

Índice de Contenidos

1.	Introducción.....	10
1.1	Descripción y justificación del proyecto	10
1.2	Objetivos.....	12
1.2.1	Objetivo General.....	12
1.2.2	Objetivos Específicos	12
1.3	Contribuciones.....	12
1.4	Metodología.....	12
1.4.1	Definir los requerimientos de información.....	12
1.4.2	Establecer indicadores	13
1.4.3	Proceso ETL	13
1.4.4	Análisis y diseño del modelo de datos.....	13
1.4.5	Web Mining	13
1.4.6	Implementación y visualización de indicadores	13
1.4.7	Metodología de web mining Crips-DM.....	14
1.5	Alcances.....	16
1.6	Descripción del trabajo.....	17
2.	Marco Conceptual.....	18
2.1	Introducción a la Web.....	18
2.1.1	La Web	18
2.1.2	Funcionamiento de la Web	19
2.2	Sistemas de almacenamiento, procesamiento y análisis de datos	20
2.2.1	Base de datos	21
2.2.2	Sistemas de información.....	21
2.2.3	Modelo Relacional.....	23
2.2.4	Data Warehouse.....	24
2.2.5	Modelo Multidimensional	28
2.2.6	Arquitectura para Data Warehouse.....	31
2.3	Repositorio de información para la web	36
2.4	Web Mining.....	38
2.4.1	Tipos de datos originados en la Web.....	38
2.4.2	Web Logs.....	39
2.4.3	Procesamientos de los contenidos de documentos	42
2.4.4	Proceso KDD	44
2.5	Ánálisis multidimensional	45
2.5.1	Operación Drill-Down	52
2.5.2	Operación Drill-up.....	52
2.5.3	Operación Drill-across	53
2.5.4	Roll-across	53
2.5.5	Pivot.....	54
2.6	Ánálisis de comportamiento de los usuarios	54
3.	Metodología y diseño del webhouse	58
3.1	Línea base	58
3.2	Requerimientos.....	63
3.2.1	Requerimientos de información.....	63

3.2.2	Conociendo el portal.....	63
3.3	Indicadores.....	65
3.4	Fuentes de datos.....	66
3.5	Modelo del Data Staging Area (DSA).....	66
3.6	El repositorio de información	68
3.7	Arquitectura tecnológica.....	73
3.7.1	Capa de datos.....	74
3.7.2	Capa media	75
3.7.3	Capa de presentación	77
4.	Construcción del data mart	79
4.1	Descripción del sitio	79
4.2	Proceso ETL	81
4.2.1	Extracción y transformación de datos	81
4.3	Carga a la DSA	86
4.4	Creación de cubos de información	93
4.5	Análisis de comportamiento de los usuarios	100
4.5.1	Sesiones consideradas.....	100
4.5.2	Contenido de las páginas	100
4.5.3	Transformación y agrupamiento de contenidos.....	103
4.6	Interfaz de usuario	107
5.	Resultados.....	110
5.1	Indicadores obtenidos	110
5.2	Resultado de la aplicación de filtros a los web logs	118
5.3	Resultados del uso del algoritmo K-means	119
6.	Conclusiones.....	124
	Bibliografía	127
	Anexos.....	130
	A: Tablas de resultado del clustering de contenidos.....	130
	B: Resultado Bajo Interfaz Rapidminer	131
	C: Interfaz de aplicación	134
	D: Indicadores de mes de septiembre.....	136