calcula el valor cualitativo que representa el centroide de la bolsa dando clic en el botón Centroides, como se presenta en la figura 10 mostrada anteriormente.

Valor cualitativo	Chihuahua	Gato_siames	Felino	Aguila	Canino	Xoloitzcuintle	Gato_domesti...	Confusión Total
Chihuahua	0	0.8	0.2	0.6	0	0.2	0.4	2.2
Gato_siames	0.4	0	0	0.6	0.4	0.4	0.2	2
Felino	0.4	0.4	0	0.6	0.4	0.4	0.2	2.4
Aguila	0.8	1.6	0.6	0	1.2	0.8	0.8	5.8
Canino	0.2	0.8	0.2	0.6	0	0.2	0.4	2.4
Xoloitzcuintle	0.2	0.8	0.2	0.6	0	0	0.4	2.2
Gato_domestico	0.4	0.4	0	0.6	0.4	0.4	0	2.2

CENTROIDES (*)
Gato_siames con una confusión total de 2.0

Figura 15. Matriz que muestra la $conf(r,s)$ y la confusión total.

La figura 15 muestra en la última columna la confusión total que la fila r produce en la bolsa B , si elijéramos a esa fila r como centroide de la bolsa. La confusión total es la suma de las confusiones de cada elemento de la bolsa. El resto de la figura expresa qué se obtiene si usamos la fila r en vez de la columna s , el valor deseado o similar.

En la figura anterior, el valor de confusión total mínimo es 3.33 generado por el valor cualitativo Gato_siames, por lo que el posible r^* de la bolsa es Gato_siames.

En la figura 16, se presenta la confusión promedio que cada valor cualitativo genera, ésta se obtiene sacando el promedio de la confusión total de cada valor.

Valor cualitativo	Chihuahua	Gato_siames	Felino	Aguila	Canino	Xoloitzcuintle	Gato_domesti...	Conf promedio
Chihuahua	0.0	0.8	0.2	0.6	0.0	0.2	0.4	0.24
Gato_siames	0.4	0.0	0.0	0.6	0.4	0.4	0.2	0.22
Felino	0.4	0.4	0.0	0.6	0.4	0.4	0.2	0.27
Aguila	0.8	1.6	0.6	0.0	1.2	0.8	0.8	0.64
Canino	0.2	0.8	0.2	0.6	0.0	0.2	0.4	0.27
Xoloitzcuintle	0.2	0.8	0.2	0.6	0.0	0.0	0.4	0.24
Gato_domestico	0.4	0.4	0.0	0.6	0.4	0.4	0.0	0.24

La inconsistencia de la bolsa de afirmaciones sobre 9 observaciones y el (los) centroide(s) **Gato_siames** es 0.22

Figura 16. Pantalla que muestra entre otras cosas el centroide de la bolsa de vc_1 .

En la columna “Conf. Promedio”, el valor mínimo es de 0.22 que Gato_siames produce, por lo que la inconsistencia de la bolsa es de 0.22 y su centroide es Gato_siames. Este valor se calculó sacando el promedio del centroide, como se muestra enseguida:

$$\sigma = \frac{\sum_{i=1}^n \text{conf}(\text{Gato_siames}, vc_i)}{9} = 0.22$$

El número nueve representa el total de observaciones sobre las afirmaciones. El r^* es Gato_siames.

Por lo tanto, los observadores que dieron las afirmaciones $a_3 = \text{La mascota de Juan es un gato siamés}$ y $a_4 = \text{Juan tiene un gato siamés}$ son las más plausibles en sus observaciones sobre el evento ocurrido.

Se puede ver que uno de los valores más especializados en la jerarquía resultó ser el menos inconsistente.

En este capítulo, se realizó la medición sobre una bolsa de afirmaciones que describen un aspecto de la vida cotidiana; para poder determinar el valor o valores que se ajustan mejor al problema analizado.

Los factores que intervienen para encontrar la menor inconsistencia sobre la bolsa de afirmaciones son:

- El nivel de especialización del valor cualitativo en la jerarquía. Puede ser que el valor más especializado sea la mejor solución,
- el número de observaciones sobre el valor cualitativo, donde no necesariamente el valor que se tenga en la mira por más observadores pudiera ser el mejor, y
- la concentración de más observaciones sobre alguna rama de valores cualitativos en la jerarquía.

En este capítulo se resolvió el objetivo 1 del presente trabajo; el cual, tiene como finalidad medir la inconsistencia de un conjunto de afirmaciones cualitativas y hallar el valor más plausible.

Capítulo 5. Encontrando varios centroides

Como ya se explicó en el capítulo anterior cuando se tiene una bolsa de afirmaciones, se puede obtener la que sea menos inconsistente entre ellas. Ahora se trata de calcular más de un centroide sobre las afirmaciones agrupadas a las cuales se les denominará cúmulos (clusters). Estos cúmulos agruparán centroides y serán candidatos a generar menor inconsistencia. Es decir, encontrar más de un centroide* sobre las afirmaciones, agrupando las que sean afines, esto es, las cercanas (de baja confusión) entre sí.

La figura 17 representa la jerarquía que los observadores construyeron y de la cual saldrá la bolsa de valores cualitativos para poder encontrar las mejores particiones de la bolsa, es decir, las particiones que tengan una menor inconsistencia generando el o los centroides que se obtuvieron de cada cúmulo.

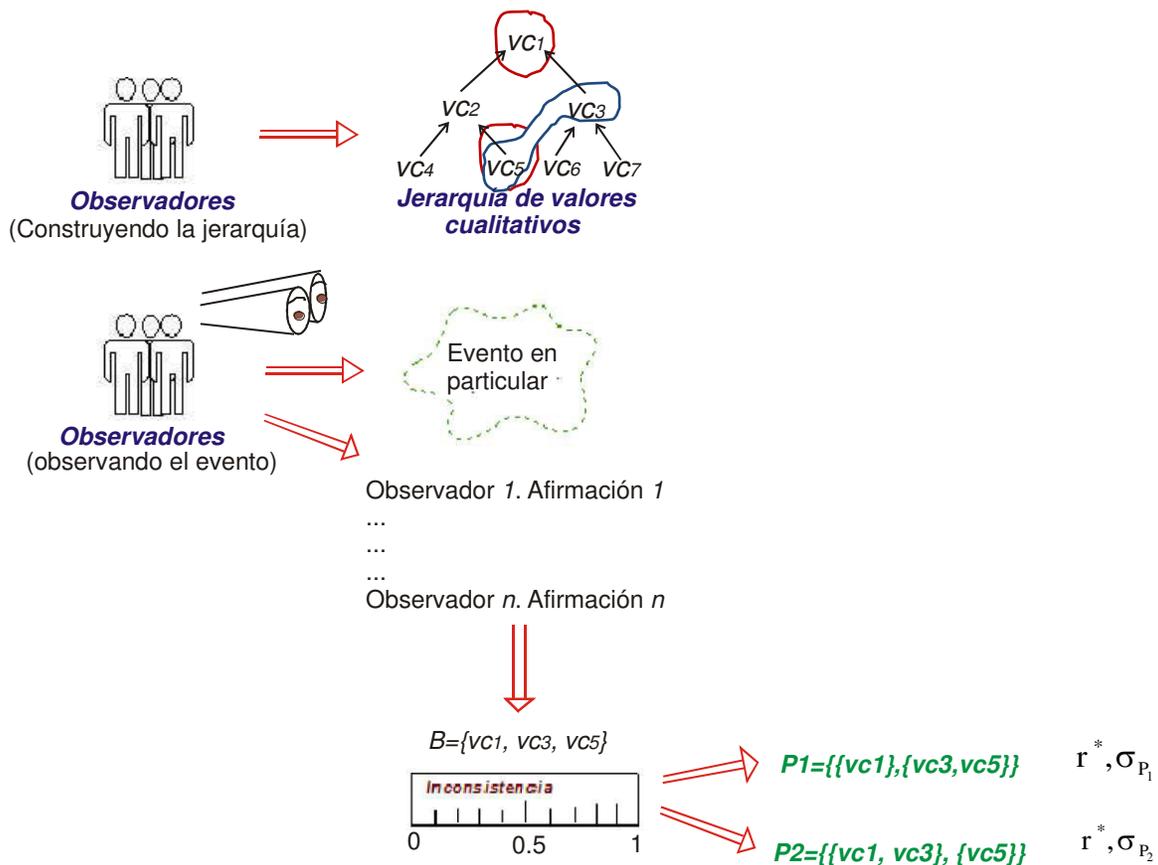


Figura 17. Esquema del cálculo de inconsistencia sobre cúmulos.

5.1 Técnicas para encontrar cúmulos

A continuación se describen dos técnicas para generar los cúmulos.

Técnica 1.

En esta técnica, la manera de crear los cúmulos será agrupando valores cualitativos cuya inconsistencia sea próxima a cero, a los cuales se les llamará votantes fuertes; y valores donde la inconsistencia sea mayor, éstos serán votantes débiles. De tal manera que, si se tiene más de una observación en los valores cualitativos se consideran votantes fuertes; en otro caso serán votantes débiles.

Para este análisis se considera el ejemplo utilizado sobre dónde se cree que inició la influenza. En este caso, los votantes indecisos son E. U., California, Texas, Distrito Federal y los votantes fuertes serán Oaxaca, Perote y La_Gloria.

En la figura 7 (ver pág. 61) se puede ver la jerarquía de lugares del mundo. Cada observación sobre alguna región está marcada con el símbolo * (asterisco).

Los clusters son los siguientes:

- {*Estados Unidos, California, Texas, Distrito Federal*} con una observación sobre cada valor cualitativo.
- {*Perote*} presenta 2 observaciones.
- {*Oaxaca*} con tres observaciones.
- {*La_Gloria*} tiene 6 observaciones.

Se debe considerar el comportamiento de los clusters anteriores, de la siguiente manera:

- 1) solo hay votantes fuertes en un cluster e indecisos en otro,
 - 2) se asignan indecisos arbitrariamente a un cluster, y
 - 3) poner indecisos en varios clusters.
- 1) Para el primer caso, se toman en cuenta dos puntos.
 - a) Cluster con votantes fuertes {*La_Gloria, Oaxaca, Perote*}.

	La_Gloria	Oaxaca	Perote	Conf. tot.	Conf. prom.
La_Gloria	0	0.75	0	0.75	0.068
Oaxaca	3.75	0	1	4.75	0.43
Perote	0.75	0.75	0	1.5	0.13

Tabla 2. Matriz de $\text{conf}(r, s)$ de votantes fuertes.

En la tabla 2, se puede observar que La_Gloria es el centroide y que Perote es la confusión siguiente más cercana al centroide. Aunque Oaxaca tiene más observaciones que Perote, este último es más cercano a La_Gloria tanto en confusión como en la jerarquía, lo cual se puede expresar que la región de Perote está más cerca de La_Gloria que de Oaxaca. Usar Perote en lugar de La_Gloria o Oaxaca da el mismo valor de confusión (0.75).

$$\text{conf}(\text{Perote}, \text{La_Gloria}) = \text{conf}(\text{Perote}, \text{Oaxaca}) = 0.75$$

En la confusión promedio (inconsistencia) de La_Gloria, Oaxaca y Perote, La_Gloria es el centro de gravedad.

b) Cúmulo con votantes indecisos;

{Estados Unidos, California, Texas, Distrito Federal}

	E. U.	California	Texas	D. F.	Conf. Tot.	Conf. Prom.
E. U.	0	0.25	0.25	0.375	0.875	0.218
California	0	0	0.125	0.375	0.5	0.125
Texas	0	0.125	0	0.375	0.5	0.125
D. F.	0.125	0.375	0.375	0	0.875	0.218

Tabla 3. Matriz de $\text{conf}(r, s)$ de votantes débiles.

En la tabla 3 se puede observar que los centroides son California y Texas. Además, las confusiones

$$\text{conf}(\text{D. F.}, \text{California}) = \text{conf}(\text{D. F.}, \text{Texas}) = 0.375$$

son iguales, debido a que en la jerarquía California y Texas tienen el mismo ancestro y el mismo número de observaciones. Por lo que usar D. F. en lugar de California o Texas da el mismo valor de confusión.

La confusión de usar E. U., California o Texas en lugar de D. F. arroja el mismo valor, como se ve enseguida:

$$\text{conf}(\text{E. U.}, \text{D. F.}) = \text{conf}(\text{California}, \text{D. F.}) = \text{conf}(\text{Texas}, \text{D. F.}) = 0.375$$

Lo anterior se debe a que tienen el mismo ancestro que en su caso es América del Norte, por el cual deben pasar para llegar a D. F.

Debido a que California y Texas tienen como antecesor E. U y el mismo número de observaciones la confusión de usar E. U. en lugar de California o Texas es 0.25.

$$\text{conf}(\text{E. U.}, \text{California}) = \text{conf}(\text{E. U.}, \text{Texas}) = 0.25$$

California y Texas se consideran como los centroides del cúmulo y como resultado se pueden considerar cualquiera de los dos valores o ambos.

Se concluye que en el cluster con votantes fuertes, La_Gloria es el centroide. Pero si se toman los centroides del cluster de indecisos, los más cercanos a La_Gloria son California y Texas sólo en valor de confusión no así en cercanía del lugar.

- 2) Cada una de las siguientes tablas muestra los resultados cuando los votantes indecisos son asignados a clusters ya existentes o se crean nuevos clusters.

	California	Texas	Conf. tot.	Conf. prom.
California	0	0.125	0.125	0.125
Texas	0.125	0	0.125	0.125

Tabla 4. Matriz de $conf(r, s)$ de un cluster creado con dos votantes indecisos.

En la tabla 4 se ve que, cuando se utiliza California en lugar de Texas o viceversa produce la misma confusión promedio, por lo que cualquiera de los dos puede ser centroide.

La tabla 5 muestra que cuando un votante indeciso se agrega a un clusters de votantes fuertes, éste se aleja mucho del centroide. Antes de añadir E. U., La_Gloria era el centroide y después no cambió el centroide pero E. U. está lejos del centroide.

	La_Gloria	Oaxaca	Perote	E. U.	Conf. tot.	Conf. prom.
La_Gloria	0	0.75	0	0.125	0.875	0.072
Oaxaca	3.75	0	1	0.125	4.875	0.406
Perote	0.75	0.75	0	0.125	1.625	0.135
E. U.	4.5	1.125	1.25	0	6.875	0.572

Tabla 5. Matriz de $conf(r, s)$ de un cluster creado más un votante indeciso.

- 3) Aquí se dispersan los cuatro votantes indecisos en varios clusters.

Se crearon tres clusters el primero con el votante más fuerte y el más débil, el segundo con un votante fuerte y dos débiles y el tercero con un votante fuerte y uno débil.

En la tabla 6, E. U. se aleja mucho de La_Gloria en su valor de inconsistencia.

	La_Gloria	E. U.	Conf. tot.	Conf. prom.
La_Gloria	0	0.125	0.125	0.017
E. U.	4.5	0	4.5	0.64

Tabla 6. Matriz de $conf(r, s)$ de un cluster con un votante fuerte y uno indeciso.

En la tabla 7, se muestra que usar Oaxaca en lugar de California o Texas arroja el mismo resultado y utilizar California o Texas en lugar de Oaxaca da el mismo valor.

	Oaxaca	California	Texas	Conf. tot.	Conf. prom.
Oaxaca	0	0.375	0.375	0.75	0.15
California	1.125	0	0.125	1.25	0.25
Texas	1.125	0.125	0	1.25	0.25

Tabla 7. Matriz de $conf(r, s)$ de un cluster con un votante fuerte y dos indecisos.

La tabla 8 ilustra como D. F. votante indeciso, se aleja mucho de tener una inconsistencia próxima a cero, pero Perote es menos inconsistente.

	Distrito_Federal	Perote	Conf. tot.	Conf. prom.
Distrito_Federal	0	1	1	0.33
Perote	0.25	0	0.25	0.083

Tabla 8. Matriz de $conf(r, s)$ de un cluster con un votante fuerte y uno indeciso.

De los tres casos anteriores, se concluye que cuando se juntan votantes fuertes con algún(os) débil(es), éstos últimos se alejan más del centroide. También se pueden presentar en algunos grupos (cúmulos) más de un solo resultado, es decir, más de un centroide que permita determinar a cualquiera o a todos como los valores con menor inconsistencia.

Técnica 2.

En esta técnica, cada grupo de afirmaciones será poco inconsistente y cada uno generará un centroide. Esto es, encontrar más de una σ , lo cual podría indicar que existe más de un resultado que nos interese. Por ejemplo, cuando se habla del transporte que utilizó Juan y si se forman cúmulos de las afirmaciones en cuestión, en cada uno de ellos se podría encontrar un centroide distinto, lo cual quiere decir que posiblemente Juan viajó en más de un transporte. También pudiera ser que Luis tuviera más de una mascota. O bien hay tres lugares donde Osama es bastante plausible que esté escondido.

Para este estudio se deberá ignorar el subconjunto \emptyset , y los cúmulos de un solo elemento. El primero se descarta, ya que interesa encontrar la inconsistencia de afirmaciones; y el segundo se elimina debido a que si se tuvieran 5 clusters de 1 afirmación todos tendrían una inconsistencia de cero, ya que están de acuerdo con ellos mismos. Es decir, el problema de minimizar la inconsistencia de un conjunto de n afirmaciones tiene una inconsistencia mínima 0 si se permiten n cúmulos, cada uno con un solo elemento. Esta solución trivial se descarta.

Se realizaron dos formas para hacer agrupamientos de una bolsa de valores cualitativos donde se llegó a la conclusión que los dos métodos generan el mismo resultado.

- a) A partir de la matriz de confusiones de la bolsa se agrupan los valores de confusión de acuerdo al mismo número de confusión para posteriormente obtener cúmulos haciendo **particiones** de los valores cualitativos con menor confusión.
- b) A partir de la matriz de confusiones de la bolsa se agrupan los valores de confusión de acuerdo al mismo número de confusión para posteriormente obtener cúmulos de dos, tres, hasta (n-1) vc_i .

El que se agrupen los vc_i de menor confusión garantiza que se va a tener cúmulos formados por particiones (punto 1) o subconjuntos (punto 2) que tendrán una menor inconsistencia entre ellos.

Partiendo de lo siguiente, se encuentran los clusters:

Sea una bolsa de valores cualitativos $B = \{vc_1, vc_2, vc_3, vc_4, vc_5, vc_6, vc_7\}$.

Primero. Se obtiene una matriz de confusiones sobre B (ver tabla 9).

	vc_1	vc_2	vc_n
vc_1	$conf(vc_1,vc_1)$	$\sum_{\#O_{vc_2}=1}^{\#OT_{vc_2}} conf(vc_1,vc_2)$	$\#O_{vc_2}$	$\sum_{\#O_{vc_n}=1}^{\#OT_{vc_n}} conf(vc_1,vc_n)$
vc_2	$\sum_{\#OT_{vc_1}=1}^{\#OT_{vc_1}} conf(vc_2,vc_1)$	$conf(vc_2,vc_2)$	$\sum_{\#O_{vc_n}=1}^{\#OT_{vc_n}} conf(vc_2,vc_n)$
.....
vc_n	$conf(vc_n,vc_1)$	$\sum_{\#O_{vc_2}=1}^{\#OT_{vc_2}} conf(vc_n,vc_2)$	$\#O_{vc_2}$	$conf(vc_n,vc_n)$

Tabla 9. Representación en forma general de cómo se calculan las confusiones de cada vc_i .

Segundo. Se van agrupar los valores que tengan una $conf(vc_i,vc_j)$ igual; es decir, si el menor valor de confusión es 0, de cada casilla que tenga el valor de 0 se pueden ir formando clusters de dos, tres, hasta n-1 valores cualitativos.

Tercero. Del valor menor de $conf(vc_i,vc_j)$ se obtendrán las particiones con la menor inconsistencia y del mayor valor se podrán sacar los de mayor desacuerdo.

Experimento 3 (Retomando el experimento 1)

Para explicar detalladamente como se obtienen los clusters de menor y mayor inconsistencia, primero se genera la siguiente matriz con los datos de confusión por cada valor cualitativo (ver tabla10).

	Distrito_Federal	Oaxaca	Texas	Estados_Unidos	La_Gloria	California	Perote
Distrito_Federal	0	0.75	0.375	0.125	3.75	0.375	1
Oaxaca	0.25	0	0.375	0.125	3.75	0.375	1
Texas	0.375	1.125	0	0	4.5	0.125	1.25
Estados_Unidos	0.375	1.125	0.25	0	4.5	0.25	1.25
La_Gloria	0.25	0.75	0.375	0.125	0	0.375	0
California	0.375	1.125	0.125	0	4.5	0	1.25
Perote	0.25	0.75	0.375	0.125	0.75	0.375	0

Tabla 10. Matriz de confusiones del primer ejemplo de este trabajo.

En seguida, se agrupan las confusiones ($conf(vc_i, vc_j)$) de los valores cualitativos que fueron iguales en valor. La posición en la matriz se denota como $[m, n]$, donde m es el número de renglón y n el número de columna.

Grupo 1 (para 0)

[3,4] (Texas, Estados_Unidos)

[5, 7] (La_Gloria, Perote)

[6,4] (California, Estados_Unidos)

Grupo 2 (para 0.125)

[1,4] (Distrito_Federal, Estados_Unidos)

[2,4] (Oaxaca, Estados_Unidos)

[3,6] (Texas, California)

[5,4] (La_Gloria, Estados_Unidos)

[6,3] (California, Texas)

[7,4] (Perote, Estados_Unidos)

Grupo 3 (para 0.25)

[2,1] (Oaxaca, Distrito_Federal)

[4,3] (Estados_Unidos, Texas)

[4,6] (Estados_Unidos, California)

[5,1] (La_Gloria, Distrito_Federal)

[7,1] (Perote, Distrito_Federal)

Grupo 4 (para 0.375)

[1,3] (Distrito_Federal, Texas)

[1,6] (Distrito_Federal, California)

[2,3] (Oaxaca, Texas)

[2,6] (Oaxaca, California)

[3,1] (Texas, Distrito_Federal)

[4,1] (Estados_Unidos, Distrito_Federal)

[5,3] (La_Gloria, Texas)

[5,6] (La_Gloria, California)

[6,1] (California, Distrito_Federal)

[7,3] (Perote, Texas)

[7,6] (Perote, California)

Grupo 5 (para 0.75)

[1,2] (Distrito_Federal, Oaxaca)

[5,2] (La_Gloria, Oaxaca)

[7,2] (Perote, Oaxaca)

[7,5] (Perote, La_Gloria)

Grupo 6 (para 1)

[1,7] (Distrito_Federal, Perote)

[2,7] (Oaxaca, Perote)

Grupo 7 (para 1.125)	Grupo 8 (para 1.25)
[3,2] (Texas, Oaxaca)	[3,7] (Texas, Perote)
[4,2] (Estados_Unidos, Oaxaca)	[4,7] (Estados_Unidos, Perote)
[6,2] (California, Oaxaca)	[6,7] (California, Perote)
Grupo 9 (para 3.75)	Grupo 10 (para 4.5)
[1,5] (Distrito_Federal, La_Gloria)	[3,5] (Texas, La_Gloria)
[2,5] (Oaxaca, La_Gloria)	[4,5] (Estados_Unidos, La_Gloria)
	[6,5] (California, La_Gloria)

A continuación se explican las dos formas de hacer clusters en la técnica 2.

a) Ahora se van a generar las particiones con los grupos que tuvieron la menor confusión, en caso de que se requieran más v_{c_i} para completar la partición se podrán utilizar los v_{c_i} del siguiente grupo. Los bloques de las particiones se llamarán cúmulos o conglomerados.

- Particiones construidas con el grupo 1 de v_{c_i} .
Este grupo contiene a {Texas, Estados_Unidos}, {La_Gloria, Perote} y {California, Estados_Unidos} y las particiones son:

$$\diamond \{ \{ \text{Distrito_Federal} \}, \{ \text{Oaxaca} \}, \{ \text{Texas}, \text{Estados_Unidos} \}, \{ \text{La_Gloria}, \text{California} \}, \{ \text{Perote} \} \}.$$

Después se calcula la confusión total por cada bloque de la partición. Esta confusión la determina el centroide de cada cúmulo y se divide por el número de observaciones en el bloque y por último se realiza la suma de confusiones de cada bloque. Esto se lleva a cabo de la siguiente manera:

Para el cúmulo {Distrito_Federal} su confusión es:

$\text{conf}(\text{Distrito_Federal}, \text{Distrito_Federal})=0$, lo mismo se realiza para los demás conglomerados con un v_{c_i} .

Para el bloque {Texas, Estados_Unidos} su confusión se muestra en la tabla 11.

	Texas	Estados_Unidos	Confusión
Texas	0	0	0
Estados_Unidos	0.25	0	0.25

Tabla 11. Matriz de $\text{conf}(r, s)$ de un bloque con un votantes indecisos.

En este bloque la confusión será 0 porque Texas es el centroide entre ambos v_{c_i} .

La inconsistencia de la partición es:

$\{\{\text{Distrito_Federal}\}, \{\text{Oaxaca}\}, \{\text{Texas, Estados_Unidos}\}, \{\text{La_Gloria}\}, \{\text{California}\}, \{\text{Perote}\}\} = 0+0+0+0+0+0 = 0.$

La partición anterior se descarta debido a que cinco valores cualitativos aparecen como un bloque cada uno y el bloque $\{\text{Texas, Estados_Unidos}\}$ presenta dos votantes indecisos.

❖ La siguiente partición es $\{\{\text{Distrito_Federal}\}, \{\text{Oaxaca}\}, \{\text{Texas}\}, \{\text{California, Estados_Unidos}\}, \{\text{La_Gloria}\}, \{\text{Perote}\}\} = 0$, se puede utilizar la partición anterior o ésta como resultados posibles de inconsistencia.

❖ La partición siguiente es $\{\{\text{Distrito_Federal}\}, \{\text{Oaxaca}\}, \{\text{Texas, Estados_Unidos, La_Gloria, Perote}\}, \{\text{California}\}\} = 0 + 0 + \frac{0.5}{10} + 0 = 0.05.$

	La_Gloria	Texas	Perote	E. U.	Conf. tot.	Conf. prom.
La_Gloria	0	0.375	0	0.125	0.5	0.05
Texas	4.5	0	1.25	0	5.75	0.575
Perote	0.75	0.375	0	0.125	1.25	0.125
E. U.	4.5	0.25	1.25	0	6	0.6

Tabla 12. Matriz de $conf(r, s)$ de un bloque con un votantes indecisos.

Los bloques $\{\text{Distrito Federal}\}$, $\{\text{Oaxaca}\}$ y $\{\text{California}\}$ serían centroides junto con La_Gloria que pertenece al bloque más grande. Pero se descartan aquellos valores cualitativos que aparecen solos en un bloque. Por tanto, La_Gloria será el centro de gravedad de esta partición (ver tabla 12).

❖ Para la partición $\{\{\text{Distrito_Federal}\}, \{\text{Oaxaca}\}, \{\text{Texas, Estados_Unidos}\}, \{\text{La_Gloria, Perote}\}, \{\text{California}\}\} = 0 + 0 + 0 + 0 + 0 = 0.$

Los bloques $\{\text{Distrito_Federal}\}$, $\{\text{Oaxaca}\}$ y $\{\text{California}\}$ son centroides. Además de Texas en el bloque $\{\text{Texas, Estados_Unidos}\}$ y La_Gloria en $\{\text{La_Gloria, Perote}\}$. Pero se desprecian los bloques conformados con un solo valor cualitativo, por lo que restan como posibles resultados Texas y La_Gloria (ver tabla 13 y 14). Se sabe que Texas y Estados Unidos forman un bloque de votantes indecisos por lo que Texas es un valor cualitativo débil y La_Gloria está en un bloque de votantes fuertes, debido a esto se considera que La_Gloria es el centroide de esta partición.

	Estados Unidos	Texas	Conf. Tot.	Conf. Prom.
Estados Unidos	0	0.25	0.25	0.125
Texas	0	0	0	0

Tabla 13. Matriz de $conf(r, s)$ de un bloque con un votantes indecisos.

	La_Gloria	Perote	Conf. Tot.	Conf. Prom.
La_Gloria	0	0	0	0
Perote	0.75	0	0.75	0.093

Tabla 14. Matriz de $conf(r, s)$ de un bloque con un votantes fuertes.

Para $\{\{\text{Distrito_Federal}, \text{Estados_Unidos}, \text{Texas}, \text{California}\}, \{\text{La_Gloria}, \text{Perote}\}, \{\text{Oaxaca}\}\} = \frac{0.5}{4} + 0 + 0 = 0.125$. El primer bloque formado de votantes indecisos generó dos centroides que son California y Texas (ver tabla 3), pero solo se toma en cuenta Texas o California. Para el segundo bloque (ver tabla 14), el centroide es La_Gloria. Y como Texas y California son votantes indecisos, entonces La_Gloria será el centro de gravedad de la partición.

Para la partición $\{\{\text{Oaxaca}\}, \{\text{Distrito_Federal}, \text{Texas}, \text{Estados_Unidos}, \text{La_Gloria}, \text{Perote}, \text{California}\}\} = 0 + \frac{1.125}{12} = 0.093$.

En total se crearon 6 particiones que son las mejores de acuerdo a los valores de confusión que cada uno obtuvo. Se puede observar en detalle que si se dividen demasiado, en la bolsa puede haber muchos centroides con una inconsistencia de 0. Y si se crean bloques grandes en la partición la inconsistencia crecerá y el número de centroides disminuirá.

El método que se utilizó para hallar las mejores particiones en la bolsa de valores cualitativos evita que se lleve a cabo un algoritmo exhaustivo para se tengan que generar todas las particiones mejores de la bolsa.

Para el caso de estudio (influenza), si se toman a las noticias por separado la solución sería que todas dicen la verdad lo cual no da un buen parámetro de donde se originó el virus, como se puede ver en las siguientes particiones.

$\{\{\text{Distrito_Federal}\}, \{\text{Oaxaca}\}, \{\text{Texas}, \text{Estados_Unidos}\}, \{\text{La_Gloria}\}, \{\text{California}\}, \{\text{Perote}\}\} = 0+0+0+0+0+0 = 0$.

$\{\{\text{Distrito_Federal}\}, \{\text{Oaxaca}\}, \{\text{Texas}\}, \{\text{California}, \text{Estados_Unidos}\}, \{\text{La_Gloria}\}, \{\text{Perote}\}\} = 0 + 0 + 0 + 0 + 0 + 0 = 0$, se puede utilizar la partición anterior o ésta como resultados posibles de inconsistencia.

$$\{\{\text{Distrito_Federal}\}, \{\text{Oaxaca}\}, \{\text{Texas, Estados_Unidos}\}, \{\text{La_Gloria, Perote}\}, \{\text{California}\}\} = 0 + 0 + 0 + 0 + 0 = 0.$$

Pero si la partición tiene menos bloques habrá menos centroides, como se enuncia enseguida:

$$\{\{\text{Distrito_Federal}\}, \{\text{Oaxaca}\}, \{\text{Texas, Estados_Unidos, La_Gloria, Perote}\}, \{\text{California}\}\} = 0 + 0 + \frac{0.5}{4} + 0 = 0.125.$$

$$\text{Para } \{\{\text{Distrito_Federal, Estados_Unidos, Texas, California}\}, \{\text{La_Gloria, Perote}\}, \{\text{Oaxaca}\}\} = \frac{0.5}{4} + 0 + 0 = 0.125.$$

Para la partición $\{\{\text{Oaxaca}\}, \{\text{Distrito_Federal, Texas, Estados_Unidos, La_Gloria, Perote, California}\}\} = 0 + \frac{1.125}{12} = 0.093$. La tabla 15 representa el segundo bloque de ésta partición.

	D. F.	Texas	E. U.	La_Gloria	California	Perote	Conf. tot.	Conf. Prom.
D. F.	0	0.375	0.125	3.75	0.375	1	5.625	0.46
Texas	0.375	0	0	4.5	0.125	1.25	6.25	0.52
E. U.	0.375	0.25	0	4.5	0.25	1.25	6.625	0.55
La_Gloria	0.25	0.375	0.125	0	0.375	0	1.125	0.093
California	0.375	0.125	0	4.5	0	1.25	6.25	0.52
Perote	0.25	0.375	0.125	0.75	0.375	0	1.875	0.15

Tabla 15. Matriz de $conf(r, s)$ del cluster $\{\text{Distrito_Federal, Texas, Estados_Unidos, La_Gloria, Perote, California}\}$.

A continuación se detalla el método del inciso **b)** de la técnica 2, para construir los clusters. En caso de que se requieran más vc_i para completar el cluster de determinado número de vc_i 's se podrán utilizar los vc_i del siguiente grupo, es decir, se utilizan primero los valores cualitativos cuyo valor de confusión es cero de la siguiente manera:

Si se quieren los clusters de dos vc_i , se toman las parejas de la columna 1, obedeciendo a la definición de partición, por lo que (Texas, Estados_Unidos) y (California, Estados Unidos) solo se puede elegir de una de las dos parejas no ambas.

Columna 1

Para 0

- [3, 4] (Texas, Estados_Unidos)
- [5, 7] (La_Gloria, Perote)

Columna 2

Para 0.125

- [1,4] (Distrito_Federal, Estados_Unidos)
- [2,4] (Oaxaca, Estados_Unidos)

- [6,4] (California, Estados_Unidos) [3,6] (Texas, California)
- [5,4] (La_Gloria, Estados_Unidos)
- [6,3] (California, Texas)
- [7,4] (Perote, Estados_Unidos)

Si se quieren armar más clusters de dos vc_i , se pueden tomar los de la columna 2 y así de todos los grupos que resultaron de la matriz de confusiones que se detalló arriba.

- Clusters de dos elementos contruidos con el primer grupo de vc_i 's.

El primer cluster es {La_Gloria, Perote}

Otro bloque de dos vc_i es {Texas, Estados_Unidos} o {California, Estados_Unidos} pero no ambos porque deben cumplir los bloques la propiedad de una partición.

La confusión de cada uno de los bloques anteriores es de cero y la inconsistencia generada por ellos será cero.

El centroide para el primer bloque es Texas, el centroide para el segundo bloque es La_Gloria, y California para el último bloque, donde la inconsistencia que generan es cero. Por lo tanto, los posibles resultados son La_Gloria y TexasoCalifornia.

- Clusters de tres elementos

{Texas, Estados Unidos, California}

	Texas	Estados_Unidos	California	Conf. total	Conf. Promedio
Texas	0	0	0.125	0.125	0.041
Estados_Unidos	0.25	0	0.25	0.5	0.16
California	0.125	0	0	0.125	0.041

Tabla 16. Matriz de $conf(r, s)$ del cúmulo {Texas, Estados_Unidos, California}.

En este bloque hay dos centroides Texas y California que generan una confusión total de 0.125 y por tanto la inconsistencia será de 0.041 (ver tabla 16). Esto quiere decir que pudo haber iniciado la influencia en Texas o California.

- Clusters de 4 vc_i 's.

{Texas, Estados Unidos, La_Gloria, Perote}

	Texas	Estados Unidos	La_Gloria	Perote	Conf. Tot.
Texas	0	0	4.5	4.5	9
Estados Unidos	0.25	0	4.5	4.5	9.25
La_Gloria	0.375	0.125	0	0	0.5
Perote	0.375	0.125	0.75	0	1.25

Tabla 17. Matriz de $conf(r, s)$ del cluster {Texas, Estados_Unidos, La_Gloria, Perote}.

En este bloque el centroide es La_Gloria y la inconsistencia es $\frac{0.5}{10} = 0.05$ como se muestra en la tabla 17.

- Clusters de 5 v_{c_i} 's.

{Texas, Estados_Unidos, La_Gloria, California, Perote}

	Texas	Estados Unidos	La_Gloria	California	Perote	Conf. Tot
Texas	0	0	4.5	0.125	1.25	5.87
Estados Unidos	0.25	0	4.5	0.25	1.25	6.25
La_Gloria	0.375	0.125	0	0.375	0	<u>0.875</u>
California	0.125	0	4.5	0	1.25	5.875
Perote	0.375	0.125	0.75	0.375	0	1.625

Tabla 18. Matriz de $conf(r, s)$ del cluster {Texas, Estados_Unidos, La_Gloria, Perote, California}.

En este cluster el centroide fue La_Gloria con una inconsistencia de $\frac{0.875}{11} = 0.079$. En la tabla 18 se presenta la confusión total de La_Gloria.

- Clusters de 6 v_{c_i} 's.

{Distrito_Federal, Texas, Estados_Unidos, La_Gloria, California, Perote}

	Distrito_Federal	Texas	Estados_Unidos	La_Gloria	California	Perote	Conf. Tot.
Distrito_Federal	0	0.375	0.125	3.75	0.375	1	5.625
Texas	0.375	0	0	4.5	0.125	1.25	6.25
Estados_Unidos	0.375	0.25	0	4.5	0.25	1.25	6.625
La_Gloria	0.25	0.375	0.125	0	0.375	0	<u>1.125</u>
California	0.375	0.125	0	4.5	0	1.25	6.25
Perote	0.25	0.375	0.125	0.75	0.375	0	1.875

Tabla 19. Matriz de $conf(r, s)$ del cluster {Distrito_Federal, Texas, Estados_Unidos, La_Gloria, California, Perote}.

El $r^* = \text{La_Gloria}$ con un valor de confusión total de 1.125 (ver tabla 19) y la inconsistencia en el cluster fue 0.093.

Como se puede observar, la primera técnica toma en cuenta tanto a votantes fuertes como a votantes débiles; ya sea separándolos o mezclándolos en clusters diferentes. El segundo método crea los clusters tomando en cuenta las confusiones menores, ya sea a través de la definición de partición de un conjunto o armando subconjuntos de n elementos.

A pesar de lo anterior, ambas técnicas llegan al mismo resultado donde La_Gloria es favorecida con una inconsistencia menor.

En este capítulo se resolvió el objetivo 2 del presente trabajo; el cual, consiste en hallar varios centroides de un conjunto de afirmaciones, cuando el problema permite tener más de un centroide.

Capítulo 6. Actualización de inconsistencia cuando llega una afirmación nueva

En el capítulo 3, se calculó la inconsistencia de una bolsa de afirmaciones B. Ahora bien, ¿qué pasa si aparece una afirmación nueva? Se tienen que analizar las variaciones en la inconsistencia encontrada en principio, si existe modificación en el centroide. Es decir, se quiere saber, ¿qué tanto influye una nueva observación en la inconsistencia de la bolsa nueva?

La figura 18 muestra la manera en que se realiza la actualización de una afirmación sobre la bolsa existente.

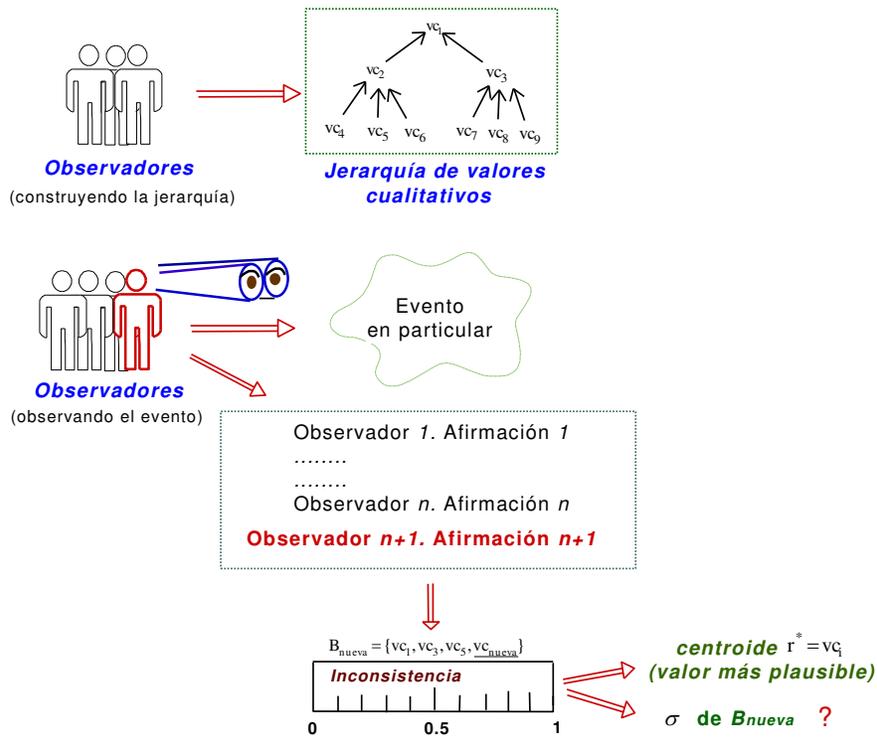


Figura 18. Bosquejo del cálculo de inconsistencia cuando se agrega una nueva afirmación.

La figura anterior detalla cómo se está agregando una afirmación nueva (Afirmación n+1) sobre la bolsa de valores cualitativos actual, enseguida se realiza el cálculo de inconsistencia con la nueva bolsa. Por último, se tiene el nuevo centroide que puede ser el que ya se tenía u otro y el nuevo valor de inconsistencia.

Es importante mencionar que la nueva afirmación representa al mismo evento que todos los observadores vieron en un tiempo determinado t y ni el evento observado, ni el tiempo en el cual ocurrió cambia.

A continuación se analiza formalmente la manera en que se actualiza la tabla de confusiones cuando aparece una afirmación nueva.

Sea una afirmación nueva denotada por a_{nueva} , el valor cualitativo vc_{nuevo} que se extrae de a_{nueva} y sea la bolsa de valores cualitativos actual B_{act} .

Caso A. Si $vc_{nuevo} \notin B$, entonces el vc_{nuevo} se agrega a la B_{act} de la siguiente manera:

$$\text{Para } vc_1, \text{ conf}(vc_1,vc_1) + \text{conf}(vc_1,vc_2) + \dots + \text{conf}(vc_1,vc_{nuevo}) = \sum_{i=1}^{nuevo} \text{conf}(vc_1,vc_i) \dots\dots(11a)$$

$$\text{Para } vc_2, \text{ conf}(vc_2,vc_1) + \text{conf}(vc_2,vc_2) + \dots + \text{conf}(vc_2,vc_{nuevo}) = \sum_{i=1}^{nuevo} \text{conf}(vc_2,vc_i) \dots\dots(11b)$$

.

$$\text{Para } vc_{n-1}, \text{ conf}(vc_{n-1},vc_1) + \text{conf}(vc_{n-1},vc_2) + \dots + \text{conf}(vc_{n-1},vc_{nuevo}) = \sum_{i=1}^{nuevo} \text{conf}(vc_{n-1},vc_i) \dots\dots(11y)$$

$$\text{Para } vc_{nuevo}, \text{ conf}(vc_{nuevo},vc_1) + \text{conf}(vc_{nuevo},vc_2) + \dots + \text{conf}(vc_{nuevo},vc_n) = \sum_{i=1}^{nuevo} \text{conf}(vc_{nuevo},vc_i) \dots\dots(11z)$$

Por lo tanto, la bolsa nueva denotada por B_{nueva} queda compuesta por $B_{nueva} = \{vc_1,vc_2,\dots,vc_{n-1},vc_{nuevo}\}$

Caso B. Si $vc_{nuevo} \in B$, entonces el vc_{nuevo} ya existe en la bolsa y contará como una nueva observación sobre el vc de B que sea igual al vc_{nuevo} . Los únicos cálculos nuevos que se realizan serán sobre la columna que involucra al vc_{nuevo} y no se re calcularán aquellos donde $vc_{nuevo} \succ vc_i$.

Para vc_1 con $\#O_{vc_1}$ observaciones,

$$\frac{\text{Conf}(vc_1, vc_1)}{h} + \sum_{\#O_{vc_2}=1}^{\#OT_{vc_2}} \left(\frac{\text{Conf}(vc_1, vc_2)}{h} \right)^{\#O_{vc_2}} + \dots + \boxed{\sum_{\#O_{vc_n}=1}^{\#OT_{vc_n}} \left(\frac{\text{Conf}(vc_1, vc_n)}{h} \right)^{\#O_{vc_{nuevo}}}} \quad \dots\dots(12a)$$

Para vc_2 con $\#O_{vc_2}$ observaciones,

$$\sum_{\#O_{vc_1}=1}^{\#OT_{vc_1}} \left(\frac{\text{Conf}(vc_2, vc_1)}{h} \right)^{\#O_{vc_1}} + \frac{\text{Conf}(vc_2, vc_2)}{h} + \dots + \boxed{\sum_{\#O_{vc_n}=1}^{\#OT_{vc_n}} \left(\frac{\text{Conf}(vc_2, vc_n)}{h} \right)^{\#O_{vc_{nuevo}}}} \quad \dots\dots(12b)$$

⋮
⋮
⋮
⋮
⋮

Para vc_{n-1} con $\#O_{vc_{n-1}}$ observaciones,

$$\sum_{\#O_{vc_1}=1}^{\#OT_{vc_1}} \left(\frac{\text{Conf}(vc_{n-1}, vc_1)}{h} \right)^{\#O_{vc_1}} + \sum_{\#O_{vc_2}=1}^{\#OT_{vc_2}} \left(\frac{\text{Conf}(vc_{n-1}, vc_2)}{h} \right)^{\#O_{vc_2}} + \dots + \frac{\text{Conf}(vc_{n-1}, vc_{n-1})}{h} + \boxed{\sum_{\#O_{vc_n}=1}^{\#OT_{vc_{nuevo}}} \left(\frac{\text{Conf}(vc_{n-1}, vc_n)}{h} \right)^{\#O_{vc_{nuevo}}}} \quad \dots(12y)$$

Para vc_n con $\#O_{vc_n}$ observaciones,

$$\sum_{\#O_{vc_1}=1}^{\#OT_{vc_1}} \left(\frac{\text{Conf}(vc_n, vc_1)}{h} \right)^{\#O_{vc_1}} + \sum_{\#O_{vc_2}=1}^{\#OT_{vc_2}} \left(\frac{\text{Conf}(vc_n, vc_2)}{h} \right)^{\#O_{vc_2}} + \dots + \boxed{\frac{\text{Conf}(vc_{nuevo}, vc_{nuevo})}{h}} \quad \dots\dots(12z)$$

Experimento 4

Retomando el ejemplo 2 de este trabajo, se añade una afirmación a la lista anterior de la siguiente manera:

Lista anterior de afirmaciones

- $a_1 =$ Juan tiene un felino,
- $a_2 =$ Juan tiene un gato doméstico,
- $a_3 =$ Juan tiene un gato siamés,
- $a_4 =$ Juan tiene un gato siamés,
- $a_5 =$ Juan tiene un perro,
- $a_6 =$ Juan tiene un canino,
- $a_7 =$ Juan tiene un xoloitzcuintle,
- $a_8 =$ Juan tiene un perro chihuahueño,
- $a_9 =$ Juan tiene un águila.

Afirmación nueva (a_{nueva}).

- $a_{10} =$ Juan posee un gato doméstico.

Valores cualitativos (vc_i) sin vc_{nuevo}

- $vc_1 = \text{Felino}$, con $\#O_{vc_1} = 1$ observaciones,
- $vc_2 = \text{Gato_domestico}$, con $\#O_{vc_2} = 1$ observaciones.
- $vc_3 = \text{Gato_siames}$, con $\#O_{vc_3} = 2$ observaciones,
- $vc_4 = \text{Canino}$, con $\#O_{vc_4} = 2$ observaciones,
- $vc_5 = \text{Xoloitzcuintle}$, con $\#O_{vc_5} = 1$ observaciones,

- $vc_6 = \text{Chihuahua}$, con $\#O_{vc_6} = 1$ observaciones,
- $vc_7 = \text{aguila}$, con $\#O_{vc_7} = 1$ observaciones.

Valor cualitativo nuevo (vc_{nuevo})

$vc_{nuevo} = \text{gato_domestico}$, con $\#O_{vc_{nuevo}} = 1$ observación.

La bolsa actual está formada por $B = \{vc_1, vc_2, vc_3, vc_4, vc_5, vc_6, vc_7\}$. Ahora bien, debido a que $vc_{nuevo} \subset B$ (**caso A**), pues $vc_{nuevo} = vc_2$, B no se modifica, solo se incrementa en uno el número de observaciones sobre vc_2 quedando como $\#O_{vc_2} = 2$.

Valores cualitativos (vc_i) con la nueva observación.

- $vc_1 = \text{Felino}$, con $\#O_{vc_1} = 1$ observaciones,
- $vc_2 = \text{Gato_domestico}$, con $\boxed{\#O_{vc_2} = 2}$ observaciones.
- $vc_3 = \text{Gato_siames}$, con $\#O_{vc_3} = 2$ observaciones,
- $vc_4 = \text{Canino}$, con $\#O_{vc_4} = 2$ observaciones,
- $vc_5 = \text{Xoloitzcuintle}$, con $\#O_{vc_5} = 1$ observaciones,
- $vc_6 = \text{Chihuahua}$, con $\#O_{vc_6} = 1$ observaciones,
- $vc_7 = \text{aguila}$, con $\#O_{vc_7} = 1$ observaciones.

La jerarquía de mascotas con la nueva afirmación se puede ver en la figura 19. Donde el símbolo de la mano apunta un asterisco que representa la nueva observación sobre el valor cualitativo `gato_domestico`.

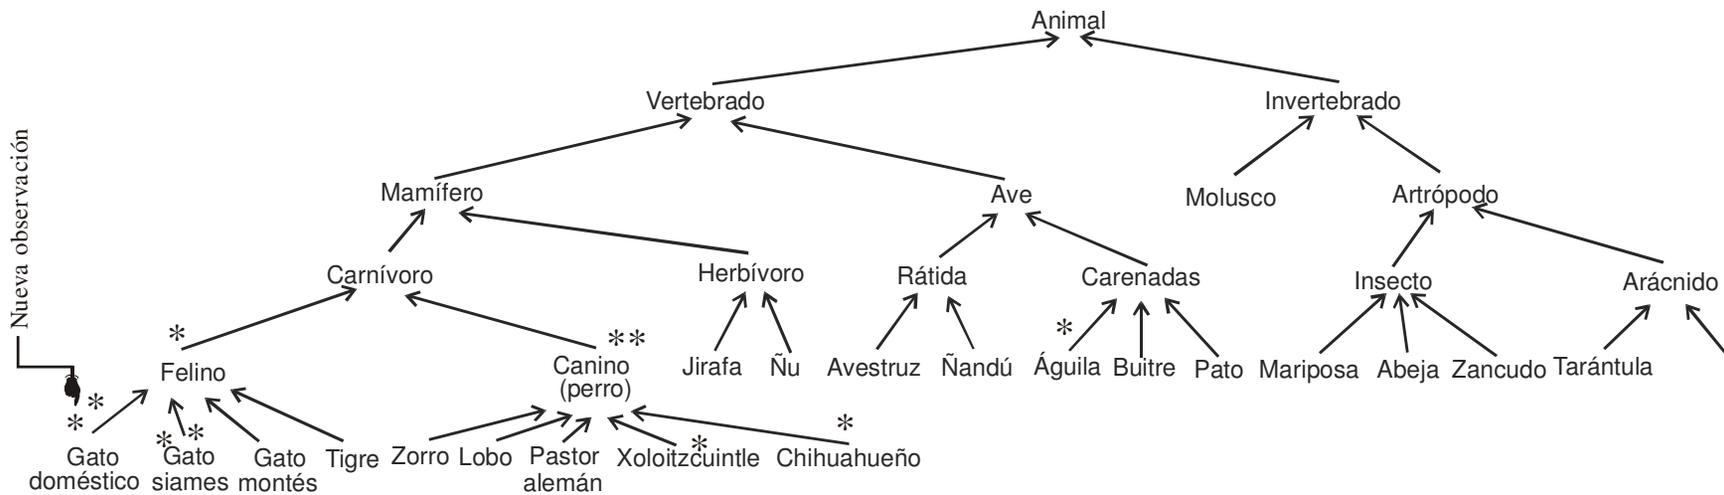


Figura 19. Jerarquía de algunos animales que incluye la nueva observación.

Debido a que solo se está incrementando el número de observaciones sobre $vc_2 = \text{Gato_domestico}$, se debe añadir la nueva observación como se puede ver en la columna 3 (ver tabla 20 y 21) relacionada con Gato_domestico.

	Felino	Gato_domestico	Gato_siames
Felino	conf(Felino,Felino)	conf(Felino,Gato_domestico)+ conf(Felino,Gato_domestico)	conf(Felino,Gato_siames)+ conf(Felino,Gato_siames)
Gato_domestico	conf(Gato_domestico,Felino)	conf(Gato_domesticoGato_domestico)+ conf(Gato_domesticoGato_domestico)	conf(Gato_domesticoGato_siames)+ conf(Gato_domesticoGato_siames)
Gato_siames	conf(Gato_siames,Felino)	conf(Gato_siames,Gato_domestico)+ conf(Gato_siames,Gato_domestico)	conf(Gato_siames,Gato_siames)+ conf(Gato_siames,Gato_siames)
Canino	conf(Canino,Felino)	conf(Canino,Gato_domestico)+ conf(Canino,Gato_domestico)	conf(Canino,Gato_siames)+ conf(Canino,Gato_siames)
Xoloitzcuintle	conf(Xoloitzcuintle,Felino)	conf(Xoloitzcuintle,Gato_domestico)+ conf(Xoloitzcuintle,Gato_domestico)	conf(Xoloitzcuintle,Gato_siames)+ conf(Xoloitzcuintle,Gato_siames)
Chihuahua	conf(Chihuahua,Felino)	conf(Chihuahua)Gato_domestico+ conf(Chihuahua,Gato_domestico)	conf(Chihuahua,Gato_siames)+ conf(Chihuahua,Gato_siames)
Aguila	conf(Aguila,Felino)	conf(Aguila,Gato_domestico)+ conf(Aguila,Gato_domestico)	conf(Aguila,Gato_siames)+ conf(Aguila,Gato_siames)

Tabla 20. Actualización de la bolsa de afirmaciones

Canino	Xoloitzcuintle	Chihuahua	Aguila
conf(Felino,Canino)+ conf(Felino,Canino)	conf(Felino,Xoloitzcuintle)	conf(Felino,Chihuahua)	conf(Felino,Aguila)
conf(Gato_domestico,Canino)+ conf(Gato_domestico,Canino)	conf(Gato_domestico,Xoloitzcuintle)	conf(Gato_domestico,Chihuahua)	conf(Gato_domestico,Aguila)
conf(Gato_siames,Canino)+ conf(Gato_siames,Canino)	conf(Gato_siames,Xoloitzcuintle)	conf(Gato_siames,Chihuahua)	conf(Gato_siames,Aguila)
conf(,Canino,Canino)+ conf(,Canino,Canino)	Conf(Canino,Xoloitzcuintle)	conf(Canino,Chihuahua)	conf(Canino,Aguila)
conf(Xoloitzcuintle,Canino)+ conf(Xoloitzcuintle,Canino)	conf(Xoloitzcuintle,Xoloitzcuintle)	conf(Xoloitzcuintle,Chihuahua)	conf(Xoloitzcuintle,Aguila)
conf(Chihuahua,Canino)+ conf(Chihuahua,Canino)	conf(Chihuahua,Xoloitzcuintle)	conf(Chihuahua,Chihuahua)	conf(Chihuahua,Aguila)
conf(Aguila,Canino)+ conf(Aguila,Canino)	conf(Aguila,Xoloitzcuintle)	conf(Aguila,Chihuahua)	conf(Aguila,Aguila)

Tabla 21. Actualización de la bolsa de afirmaciones

La tabla 22 presenta la confusión total de cada valor cualitativo.

	Felino	Gato_domestico	Gato_siames	Canino	Xoloitzcuintle	Chihuahua	Aguila	Confusión
Felino	0	0.4	0.4	0.4	0.4	0.4	0.6	2.6
Gato_domestico	0	0	0.4	0.4	0.4	0.4	0.6	2.2
Gato_siames	0	0.4	0	0.4	0.4	0.4	0.6	2.2
Canino	0.2	0.8	0.8	0	0.2	0.2	0.6	2.8
Xoloitzcuintle	0.2	0.8	0.8	0	0	0.2	0.6	2.6
Chihuahua	0.2	0.8	0.8	0	0.2	0	0.6	2.6
Aguila	0.6	1.6	1.6	1.2	0.8	0.8	0	6.6

Tabla 22.Resultados de confusión total por cada valor cualitativo.

La tabla 23 muestra las inconformidades de cada elemento de la bolsa.

	Felino	Gato_domestico	Gato_siames	Canino	Xoloitzcuintle	Chihuahua	Aguila	Conf. Tot	Conf. Prom
Felino	0	0.4	0.4	0.4	0.4	0.4	0.6	2.6	0.26
Gato_domestico	0	0	0.4	0.4	0.4	0.4	0.6	2.2	0.22
Gato_siames	0	0.4	0	0.4	0.4	0.4	0.6	2.2	0.22
Canino	0.2	0.8	0.8	0	0.2	0.2	0.6	2.8	0.28
Xoloitzcuintle	0.2	0.8	0.8	0	0	0.2	0.6	2.6	0.26
Chihuahua	0.2	0.8	0.8	0	0.2	0	0.6	2.6	0.26
Aguila	0.6	1.6	1.6	1.2	0.8	0.8	0	6.6	0.66

Tabla 23.Resultados de inconformidades sobre la bolsa de afirmaciones.

Nótese que apareció otro centroide que cumple con tener la menor inconsistencia en la bolsa al igual que el r^* anterior (ver columna Conf. Prom.de la tabla 23).

Por lo tanto, puede elegirse cualquiera de estos dos centroides como el que minimiza la inconsistencia de la bolsa; ya sea que Juan tenga un gato común y corriente o un gato siamés.

Propiedad 1.

Dada una afirmación nueva a_{nueva} y un valor cualitativo vc_{nuevo} , si vc_{nuevo} es hermano de r^* sobre la jerarquía J y además tienen el mismo número de observaciones; entonces vc_{nuevo} también será un r^* .

Para realizar los cálculos de actualización anteriores, se puede utilizar la aplicación que se construyó. A continuación se indica se agrega ésta a través de las siguientes pantallas (ver figura 20):

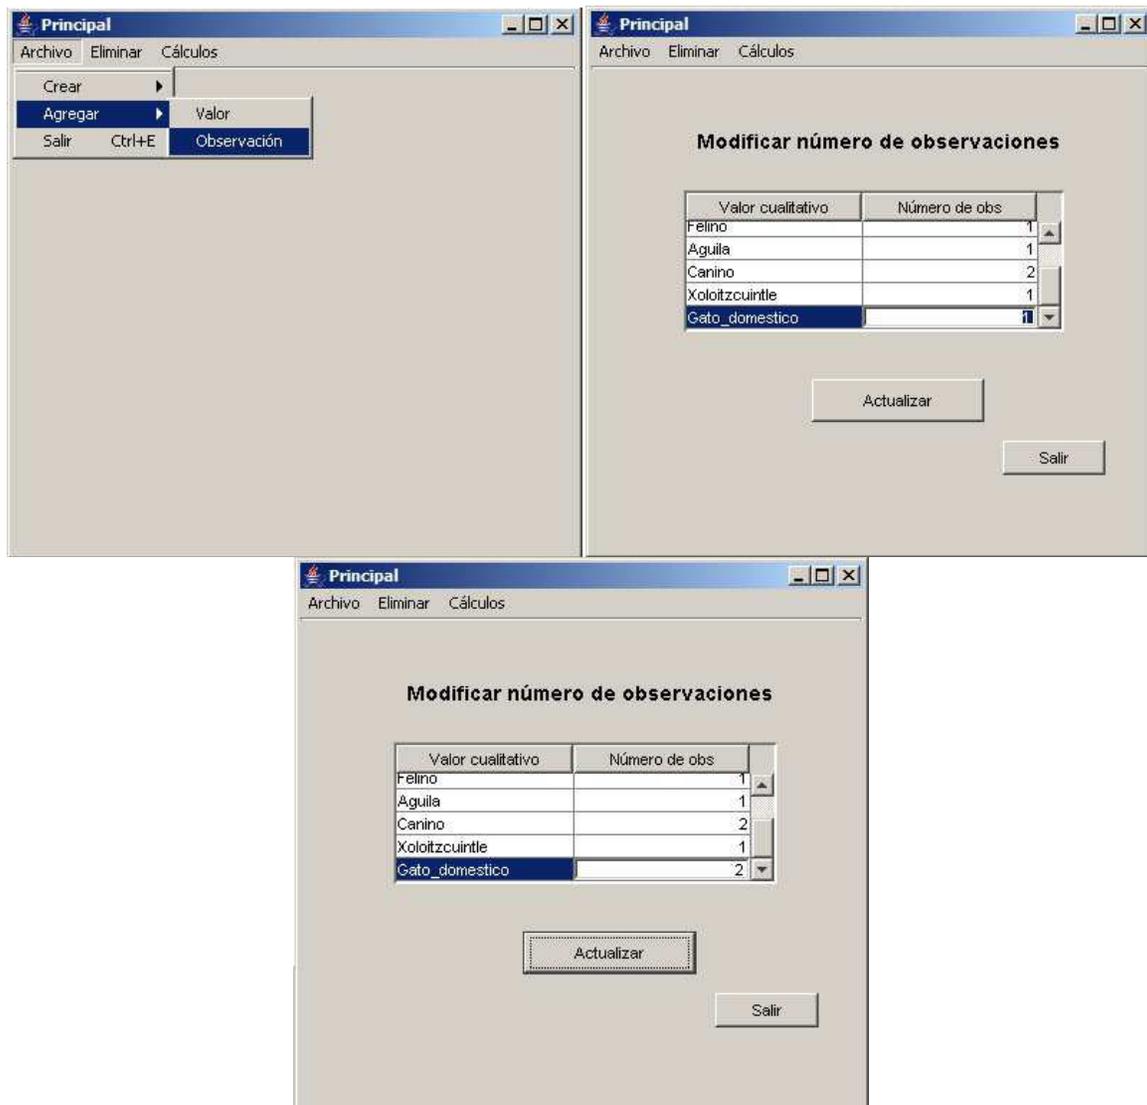


Figura 20. Pantallas para agregar nueva observación.

La figura anterior, muestra las pantallas que se tienen que abrir para agregar la nueva observación sobre gato_domestico. Para actualizar los datos nuevos se da clic en el botón Actualizar.

La figura 21 muestra las confusiones $\text{conf}(r,s)$ por cada vc_i y la columna 9 representa la confusión promedio por cada vc_i .

Inconsistencia de valores cualitativos

Valor cualitativo	Chihuahua	Gato_siam...	Felino	Aguaia	Canino	Xoloitzcuintle	Gato_dome...	Inc
Chihuahua	0.0	0.8	0.2	0.6	0.0	0.2	0.8	0.26
Gato_siames	0.4	0.0	0.0	0.6	0.4	0.4	0.4	0.22
Felino	0.4	0.4	0.0	0.6	0.4	0.4	0.4	0.26
Aguaia	0.8	1.6	0.6	0.0	1.2	0.8	1.6	0.66
Canino	0.2	0.8	0.2	0.6	0.0	0.2	0.8	0.28
Xoloitzcuintle	0.2	0.8	0.2	0.6	0.0	0.0	0.8	0.26
Gato_domestico	0.4	0.4	0.0	0.6	0.4	0.4	0.0	0.22

VALORES CON LA MENOR INCONSISTENCIA SOBRE 10 OBSERVACIONES

Gato_siames con una inconsistencia de 0.22
Gato_domestico con una inconsistencia de 0.22

Figura 21. Matriz de confusiones e inconformidades que presenta cada afirmación.

La inconsistencia de la bolsa de afirmaciones es de 0.22 y se puede elegir cualquiera de los dos centroides, ya sea Gato_domestico o Gato_siames.

Propiedad 2.

Dada una bolsa $B = \{vc_1, vc_2, \dots, vc_{n-1}, vc_n\}$,

- Si existen valores cualitativos (vc) ascendentes sobre el centroide r^* y además $vc's \in B$, ninguno podrá ser centroide sin importar el número de observaciones que haya sobre estos $vc's$. (Ver experimento), y
- todo valor cualitativo que tenga $vc's$ descendentes tampoco podrá ser centroide.

En este capítulo se resolvió el objetivo 3 del presente trabajo. Que consiste en analizar y medir la inconsistencia que una nueva afirmación añadida al conjunto de afirmaciones, provoca en el nuevo conjunto. Qué tanto esta afirmación cambia la inconsistencia del conjunto.

Capítulo 7. Encontrando inconsistencia cuando se elimina el greatest outlier

Se va examinar la bolsa cuando se elimina la afirmación o valor cualitativo que representa al **greatestoutlier**, es decir el que genera la confusión total mayor con respecto al **centroide**.

¿Variará el centroide, es decir, cambiará el centroide r^* ?, ¿se obtendrá una inconsistencia menor o mayor sobre la que ya se tenía de la bolsa?

A continuación se explica la manera en que se realiza esta eliminación.

Partiendo de la **confusión total** que el centroide r^* produce en B descrito en la ecuación 3, si $r^* = vc_i$,

$$\text{conf}(r^*, vc_1) + \text{conf}(r^*, vc_2) + \dots + \text{conf}(r^*, r^*) + \dots + \text{conf}(r^*, vc_n),$$

entonces se excluye la confusión mayor de r^* en lugar del vc_{lejano} , es decir, $\text{conf}(r^*, vc_{\text{lejano}})$. Se elimina el vc más alejado del centroide.

Para el caso A y B (explicados en el capítulo 4) se realiza el mismo procedimiento, debido a que se toma el vc_{lejano} sin tomar en cuenta si tiene más de una observación.

En seguida, se presenta un ejemplo para detallar lo antes expuesto.

Experimento 6 (Retomando el experimento 5)

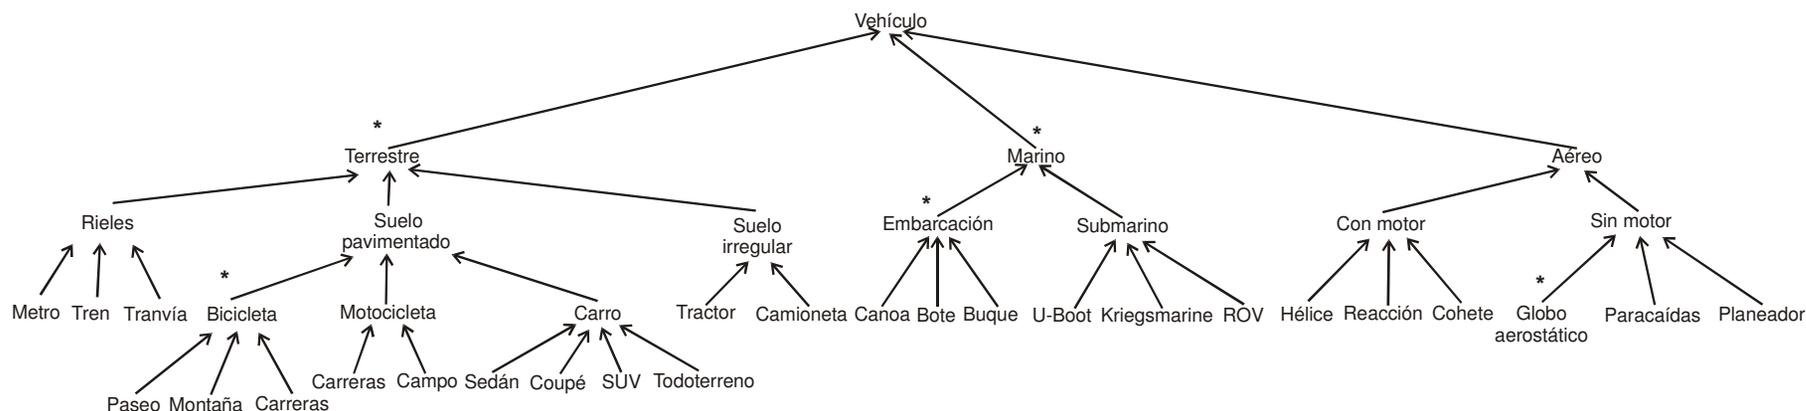


Figura 22. Jerarquía de algunos transportes, donde cada símbolo * representa una observación sobre dicho valor cualitativo.

La confusión de cada vc_i en B queda de la siguiente manera

	Terrestre	Bicicleta	Marino	Embarcación	Globo	Conf. Tot.	Conf. Prom.
Terrestre	0	0.5	0.25	0.5	0.75	2	0.4
Bicicleta	0	0	0.25	0.5	0.75	1.5	0.3
Marino	0.25	0.75	0	0.25	0.75	2	0.4
Embarcación	0.25	0.75	0	0	0.75	1.75	0.35
Globo	0.25	0.75	0.25	0.5	0	1.75	0.35

Tabla 24. Resultado de calcular la confusión de cada valor cualitativo en la bolsa.

En la tabla 24, se puede observar que la menor confusión total esta dada por Bicicleta con un valor de 1.5. Se resalta con un cuadro la confusión $conf(r^*, vc_{lejano})$, donde el vc más alejado del centroide es Globo. La tabla 25 muestra los resultados cuando es eliminado Globo.

	Terrestre	Bicicleta	Marino	Embarcación	Conf. Tot.	Conf. Prom.
Terrestre	0	0.5	0.25	0.5	1.25	0.31
Bicicleta	0	0	0.25	0.5	0.75	0.19
Marino	0.25	0.75	0	0.25	1.25	0.31
Embarcación	0.25	0.75	0	0	1	0.25

Tabla 25.Tabla resultante cuando se descarta al valor cualitativo Globo, generando una nueva bolsa.

Como se puede ver en la tabla 26, el centroide sigue siendo Bicicleta y ahora el valor cualitativo más lejano a Bicicleta es Embarcación. Si se siguen eliminando los vc lejanos a Bicicleta los resultados serían los que se ven en la tabla 27:

	Terrestre	Bicicleta	Marino	Conf. Tot.	Conf. Prom.
Terrestre	0	0.5	0.25	0.75	0.25
Bicicleta	0	0	0.25	0.25	0.08
Marino	0.25	0.75	0	1	0.33

Tabla 26.Matriz de valores cuando se elimina Embarcación.

En la tabla 27 se ve que ya se eliminó a Marino y que el centroide nunca cambió.

	Terrestre	Bicicleta	Conf. Tot.	Conf. Prom.
Terrestre	0	0.5	0.5	0.25
Bicicleta	0	0	0	0

Tabla 27.Matriz de confusiones con solo dos valores cualitativos.

En este ejemplo el centroide no cambió excluyendo los outliers que iban apareciendo.

Observación

La jerarquía de valores cualitativos de la figura 23 representa un ejemplo cuando cambia el centroide, es decir el centroide que se tenía deja de serlo y otro vc será ahora el nuevo centroide, una vez que se excluye el vc más discrepante con respecto a r^* . Se elimina el mayor valor que genere comparar a r^* con respecto a los vc de la bolsa B.

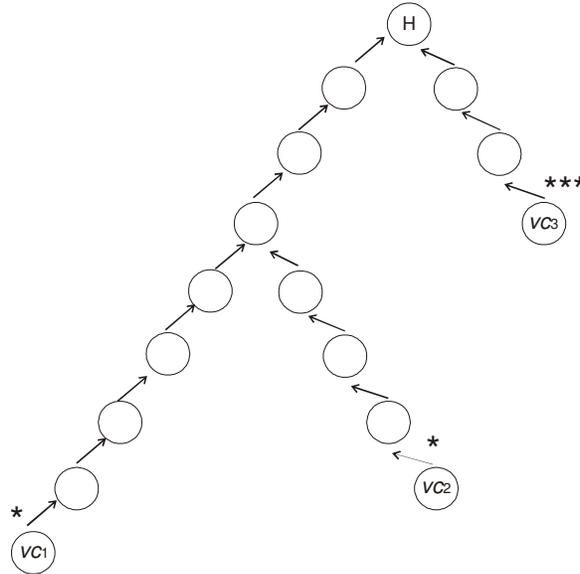


Figura 23. En esta jerarquía los nodos con el símbolo * representa una observación sobre ese vc_i .

En la figura 23 se tienen tres valores cualitativos donde uno de ellos tiene tres observaciones.

La bolsa de valores cualitativos queda formada como sigue:

$$B = \{vc_1, vc_2, vc_3\}.$$

	vc_1	vc_2	vc_3	Conf. Tot.	Conf. Prom.
vc_1	0	0.5	(0.375)(3)	1.625	0.32
vc_2	0.62	0	(0.375)(3)	1.75	0.35
vc_3	1	0.87	0	1.87	0.37

Tabla 28. Confusiones individuales, totales y promedio de cada vc_i .

En la tabla 28, columna 5 se resalta con un cuadro sólido el centroide $r^* = vc_1$.

Como se puede observar la confusión de $vc_1 \times B$ se obtiene como:

$$\begin{aligned} \text{conf}(vc_1, vc_1) + \text{conf}(vc_1, vc_2) + [\text{conf}(vc_1, vc_3) + \text{conf}(vc_2, vc_3) + \text{conf}(vc_3, vc_3)] = \\ 0 + 0.5 + [0.375 + 0.375 + 0.375] = \\ 0 + 0.5 + 1.125 = 1.625 \end{aligned}$$

y donde $\text{conf}(vc_1, vc_2)$ da el valor de confusión mayor, es decir, vc_2 tiene más desacuerdo que los demás con respecto a vc_1 . Note que el número total de observaciones sobre vc_3 no se toman, solo se considera como una observación para la eliminación. Por lo que se excluye vc_2 quedando $B_{\text{nueva}} = \{vc_1, vc_3\}$, donde los nuevos valores se muestran en la tabla 29.

	vc_1	vc_3	Conf. Tot.	Conf. Prom.
vc_1	0	0.375*(3)	1.125	0.28
vc_3	1	0	1	0.25

Tabla 29. Resultado de confusiones totales y promedio cuando se elimina vc_2 .

Como se puede observar en las tablas 32 y 33 en B , $r^* = vc_1$ y en B_{nueva} , $r^* = vc_3$.

Por lo tanto, vc_3 es el nuevo centroide y se puede ver que en este caso de estudio el centroide está representado por otro valor cualitativo diferente al centroide que se tenía originalmente.

Esto no implica que para todos los casos el centroide cambie, por lo que no se puede dar una demostración de que sí se modifica el centroide, debido a que no se cumple para todos los casos de estudio que se planteen. Es decir, cuando se elimina el valor más alejado (del centroide actual), el nuevo centroide de la bolsa así reducida puede o no cambiar. Esto resuelve el problema 4.

Capítulo 8. Medición de inconsistencia entre objetos

En este capítulo se realiza el estudio de inconsistencia sobre una bolsa de objetos cuyas características están dadas por afirmaciones que describen al objeto. Por ejemplo, el objeto persona donde sus características son: es de tez morena, es alta, su religión es cristiana, tiene un caballo, etc.

Se quiere calcular la inconsistencia de una bolsa de objetos.

Análisis de inconsistencia con objetos

Un **objeto** es un evento o hecho descrito por varias variables cualitativas.

Cada objeto está descrito por características. Cada valor que pertenece a una característica está representado en una jerarquía de valores cualitativos. Entonces, si un objeto contiene 5 características, entonces cada valor debe estar representado en una jerarquía distinta. Por lo tanto habrá 5 jerarquías sobre las cuales se trabajará para calcular la inconsistencia de la bolsa. La figura 24, trata de explicar todos los pasos que se siguen para hallar la inconsistencia de una bolsa de objetos, donde ya no va haber una sola jerarquía sino que se tendrá una jerarquía por cada característica del objeto y por cada observación habrá un objeto.

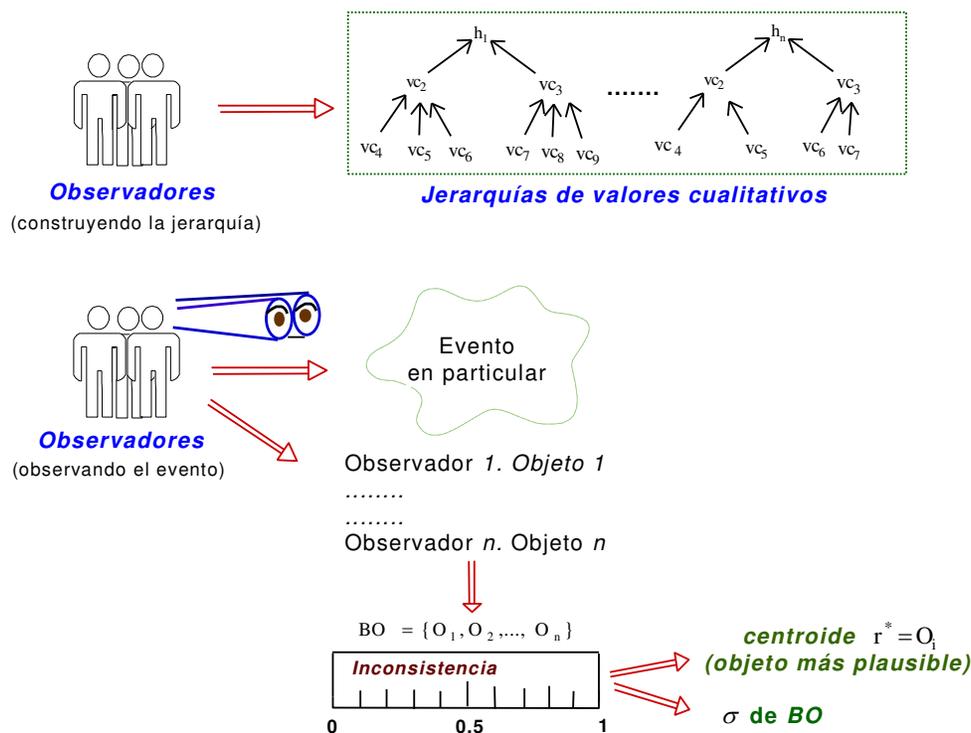


Figura 24. Bosquejo de la manera en que se calcula la inconsistencia de una bolsa de objetos.

A continuación se definen los conceptos necesarios y generar los datos de entrada para el cálculo de inconsistencia de los objetos:

Definición 1. Sea BO una bolsa de objetos $BO = \{O_1, O_2, \dots, O_n\}$, donde cada objeto está formado por m pares (propiedad, valor), como $(p_1, vc_1), (p_2, vc_2), \dots, (p_m, vc_m)$, el subíndice m representa el número de objeto, n el número de valor cualitativo y

$P = \{p_1, p_2, \dots, p_m\}$, representa al conjunto de propiedades del objeto y su dominio son todas aquellas variables lingüísticas⁷ que representan a cada característica de un objeto. Por ejemplo de la variable lingüística tamaño resultan como sus valores cualitativos peso, color, religión, mascota, etc.

$VC = \{vc_1, vc_2, \dots, vc_m\}$ es el conjunto de valores cualitativos donde su dominio son los valores que pueda tomar una variable lingüística. Por ejemplo, la propiedad tamaño puede tener como valores cualitativos bajo, mediano, alto, etc.

$H = \{h_1, h_2, \dots, h_s\}$ es el conjunto de jerarquías que incluyen los valores cualitativos que describen las características de los objetos. Por ejemplo la variable mascota incluirá únicamente valores cualitativos de animales, la variable religión contendrá solo valores de religiones. Las jerarquías de valores cualitativos son creadas por los observadores y a partir de éstas se van obteniendo las propiedades de los objetos.

El subíndice s representa el número de jerarquías que se están utilizando.

Entonces, cada objeto queda construido de la siguiente manera:

$$\begin{aligned}
 O_1 &= \{(p_1, vc_1), (p_2, vc_2), \dots, (p_m, vc_m)\} \\
 O_2 &= \{(p_1, vc_1), (p_2, vc_2), \dots, (p_m, vc_m)\} \\
 &\dots \dots \dots (15) \\
 &\dots \\
 O_n &= \{(p_1, vc_1), (p_2, vc_2), \dots, (p_m, vc_m)\}
 \end{aligned}$$

donde vc_1 de $O_1, O_2, \dots, O_n \in \text{Dom}(p_1)$, vc_2 de $O_1, O_2, \dots, O_n \in \text{Dom}(p_2)$, ..., vc_n de $O_1, O_2, \dots, O_n \in \text{Dom}(p_n)$.

Una vez que ya se tienen definidos los datos de entrada, se debe calcular la inconsistencia de una bolsa de objetos. Ésta se lleva a cabo calculando la confusión entre cada objeto.

⁷ Variable lingüística también llamada variable cualitativa donde su dominio son valores cualitativos relacionados con la variable lingüística en cuestión.

Para comparar dos objetos se calcula la confusión entre ellos con la función $\text{conf}(O_r, O_s)$. Esto permite comparar el valor de cada propiedad del O_r con respecto a los valores de las propiedades correspondientes del objeto O_s . Se comparan el valor de la primera propiedad entre ambos objetos, enseguida el segundo valor de la segunda propiedad entre los objetos, y así para los demás valores que conforman los objetos, entonces se obtiene la suma de cada propiedad dividida por el número de propiedades totales. En la ec.16 se realiza el cálculo de confusión de dos objetos.

$$\begin{aligned} \text{conf}(O_r, O_s) &= \frac{\text{conf}(vc_{r,1}, vc_{s,1}) + \text{conf}(vc_{r,2}, vc_{s,2}) + \dots + \text{conf}(vc_{r,n}, vc_{s,n})}{n(P)} \\ &= \frac{\sum_{i=1}^n \text{conf}(vc_{r,i}, vc_{s,i})}{n(P)}. \end{aligned} \quad \dots(16)$$

n es el número de valor cualitativo,
 $n(P)$ es el número total de propiedades del conjunto P .

Para calcular la confusión total de cada objeto se realiza la confusión de $O \times O$ como lo muestra a continuación.

Sea una bolsa de objetos $BO = \{O_1, O_2, \dots, O_n\}$ con m pares (propiedad, valor), como $(p_1, vc_1), (p_2, vc_2), \dots, (p_m, vc_m)$, la confusión total se obtiene:

Para O_1

$$\frac{\text{conf}(vc_{1,1}, vc_{2,1}) + \text{conf}(vc_{1,2}, vc_{2,2}) + \dots + \text{conf}(vc_{1,n}, vc_{n,n})}{n(P)} = \frac{\sum_{i=1}^n \text{conf}(vc_{1,i}, vc_{i,i})}{n(P)}, \quad (17a)$$

Para O_2

$$\frac{\text{conf}(vc_{2,1}, vc_{2,1}) + \text{conf}(vc_{2,2}, vc_{2,2}) + \dots + \text{conf}(vc_{2,n}, vc_{n,n})}{n(P)} = \frac{\sum_{i=1}^n \text{conf}(vc_{2,i}, vc_{i,i})}{n(P)}, \quad (17b)$$

·
·
·

Para O_{n-1}

$$\frac{\text{conf}(vc_{n-1,1}, vc_{1,1}) + \text{conf}(vc_{n-1,2}, vc_{2,2}) + \dots + \text{conf}(vc_{n-1,n}, vc_{2,n})}{n(P)} = \frac{\sum_{i=1}^n \text{conf}(vc_{n-1,i}, vc_{i,i})}{n(P)},$$

....(17c)

Para O_n

$$\frac{\text{conf}(vc_{n,1}, vc_{1,1}) + \text{conf}(vc_{n,2}, vc_{2,2}) + \dots + \text{conf}(vc_{n,n}, vc_{n,n})}{n(P)} = \frac{\sum_{i=1}^n \text{conf}(vc_{n,i}, vc_{i,i})}{n(P)}, \dots(17d)$$

La **confusión total** que O_i produce en $BO = \{O_1, O_2, \dots, O_n\}$ se obtiene como lo muestra la ecuación 18.

$$\begin{aligned} & \frac{\text{conf}(vc_{i,1}, vc_{1,1}) + \text{conf}(vc_{i,2}, vc_{2,2}) + \dots + \text{conf}(vc_{i,i}, vc_{i,i}) + \dots + \text{conf}(vc_{i,n}, vc_{n,n})}{n(P)} \\ &= \text{conf}(O_i, O_1) + \text{conf}(O_i, O_2) + \dots + \text{conf}(O_i, O_n) \quad \dots(18) \\ &= \sum_{j=1}^n \text{conf}(O_i, O_j). \end{aligned}$$

Es el descontento total de los objetos de la bolsa, la suma de cada uno de los descontentos de O_1, O_2, \dots, O_n , cuando se elige O_i en lugar de cada uno de ellos.

La **confusión promedio** de cada objeto en la bolsa es la confusión total que cada objeto produce dividida por el número de objetos de la bolsa representados por k .

Ahora se muestra como se calculan n confusiones promedio de los objetos en la bolsa.

$\forall O_i$ en BO , las confusiones promedio son:

$$\text{Para } O_1, \frac{\sum_{j=1}^n \text{conf}(O_1, O_j)}{k} \dots\dots\dots(19a)$$

$$\text{Para } O_2, \frac{\sum_{j=1}^n \text{conf}(O_2, O_j)}{k} \dots\dots\dots(19b)$$

...

...

$$\text{Para } O_{n-1}, \frac{\sum_{j=1}^n \text{conf}(O_{n-1}, O_j)}{k} \dots\dots\dots(19y)$$

$$\text{Para } O_n, \frac{\sum_{j=1}^n \text{conf}(O_n, O_j)}{k} \dots\dots\dots(19z)$$

De las fórmulas (19a, 19b,..., 19z), se halla el objeto (O_i) que minimiza la confusión promedio de acuerdo a la ecuación 20.

$$\min \left[\frac{\sum_{i=1}^n \text{conf}(vc_{1,i}, vc_{i,i})}{n(P)}, \frac{\sum_{i=1}^n \text{conf}(vc_{2,i}, vc_{i,i})}{n(P)}, \dots, \frac{\sum_{i=1}^n \text{conf}(vc_{n-1,i}, vc_{i,i})}{n(P)}, \frac{\sum_{i=1}^n \text{conf}(vc_{n,i}, vc_{i,i})}{n(P)} \right] \dots\dots(20)$$

El **centroide** de una bolsa de objetos (también llamado objeto centroide) $BO = \{O_1, O_2, \dots, O_n\}$ es el objeto O_i que minimizó la confusión total en la ecuación 20 y se representa por O^* . Es el valor más plausible si la única información que tenemos son las afirmaciones (expresadas como objetos) de la bolsa.

La **inconsistenciade** una bolsa de objetos es el valor mínimo que resultó de la ecuación 20. Es el valor de confusión promedio que el centroide O^* produce en la bolsa. La inconsistencia de la bolsa se denota por σ , donde $\sigma \in [0,1]$.

Para poder determinar la inconsistencia de la bolsa de objetos, se construyó un software en java (ver capítulo 9).

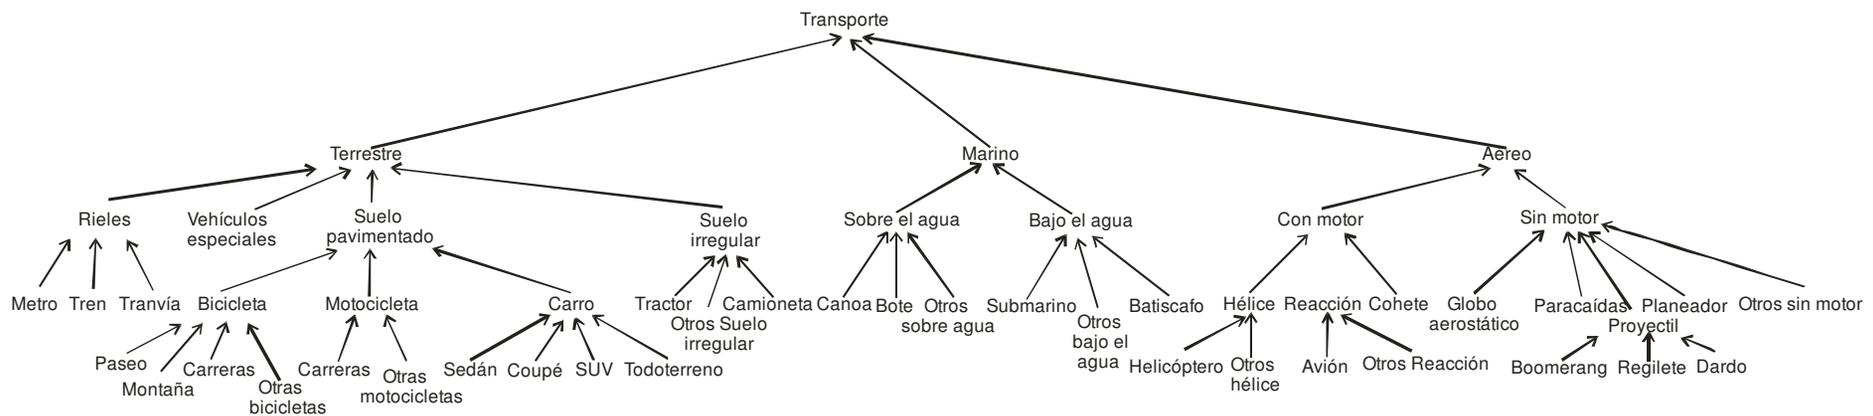
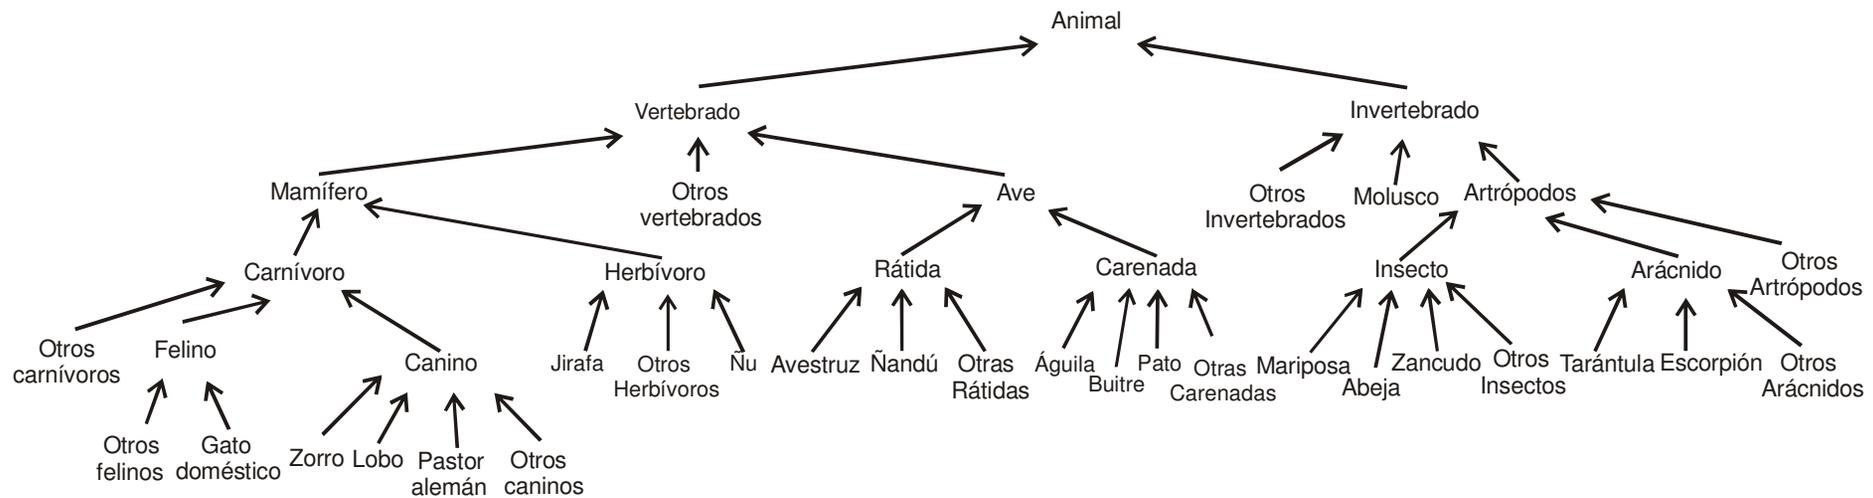
Experimento7

Se presentan determinadas características sobre una persona, para esto existen observadores que lograron ver al susodicho. Se quiere determinar qué objeto modela mejor a la persona que los observadores vieron.

- Juan = {(mascota, animal), (transporte, bote), (religión, cristiano)}
- Pedro = {(mascota, gato_domestico), (transporte, avión), (religión, católico)}
- Luis = {(mascota, ave), (transporte, metro), (religión, católico)}

Se tiene la siguiente bolsa de objetos:
 $BO = \{Juan, Pedro, Luis\}$

Las jerarquías creadas se muestran en la figura 25.



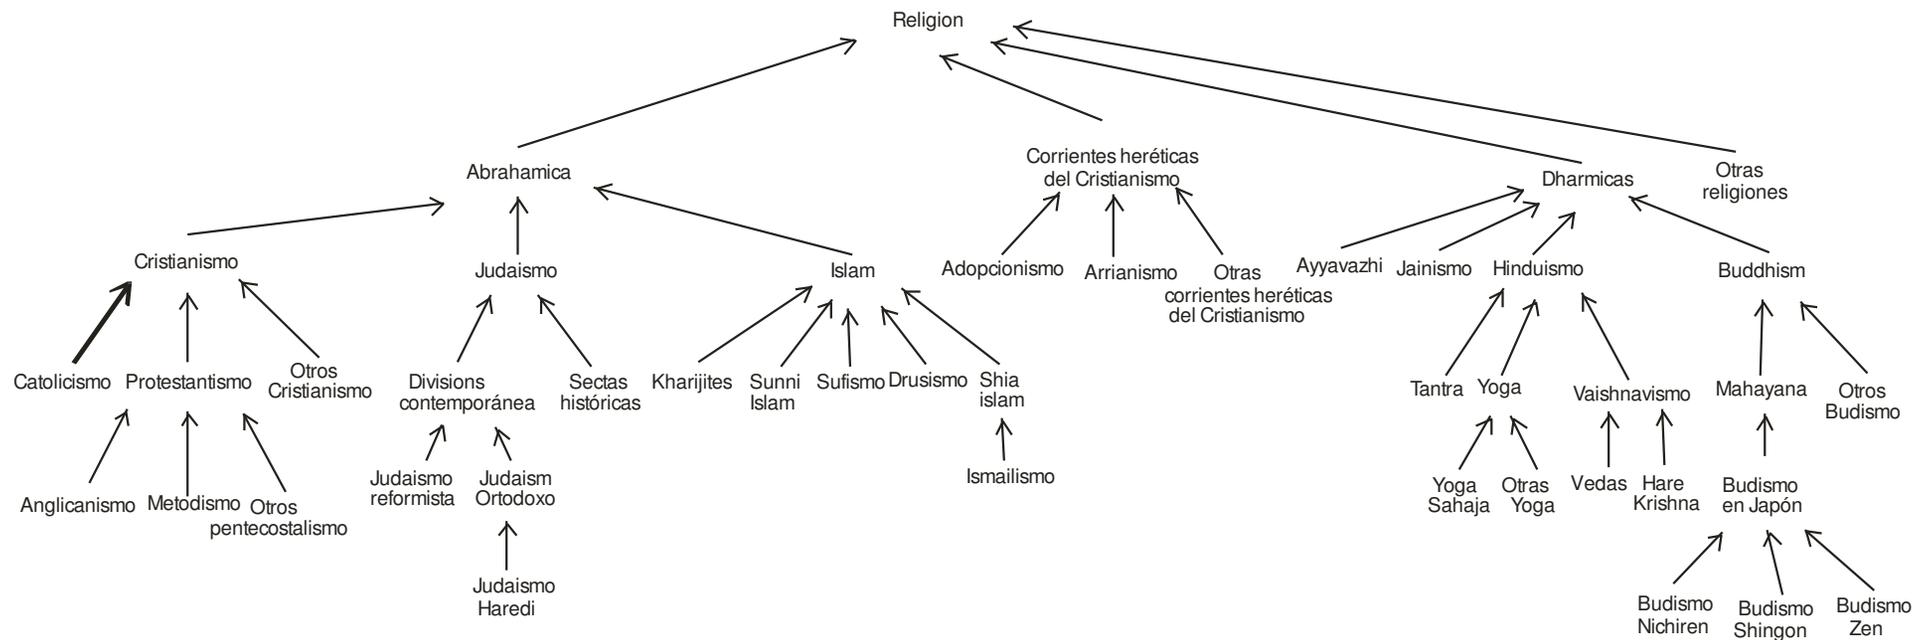


Figura 25.Jerarquías de valores cualitativos que representan animales, transportes y religiones.

Las jerarquías mostradas en la figura 25, deben estar en un archivo XML como es muestra en la figura 26.

```

<?xml version="1.0" encoding="UTF-8"?>
<nodo>Animal
  <nodo>Vertebrado
    <nodo>Mamifero
      <nodo>Carnivoro
        <nodo>Otros_carnivoros
        </nodo>
        <nodo>Felino
          <nodo>Gato_domestico
          </nodo>
          <nodo>Gato_siames
          </nodo>
          <nodo>Gato_montes
          </nodo>
          <nodo>Tigre
          </nodo>
          <nodo>Otros_felinos
          </nodo>
        </nodo>
        <nodo>Canino
          <nodo>Zorro
          </nodo>
          <nodo>Lobo
          </nodo>
          <nodo>Pastor_aleman
          </nodo>
          <nodo>Xoloitzcuintle
          </nodo>
          <nodo>Chihuahua
          </nodo>
          <nodo>Otros_caninos
          </nodo>
        </nodo>
      </nodo>
    <nodo>Hervivoro
  </nodo>
</nodo>
  
```

```

<?xml version="1.0" encoding="UTF-8"?>
<nodo>Vehiculo
  <nodo>Terrestre
    <nodo>Riel
      <nodo>Metro
      </nodo>
      <nodo>Tren
      </nodo>
      <nodo>Tranvia
      </nodo>
    </nodo>
    <nodo>Suelo_pavimentado
      <nodo>Bicicleta
        <nodo>Paseo
        </nodo>
        <nodo>Montana
        </nodo>
        <nodo>BCarreras
        </nodo>
      </nodo>
      <nodo>Motocicleta
        <nodo>MCarreras
        </nodo>
        <nodo>Campo
        </nodo>
      </nodo>
      <nodo>Carro
        <nodo>Sedan
        </nodo>
        <nodo>Coupe
        </nodo>
        <nodo>SUV
        </nodo>
        <nodo>Todoterreno
        </nodo>
      </nodo>
    </nodo>
  </nodo>
  
```

```

<?xml version="1.0" encoding="UTF-8"?>
<nodo>Religion
  <nodo>Abrahamica
    <nodo>Judaismo_mesianico
    </nodo>
    <nodo>Movimiento_rastafari
    </nodo>
    <nodo>Makuya
    </nodo>
  <nodo>Bahaismo
    <nodo>Fe_Baha_i
    </nodo>
    <nodo>Fe_Baha_i_Ortodoxa
    </nodo>
  </nodo>
  <nodo>Islam
    <nodo>Jariyismo
    </nodo>
    <nodo>Sunismo
    </nodo>
    <nodo>Sufismo
    </nodo>
    <nodo>Drusismo
    </nodo>
    <nodo>Chiismo_o_Shiismo
      <nodo>Ismailismo
      </nodo>
    </nodo>
  </nodo>
  <nodo>Judaismo
    <nodo>Divisiones_contemporaneas
      <nodo>Judaismo_Reformista
      </nodo>
      <nodo>Judaismo_Ortodoxo
      <nodo>Judaismo_Jaredi
    </nodo>
  </nodo>
  
```

Figura 26. Representación de las jerarquías Mascota, Transporte y Religión en formato XML.

Enseguida se ejecuta la aplicación “Inconsistencia”, primero se van a capturar los nombres de las propiedades de los objetos, como se muestra en la figura 27.

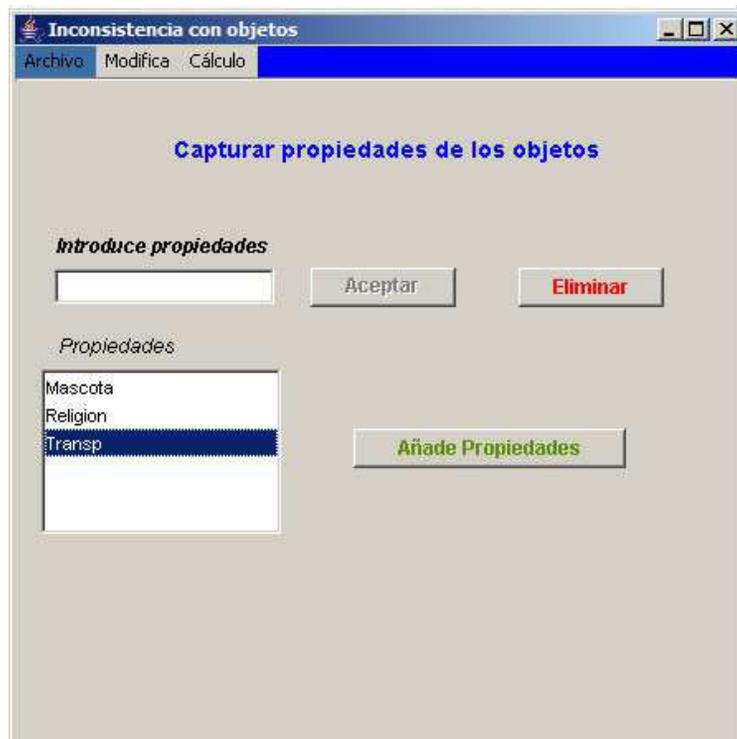


Figura 27. Pantalla para capturar las propiedades de la bolsa de objetos.

En la figura anterior, se introducen las propiedades de cada objeto, enseguida se presiona el botón “Añadir propiedad”.

Después se procede a crear los objetos con los valores de cada una de sus propiedades. Ver figura 28.

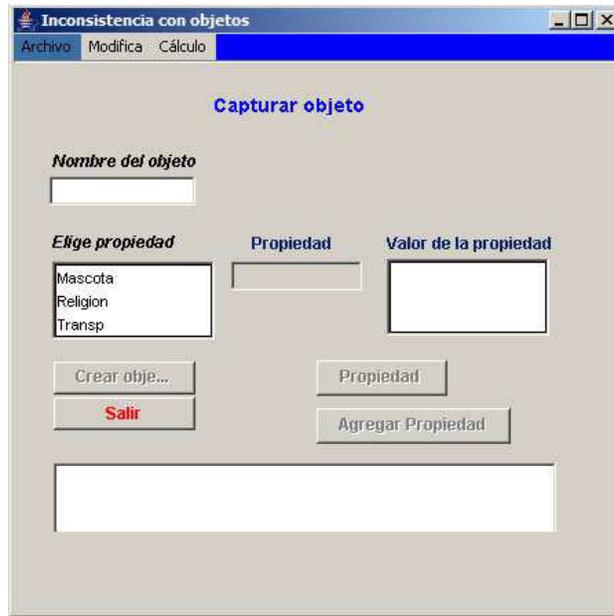


Figura 28. Pantalla para agregar valor de las propiedades de cada objeto.

Después se realiza el cálculo de inconsistencia de la bolsa de objetos. En la aplicación se elige el menú “Cálculo”, donde aparecerá una pantalla como la figura 29.

Primero hace la medición de confusión de los objetos dando clic en el botón “Medición.

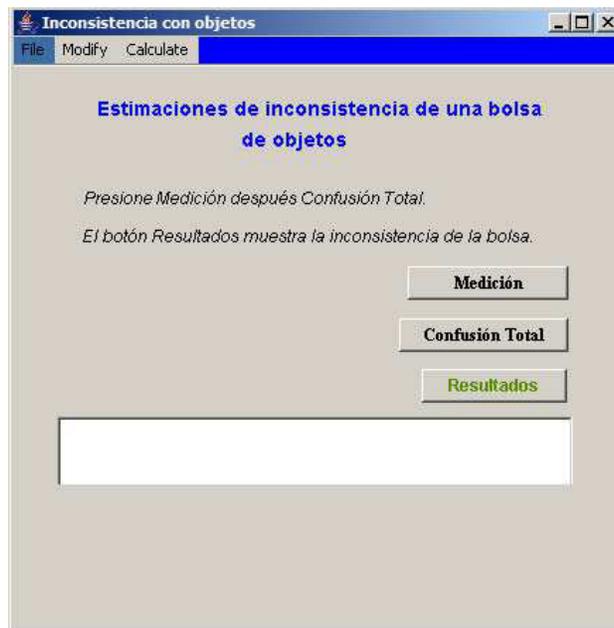


Figura 29. Pantalla que ayuda a realizar el cálculo de inconsistencia.

Segundo, se oprime el botón “Confusión Total” para obtener los valores de Confusión Promedio de los objetos. Ver figura 30.

VALORES DE INCONFORMIDAD						
ObjetoR	ObjetoS	Características				Inconformidad
		Jerarquía	Propiedad Or	Propiedad Os	Conf	
Pedro	Luis	Transp	Avion	Metro	0.75	0.317
		ReligionEsp	Catolicismo	Catolicismo	0.0	
		Mascota	Gato_domest...	Ave	0.2	
Pedro	Juan	Transp	Avion	Bote	1.0	0.333
		ReligionEsp	Catolicismo	Cristianismo	0.0	
		Mascota	Gato_domest...	Animal	0.0	
Luis	Juan	Transp	Metro	Bote	1.0	0.333
		ReligionEsp	Catolicismo	Cristianismo	0.0	
		Mascota	Ave	Animal	0.0	
Juan	Luis	Transp	Bote	Metro	0.75	0.45
		ReligionEsp	Cristianismo	Catolicismo	0.2	
		Mascota	Animal	Ave	0.4	
Luis	Pedro	Transp	Metro	Avion	1.0	0.6
		ReligionEsp	Catolicismo	Catolicismo	0.0	
		Mascota	Ave	Gato_domest...	0.8	
Juan	Pedro	Transp	Bote	Avion	1.0	0.733
		ReligionEsp	Cristianismo	Catolicismo	0.2	
		Mascota	Animal	Gato_domest...	1.0	

Figura 30. Pantalla de inconformidades de cada objeto.

Y por último se despliega la solución con el botón “Resultados”. Ver figura 31.

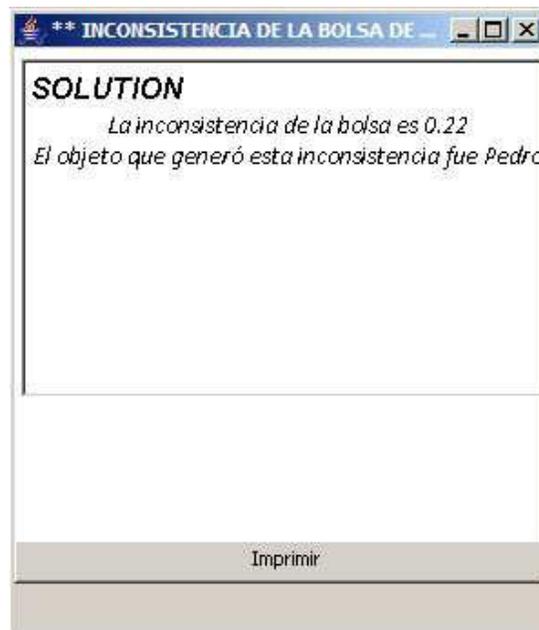


Figura 31. Pantalla que imprime el valor de inconsistencia de la bolsa de objetos.

Como se puede ver en la figura 33, el valor de inconsistencia de la bolsa es 0.22 generada por Pedro. Por lo tanto, Pedro será el centroide de la bolsa, lo que quiere decir que Pedro es el individuo que más se adecúa a la solución del problema.

Experimento 8

Se hizo una encuesta sobre las votaciones del 5 de julio de 2009. Lo que se quiere medir es el parecido entre los votantes de acuerdo la respuesta que hayan puesto en las preguntas siguientes:

Último nivel de estudios y por quién votó.

Para este estudio se registraron los datos de 13 personas.

Persona_Uno = {(Escolaridad, Maestría), (Partidos Políticos, PAN)}
 Persona_Dos = {(Escolaridad, Universidad), (Partidos Políticos, PAN)}
 Persona_Tres = {(Escolaridad, Maestría), (Partidos Políticos,)}
 Persona_Cuatro = {(Escolaridad, Carrera Técnica), (Partidos Políticos, Convergencia)}
 Persona_Cinco = {(Escolaridad, Primaria), (Partidos Políticos, PRD)}
 Persona_Seis = {(Escolaridad, Doctorado), (Partidos Políticos, PRD)}
 Persona_Siete = {(Escolaridad, Doctorado), (Partidos Políticos, PT)}
 Persona_Ocho = {(Escolaridad, Doctorado), (Partidos Políticos, PRD)}
 Persona_Nueve = {(Escolaridad, Especialidad), (Partidos Políticos, PT)}
 Persona_Diez = {(Escolaridad, Especialidad), (Partidos Políticos, Convergencia)}
 Persona_Once = {(Escolaridad, Universidad), (Partidos Políticos, PRD)}
 Persona_Doce = {(Escolaridad, Secundaria), (PartidoPolítico, PRI)}
 Persona_Trece = {(Escolaridad,), (PartidoPolítico, PAN)}

La bolsa de objetos está compuesta de los objetos $BO = \{Persona_Uno, Persona_Dos, Persona_Tres, Persona_Cuatro, Persona_Cinco, Persona_Seis, Persona_Siete, Persona_Ocho, Persona_Nueve, Persona_Diez, Persona_Once, Persona_Doce, Persona_Trece\}$.

En la figura 32 se muestran las jerarquías que se necesitan para calcular la inconsistencia de la bolsa de objetos.





Figura 32. Jerarquías que Escolaridad y Partidos Políticos.

La figura 33 presenta las jerarquías anteriores en XML.

```

Escolaridad.xml | PartidoPolitico.xml
-->
<nodo>escolaridad
  <nodo>Nivel basico
    <nodo>Primaria
    </nodo>
    <nodo>Secundaria
    </nodo>
  </nodo>
  <nodo>Nivel medio superior
    <nodo>Preparatoria
    </nodo>
    <nodo>Vocacional
    </nodo>
    <nodo>Bachillerato
    </nodo>
  </nodo>
  <nodo>Nivel Superior
    <nodo>Universidad
    </nodo>
  </nodo>
  <nodo>Posgrado
    <nodo>Especialidad
    </nodo>
    <nodo>Maestria
    </nodo>
    <nodo>Doctorado
    </nodo>
  </nodo>
  <nodo>Carrera Tecnica
  </nodo>
</nodo>

<nodo>Partido politico
  <nodo>Partidos de derecha
    <nodo>PRI
    </nodo>
    <nodo>PAN
    </nodo>
    <nodo>PVE
    </nodo>
    <nodo>PSD
    </nodo>
  </nodo>
  <nodo>Partidos de izquierda
    <nodo>PRD
    </nodo>
    <nodo>Convergencia
    </nodo>
    <nodo>PT
    </nodo>
  </nodo>
</nodo>
  
```

Figura 33. Representación en XML de las jerarquías Escolaridad y Partidos Políticos.

La figura 34 muestra la pantalla de la aplicación donde se eligen las propiedades de los objetos. En este ejemplo, los objetos tienen dos propiedades.

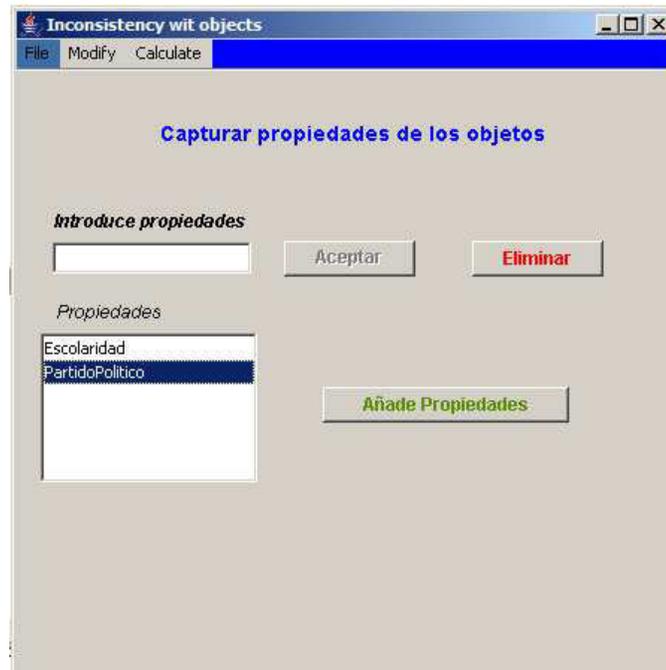


Figura 34. Pantalla para capturar las propiedades de los objetos de la bolsa.

La figura 35 presenta la pantalla del software donde se harán los cálculos correspondientes y visualización de la inconsistencia de la BO. Aquí primero se deben estimar las confusiones de cada objeto presionando en el botón “Medición”, enseguida con el botón “Confusión Total”, muestra los objetos que se están comparando con sus propiedades y confusiones totales, después con el botón “Resultados” se calcula la inconsistencia de la bolsa de objetos emitiendo los centroides que se encontraron.

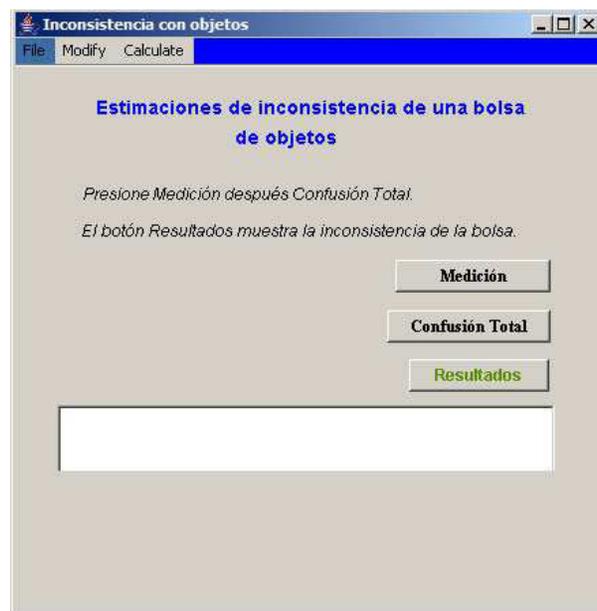


Figura 35. Pantalla para calcular la inconsistencia de la BO.

Parte de los resultados de Confusión Total se presentan en la figura 36.

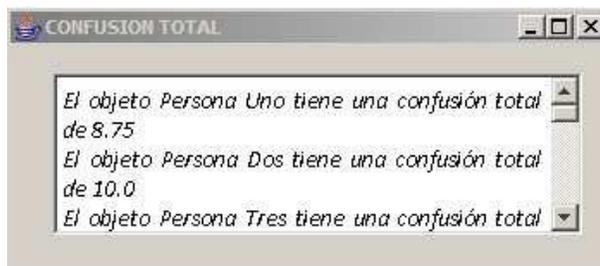


Figura 36. Pantalla que muestra la confusión total de cada objeto.

Debido a que no se pueden ver todos los resultados en la pantalla se presentan a continuación los datos completos que se extrajeron de la figura anterior.

El objeto Persona Uno tiene una confusión total de 8.75
El objeto Persona Dos tiene una confusión total de 10.0
El objeto Persona Tres tiene una confusión total de 7.5
El objeto Persona Cuatro tiene una confusión total de 9.75
El objeto Persona Cinco tiene una confusión total de 8.5
El objeto Persona Seis tiene una confusión total de 7.0
El objeto Persona Siete tiene una confusión total de 7.25
El objeto Persona Ocho tiene una confusión total de 7.0
El objeto Persona Nueve tiene una confusión total de 7.5
El objeto Persona Diez tiene una confusión total de 7.75
El objeto Persona Once tiene una confusión total de 8.5
El objeto Persona Doce tiene una confusión total de 10.25
El objeto Persona Trece tiene una confusión total de 9.75

De acuerdo a los resultados anteriores los objetos con la misma confusión total son:

Persona Seis y Persona Ocho con una confusión total (ct) de 7.0. Estas personas votaron por el PRD.

Persona Tres y Nueve con $ct = 7.5$. Voto por el PT

Persona Cinco y Persona Once $ct=8.5$. Voto por el PRD

Persona Cuatro y Persona Trece $ct=9.75$. Difieren en escolaridad y votaron por partido diferente.

Persona Siete con $ct = 7.25$ votó por el PT y es una confusión cercana a la menor.

Persona Diez con $ct = 7.75$ votó por Convergencia.

Persona 12 con $ct = 10.25$ votó por el PRI y es el que tiene la máxima confusión total.

Persona Uno y Dos votaron por el PAN y su ct es más grande que los que obtuvieron la menor confusión total.

En los resultados anteriores, se puede notar que los que votaron por el PT tienen estudios de doctorado y especialidad.

Los que votaron por el PRD tienen estudios de primaria, universidad, maestría y doctorado.

Y la confusión total mayor fue quien votó por el PRI con escolaridad secundaria.

Quien votó por el PAN tiene escolaridad de maestría o menor. Quienes votaron por Convergencia uno fue de carrera técnica y otro de especialidad. En este experimento se pudo ver que la tendencia fue hacia el PRD y el PT y la mayoría de estos votantes tiene una escolaridad de especialidad o superior.

La figura 37 contiene una tabla donde se muestra parte de la información de cómo se llevan a cabo las confusiones de cada objeto con respecto a sus propiedades y la confusión promedio de un O_a con respecto a un O_b .

VALORES DE INCONFORMIDAD						
ObjetoR	ObjetoS	Características				Conf. Prom.
		Jerarquía	Propiedad Or	Propiedad Os	Conf	
Persona Seis	Persona 8	Escolaridad	Doctorado	Doctorado	0.0	0
		PartidoPolitico	PRD	PRD	0.0	
Persona 8	Persona Seis	Escolaridad	Doctorado	Doctorado	0.0	0
		PartidoPolitico	PRD	PRD	0.0	
Persona Tres	Persona Siete	Escolaridad	Maestria	Doctorado	0.5	0.25
		PartidoPolitico	PT	PT	0.0	
Persona Tres	Persona Nueve	Escolaridad	Maestria	Especialidad	0.5	0.25
		PartidoPolitico	PT	PT	0.0	
Persona Seis	Persona Siete	Escolaridad	Doctorado	Doctorado	0.0	0.25
		PartidoPolitico	PRD	PT	0.5	
Persona Siete	Persona Tres	Escolaridad	Doctorado	Maestria	0.5	0.25
		PartidoPolitico	PT	PT	0.0	

Figura 37. Comparación de O_xO sobre una BO donde se aprecia claramente, los objetos a medir, las jerarquías utilizadas, las propiedades de cada objeto y la confusión promedio.

La figura 38 muestra el valor de inconsistencia de la bolsa y los centroides (O^*) que en este caso fueron Persona Seis y Persona 8, debido a que ambas tienen la misma escolaridad (doctorado) y votaron por el mismo partido (PRD).

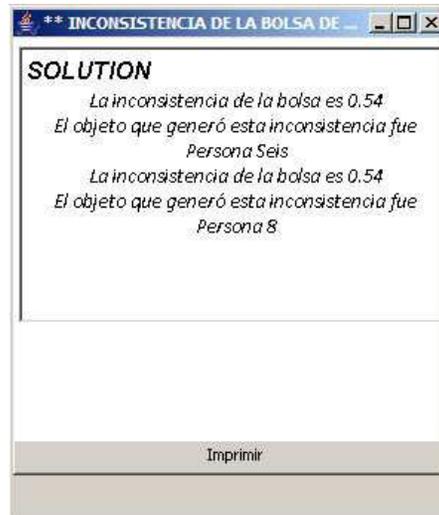


Figura 38. Esta imagen presenta la inconsistencia de la bolsa y los centroides que aparecieron en ella.

En este capítulo se resolvió el objetivo 5 del presente trabajo. En los objetivos anteriores las afirmaciones son aisladas y todas pertenecen a una misma jerarquía. Aquí se analizaron afirmaciones que vienen en paquete (caracterizaciones de un objeto), a fin de hallar el centroide y la inconsistencia del conjunto de afirmaciones.

Capítulo 9. Arquitectura de la implementación del software para medir Inconsistencia.

Se desarrollaron dos aplicaciones para realizar el cálculo de inconsistencia. Una analiza una bolsa de valores cualitativos para calcular la inconsistencia de la bolsa. La otra aplicación hace el cálculo de inconsistencia de una bolsa de objetos. Ambas aplicaciones se construyeron bajo la plataforma Java.

Se utilizó XML (eXtensibleMarkupLanguage) para introducir los valores cualitativos. Para extraer los datos del documento XML se usó JDOM un API de Java con finalidad de hacer el análisis sintáctico del documento XML con ayuda de un parser que incluye JDOM llamado XERCES y poder tener la representación del documento XML en Java para después proceder a realizar el análisis de inconsistencia.

A continuación se explican brevemente las herramientas que se requirieron para construir el software:

- XML es un Lenguaje de Etiquetado Extensible similar a HTML, pero su función principal es describir datos y no mostrarlos como lo hace HTML. XML es un formato que permite la lectura de datos a través de diferentes aplicaciones. XML sirve para estructurar, almacenar e intercambiar información.
- JDOM es una representación de Java de un documento XML. JDOM ofrece forma de representar a ese documento para su lectura fácil y eficiente, la manipulación, y la escritura. Dispone de un sencillo API, es ligero y rápido, y está optimizado para el programador de Java. Es una alternativa a SAX y DOM, aunque se integra bien con SAX y DOM.

JDOM es "documento de modelo de objetos" basado en Java para archivos XML. JDOM al igual que DOM se basa en el parseado de un documento XML y la construcción de un árbol de Elementos, Atributos, Comentarios, instrucciones de procesamiento, etc., pero JDOM es más fácil de usar.

Una vez construido el árbol se puede acceder directamente a cualquiera de sus componentes.

Por ella misma, la API no incluye un parseador pero se puede utilizar alguno ya existente (por ejemplo Xerces) para construir el árbol de elementos JDOM. Por lo que JDOM no es un analizador de XML (XMLparser), como Xerces o Crimson. Es un documento de modelo de objetos que utiliza analizadores de XML para construir documentos. La clase SAXBuilder de JDOM, por ejemplo, utiliza los eventos de SAX generados por un analizador (parser) XML para construir un árbol JDOM. El analizador XML por defecto utilizado por JDOM es el analizador seleccionado por JAXP, pero JDOM puede usar casi cualquier analizador.

- JAXP (Java API for XML Processing) es una iniciativa de Sun Microsystems para uniformizar el desarrollo de aplicaciones Java con XML, es muy importante señalar que JAXP no es un "parser", sino que JAXP funciona en conjunción con un "parser".

JAXP es para procesar datos en XML usando aplicaciones escritas en el lenguaje de programación Java.

Lo que se intenta lograr mediante JAXP es interoperabilidad entre los diferentes "parsers" que existen en el mercado, esto es, debido a que existen diversas implementaciones de "parsers" se suelen definir ciertas funciones propietarias por "parser", la utilización de JAXP permite aislar la aplicación del programa de estas funciones propietarias.

Configuración de la Aplicación

El software y librerías que se requieren para correr el programa creado para el cálculo de inconsistencia son:

1. JDK 5 o posteriores.
2. La biblioteca de JDOM ver. 1.1
3. Paquete `ca.ubc.cs.kisynski.bell`
4. Conjunto de librerías `mathCollection` y `mathCollectionDoc`
5. Archivos en XML.

Para instalar en Windows XP Profesional, XP Home o XP Home Vista se hace lo siguiente:

El paquete JDOM debe estar dentro del directorio del JDK de java. Por ejemplo, si se tiene la versión JDK 5, entonces el directorio quedará en la dirección `C:/ProgramFiles/Java/jdk1.5.0_18/jdom-1.1`.

Los paquetes `ca.ubc.cs.kisynski.bell`, `mathCollection` y `mathCollectionDoc`, también deben dentro de la ruta `C:/ProgramFiles/Java/jdk1.5.0_18/`; por ejemplo, para el primer paquete será de la siguiente manera `C:/ProgramFiles/Java/jdk1.5.0_18/ca.ubc.cs.kisynski.bell` y así para los demás.

Los archivos en XML son extraídos por la aplicación desde una clase que los busca en el directorio `C:/XML/`. Por ejemplo, `C:/XML/Jerarquia.xml`.

En la figura 39, se muestra la manera en que se lleva a cabo el cálculo de inconsistencia con las aplicaciones.

Primero se requiere que las jerarquías a utilizar estén en un documento XML. JDOM generará un documento con el cual trabajarán las aplicaciones. La aplicación 1 realizará el cálculo de inconsistencia sobre una bolsa de valores cualitativos y como resultado entregará la inconsistencia de la bolsa y el valor cualitativo que la genera. La aplicación 2 hará el cálculo parecido a la anterior pero con objetos.

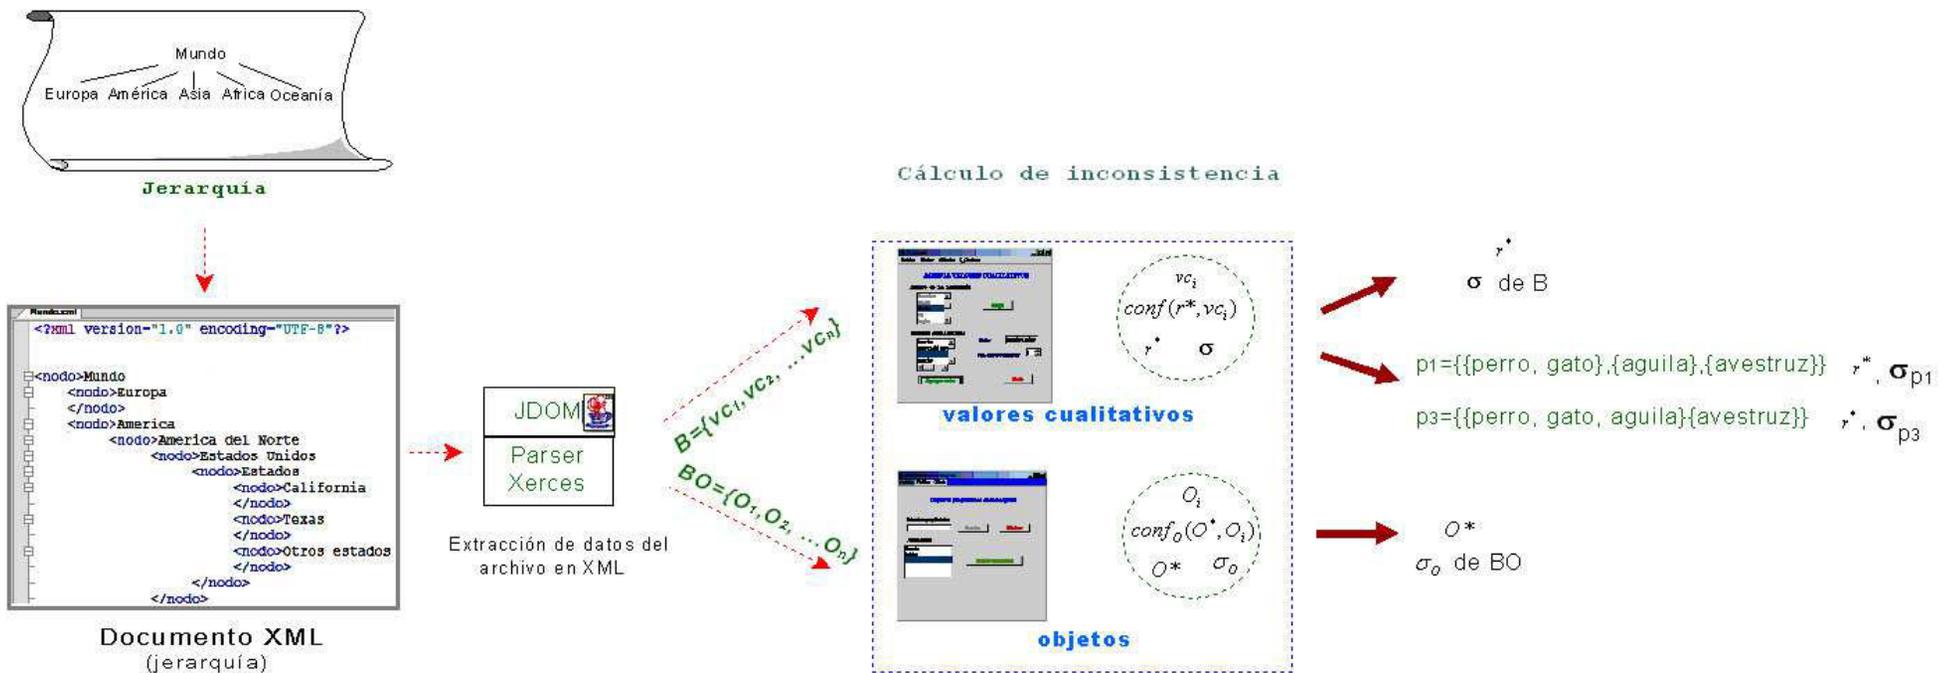


Figura 39. Esquema de la implementación del análisis para medir inconsistencia.

Capítulo 10. Conclusiones

En la actualidad se están creando varias metodologías para tratar de encontrar inconsistencia en información, ya sea utilizando diferentes tipos de lógica y probabilidad.

En esta tesis, se logró resolver la inconsistencia de información que se tiene sobre un evento en particular. Esta información se jerarquizó para poder calcular la discrepancia entre los datos que presentaron determinados observadores. El cálculo de inconsistencia se realizó a través de analizar la información concerniente a un evento en particular. Se encontró la solución cuando se tiene una bolsa de valores cualitativos que describen al suceso en cuestión. Esto puede ser útil cuando se tiene mucha información que describe el suceso en cuestión y no se sabe con certeza lo que ocurrió. Se vio un caso en el cual se tienen varios reportajes que tratan del lugar donde se originó el virus de la influenza porcina. Para una persona es difícil decidir el lugar en donde pudo ocurrir este evento por primera vez y peor aún si se tienen muchos reportes sobre lo mismo. Por tanto, se logró dar solución a este evento con la primera técnica de inconsistencia que se desarrolló en esta tesis.

También se creó una forma para particionar estos valores cualitativos con la finalidad de poder determinar si es conveniente tener una o más soluciones al problema.

Se logró analizar un evento cuando se detectan cambios en la información ya sea que aparecen nuevos datos o se eliminan datos que generen mucha inconsistencia sobre el evento.

Otra técnica importante que se resolvió satisfactoriamente fue cuando se quieren medir objetos de acuerdo a sus características, con la metodología de inconsistencia se pueden encontrar el o los objetos que describen mejor el evento. Esta parte del trabajo se puede utilizar para toma de decisiones, por ejemplo si se quiere contratar personal y son demasiadas las personas que concursan para ello, se medirán sus características como pueden ser su profesión, si hablan varios idiomas o qué oficio hacen, etc.

Cabe destacar que se realizaron satisfactoriamente los objetivos de este trabajo y lo más importante se encontraron varias técnicas para poder medir información que describe algún evento en particular.

Bibliografía

- [1] A. C. W. Finkelstein, D. Gabbay, A. Hunter, J. Kramer and B. Nuseibeh, "Inconsistency Handling in Multiperspective Specifications", Department of Computing, Imperial College of Science, Technology and Medicine. 180 Queen's Gate, London, IEEE Transactions on Software Engineering, vol.20 n.8, pp.569-578, August 1994.
- [2] A. Guzmán-Arenas and A. Jiménez, "Measuring Inconsistency over a Hierarchy of Qualitative Facts", Research in Computer Science, Special issue on Data Mining and Information Systems, ICDIS 06 (CIC),15-30. CIC-IPN Mexico. ISSN 1870-4069, 2006.
- [3] A. Guzmán-Arenas and A. Jiménez, "Obtaining the consensus and inconsistency among a set of assertions on a qualitative attribute", Expert Systems with Applications, May 2009.
- [4] Adolfo Guzman-Arenas, Alma-Delia Cuevas, Adriana Jimenez. (2011) The centroid or consensus of a set of objects with qualitative attributes. Expert Systems with Applications 38 (2011) 4908-4919.
- [5] Adolfo Guzmán-Arenas, Alma-Delia Cuevas, (2011) Quantitative Measures of confusion and inconsistency for symbolic values, submitted to Information Sciences Journal, special issue on Statistics with Imperfect Data.
- [6] Guzman, A., and S. (2004) Graduated errors in approximate queries using hierarchies and ordered sets. Lecture Notes in Artificial Intelligence LNAI **2972**, Springer-Verlag. 139-148. ISSN 0302-9743.
- [7] Adolfo Guzman-Arenas, Sergei Levachkine and Victor-Polo de-Gyves, Measuring the confusion between two qualitative values organized in hierarchies. Submitted to Knowledge and Information Systems.
- [8] A. Hunter, "How to act on inconsistent news: Ignore, resolve, or reject". Department of Computer Science. University College London.
- [9] A. Hunter, "Measuring Inconsistency in Knowledge via Quasi-classical Model", Eighteenth National Conference on Artificial Intelligence, Edmonton, Alberta, Canada, pp. 68-73. 2002.
- [10] A. Hunter and B. Nuseibeh, "Managing Inconsistent Specifications. Reasoning, Analysis and Action", Department of Computer Science, University College London, May 22, 1998.
- [11] A. Tversky, "Features of similarity", Psychological Review, vol. 84, no. 4, July 1997.
- [12] B. McLaughlin. "Java & XML", 2nd ed. O'Reilly, August, 2001.

- [13] B. Nuseibeh, "Computer-Aided Inconsistency Management in Software Development Department of Computing", Department of Computing, Imperial College, London SW7 2BZ, Technical report DoC 95/4.
- [14] B.Nuseibeh, J.Kramer and A.Finkelstein,"A framework for expressing the relationships between multiple views in requirements specification", IEEE Transactions on Software Engineering, pp. 760-773, 1994.
- [15] B. Nuseibeh, J. Kramer and A. Finkelstein,"Expressing the Relationships Between Multiple Views in Requirements Specification",International Conference on Software Engineering,Proceedings of 15th International Conference on Software Engineering,Baltimore, Maryland, United States, pp. 187-196, 1993
- [16] C.Gershenson,"Lógica Multidimensional. Un modelo de lógica paraconsistente", XI Congreso Nacional ANIEI, pp 132-141, Xalapa, México.
- [17] D. Lin, "An Information-Theoretic Definition of Similarity", Proceedings of the 15th International Conference on Machine Learning, pags. 296 – 304, 1998.
- [18] Didier, Dubois; Henri, Prade: Fuzzy Sets and Systems: Theoy and Applications. Mathematics in Science and Engineering. Volume 144.Academic Press Inc. 1980.
- [19] D. M. Gabbay and A. Hunter, "Making inconsistency respectable: a logical framework for inconsistency in reasoning: Part 1", Proceedings of the International Workshop on Fundamentals of Artificial Intelligence Research, pp.19-32, September 08-13, 1991.
- [20] D. M. Gabbay and Anthony Hunter, "Making Inconsistency Respectable: Part 2 - Meta-level handling of inconsistency", Proceedings of the European Conference on Symbolic and Quantitative Approaches to Reasoning and Uncertainty, pp.129-136, November 08-10, 1993.
- [21] D. Megginson: Structuring XML Documents. Prentice Hall PTR. 1998.
- [22] E. Byrne and A. Hunter,"Evaluating violations of expectations to find exceptional information", Data and Knowledge Engineering, vol. 54,pp. 97-120, Elsevier Science Publishers B. V. Amsterdam, The Netherlands, 2005.
- [23] E. Byrne and A. Hunter,"Man Bites Dog: Looking for Interesting Inconsistencies in Structured News Reports", Department of Computer Science, University College London, May 29, 2003.
- [24] F. Matías-Pailos, "Kripke y las oraciones intrínsecamente paradójicas", XIV Congreso Nacional de Filosofía de AFRA,San Miguel de Tucumán, Arg., Sept. 2007. Disponible en: <http://www.accionfilosofica.com/misc/1190465372jrnDoc.doc>

- [25] F. Sánchez-de-Armas, “Ejemplo de red semántica”, Sept. 2007. Disponible en: http://es.wikipedia.org/wiki/Archivo:Red_Semantica.png
- [26] G. Shafer, “A mathematical theory of evidence”, Princeton University Press, New Jersey, 1972.
- [27] G. Shafer, “Perspectives on the theory and practice of belief functions”, International Journal of Approximate Reasoning, vol.4 ,pp 323-362, 1990.
- [28] J. Carlson and R. R-Murphy, “Use of Dempster-Shafer Conflict Metric to Detect Interpretation Inconsistency”, Proceedings of the 21th Annual Conference on Uncertainty in Artificial Intelligence (UAI-05), pp. 94-104, AUAI Press, Arlington, Virginia, 2005.
- [29] J. F-Sowa, "Semantic Networks", Encyclopedia of Artificial Intelligence, Ed. Stuart C Shapiro, Retrieved on 2008-04-29, 1987.
- [30] J. Grant and A. Hunter, “Measuring inconsistency in knowledgebases. Journal of Intelligent Information Systems”, Volume 27 , Issue 2, pp. 159 – 184, Hingham, MA, USA. 2006.
- [31] J. Lin, “Consistent Belief Reasoning in the Presence of Inconsistency”, Proceedings of the 5th conference on Theoretical aspects of reasoning about knowledge”, Pacific Grove, California, pp. 80-94, Morgan Kaufmann Publishers Inc. San Francisco, CA, USA, 1994.
- [32] K. J Arrow. “Social Choice and Individual Values”, New York, Wiley, 1963.
- [33] L. A-Zadeh, “Fuzzy logic for the management of uncertainty”, Edited by Lotfi A. Zadeh, Janusz Kacprzyk, New York, Wiley, 1992.
- [34] L. García-Cabrera, “Introducción a la teoría de conjuntos difusos y su aplicación a sistemas de control”, Departamento de Ingeniería Eléctrica y Computadoras, Universidad de Puerto Rico, Recinto Universitario de Mayagüez, 1997.
- [35] N. De Marco, “Kripke y el abandono de la bivalencia: Límites de la negación no-clásica”, 2007.
- [36] R. Miarka, J. Derrick and E. Boiten, “Handling Inconsistencies in Z using Quasi-Classical Logic”, Lecture Notes In Computer Science, vol. 2272, Proceedings of the 2nd International Conference of B and Z Users on Formal Specification and Development in Z and B, pp. 204-225, 2002.
- [37] R. Balzer, “Tolerating Inconsistency”, IEEE Computer Society Press, International Conference on Software Engineering (ICSE-13), Proceedings of the 13th international

conference on Software engineering, Austin, Texas, United States, pp. 158-165, 13-17th May, 1991.

[38] S. Levachkine, A. Guzman-Arenas (2007) Hierarchy as a new data type for qualitative variables. *Journal Expert Systems with Applications* **32**, 3, 899-910.

[39] S. Levachkine and A. Guzmán-Arenas, “Hierarchies Measuring Qualitative Variables”, *Lecture Notes in Computer Science LNCS 2945 (Computational Linguistics and Intelligent Text Processing)*, Springer-Verlag).

[40] Sergei Levachkine, Adolfo Guzman-Arenas, Victor Polo de Gyves (2005) The semantics of confusion in hierarchies: from theory to practice. In *Contributions to ICCS 0513th International Conference on Conceptual Structures: common semantics for haring knowledge*, July 18-22 2005, Kassel, Germany. 94-107.
<http://www.divshare.com/download/6257877-9a7>

[41] S. Easterbrook, A. Finkelstein, J. Kramer and B. Nuseibeh, “Coordinating Distributed ViewPoints”, *Concurrent Engineering: Research and Applications*, vol. 2, pp. 209-222, USA, 1994.

[42] S. Easterbrook and B. Nuseibeh, “Managing inconsistencies in an evolving specification”, *Proceedings of the Second IEEE International Symposium on Requirements Engineering*, pp.48, March 27-29, 1995.

[43] Morgenthal, J. P.; La Forge, Bill: *Enterprise Application Integration with XML and Java*. Prentice Hall PTR. 2001.

[44] K. Narayanaswamy and N. Goldman, “Lazy consistency: A basis for cooperative software development”, *Proceedings of International Conference on Computer-Supported Cooperative Work*, Pags. 257-264, Canada, Nov, 1992.

[45] National Council of Teachers of Mathematics, “Medida”, ed. 14, edit. Trillas, feb 1987.

[46] P. Routio, “Registrar hechos”, ago. 2007. Disponible en:
<http://www2.uiah.fi/projects/metodi/254.htm>

[47] Osmosis Latina, “Intercambio de información”, 2005. Disponible en:
<http://www.osmosislatina.com/xml/basico.htm>

[48] P. F-V, “Nominal, Ordinal, Interval, and Ratio Typologies are Misleading”, Cornell University and Data Description, Inc. Leland Wilkinson, SYSTAT, Inc. and Northwestern University.

[49] Victor Polo de Gyves, Adolfo Guzman, Serguei Levachkine (2005) Extending databases to precision-controlled retrieval of qualitative information. *Lecture Notes in*

Computer Science **3563** (Springer Verlag 2005) 21-32. Also in:
<http://www.divshare.com/download/6270168-62f>

[50] W3C, “Guíabreve de tecnologías XML”, 2008. Disponible en:
<http://www.w3c.es/divulgacion/guiasbreves/tecnologiasXML>

[51] Wikipedia, “Red Semántica”, jul 2009. Disponible en:
http://es.wikipedia.org/wiki/Red_sem%C3%A1ntica

[52] Xiaoxin, Yin; Jiawei, Han; P. S. Yu. Truth Discovery with Multiple Conflicting Information Providers on the Web, International Conference on Knowledge Discovery and Data Mining, San Jose, California, USA, vol, 20, no. 6, pp. 1048-1052, June 2008.

En todo momento hacemos algo que ignoramos. Esta capacidad irá en aumento hasta que llegue el día en que el hombre haga todo sin saberlo; su misma razón será la de un animal pensante. La razón tiende a lo animal.

Aforismos
Georg Christoph Lichtenberg.