

**DISEÑO DE UN SISTEMA DE APOYO A LA TOMA DE DECISIONES - DSS PARA LA
GESTIÓN DE LAS ETAPAS PRE-DESASTRE DE SISMOS EN BUCARAMANGA,
BASADO EN TÉCNICAS DE APRENDIZAJE AUTOMÁTICO (MACHINE
LEARNING)**

DANIEL ORLANDO MARTÍNEZ QUEZADA

Trabajo de investigación para optar el título de Magíster en Ingeniería Industrial

Director:

HENRY LAMOS DÍAZ, Ph. D

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE ESTUDIOS INDUSTRIALES Y EMPRESARIALES
MAESTRÍA EN INGENIERÍA INDUSTRIAL
BUCARAMANGA**

2017

TABLA DE CONTENIDO

INTRODUCCIÓN	11
1. REVISIÓN EN LA LITERATURA	14
1.1. Gestión de desastres	14
1.2. Sistemas de información y gestión de desastres	14
1.3. Sistemas de apoyo a la toma de decisiones DSS.....	15
1.4. Modelos de investigación operativa aplicados a la gestión de desastres	18
1.5. Modelos de aprendizaje automático en la gestión de desastres	19
1.6. DSS en la gestión de desastres	19
1.7. Optimización Multiobjetivo	21
1.7.1. Algoritmo Genético de Ordenamiento No-dominado segunda generación NSGA-II	24
1.8. Modelos de aprendizaje automático.....	26
1.8.1. Regresión lineal múltiple	26
1.8.2. Máquinas de soporte vectorial	27
1.8.3. Redes neuronales artificiales.....	29
1.8.4. Árboles de decisión.....	30
1.8.5. K-medias	31
2. PLANTEAMIENTO DEL PROBLEMA	32
3. OBJETIVOS	35
4. HIPÓTESIS.....	36
5. ARQUITECTURA PROPUESTA.....	37
5.1. Comunicación	37
5.2. Procesador de problemas	38
5.3. Gestor de conocimiento	38
5.3.1. Bases de datos históricos e información geográfica	39
5.3.1.1. Datos históricos.....	39
5.3.1.2. Datos Cartográficos.....	40
5.4. Unidades de diseño	42
6. UNIDAD I: GENERADOR DE ESCENARIOS	45
6.1. Demanda del nodo cliente.....	45
6.2. Vulnerabilidad de los albergues	51

6.3.	Vulnerabilidad de los arcos.....	53
7.	UNIDAD II: LOCALIZACIÓN DE ALBERGUES Y ASIGNACIÓN DE AFECTADOS	56
7.1.	Estructura de la solución.....	59
7.2.	Generación de la población inicial.....	60
7.3.	Operadores genéticos	60
7.4.	Evaluación de rendimiento.....	62
8.	UNIDAD III: DISTRIBUCIÓN DE AYUDAS HUMANITARIAS	65
8.1.	Estructura de la solución.....	67
8.2.	Generación de la población inicial.....	68
8.3.	Operadores genéticos	68
8.4.	Evaluación del desempeño.....	70
9.	RESULTADOS.....	74
9.1.	Albergues	75
9.2.	Población.....	76
9.3.	Planeador logístico.....	76
10.	ANÁLISIS DE RESULTADOS	80
11.	CONCLUSIONES	89
12.	REFERENCIAS.....	93

LISTA DE TABLAS

Tabla 1 Variaciones de DSS	16
Tabla 2 Resumen de datos históricos	40
Tabla 3 Resumen de representaciones cartográficas.....	40
Tabla 4 Resumen de características elemento albergue.....	41
Tabla 5 Resumen de características elemento manzana	41
Tabla 6 Resumen de características elemento arco.....	42
Tabla 7 Resumen de variables de nodos clientes	49
Tabla 8 Resumen de variables para los albergues.....	51
Tabla 9 Porcentaje correspondiente a la SS entre grupos relativo a la SS total.....	52
Tabla 10 Descripción de clusters	52
Tabla 11 Resumen de característica para los arcos.....	54
Tabla 12 Porcentaje correspondiente a la SS entre grupos relativo a la SS total.....	55
Tabla 13 Resumen del análisis de centroides por cluster.....	55

LISTA DE FIGURAS

Figura 1 Representación de espacio solución y espacio objetivo	22
Figura 2 Ejemplo de espacio objetivo y frente de pareto	23
Figura 3 Procedimiento NSGA-II	26
Figura 4 Arquitectura DSS-DM	37
Figura 5 Elementos correspondientes a la unidad 1	43
Figura 6 Elementos correspondientes a la unidad 2	43
Figura 7 Elementos correspondientes a la unidad 3	44
Figura 8 Prueba Box-Cox	47
Figura 9 RMSE conjuntos de prueba y entrenamiento	48
Figura 10 VAAE conjuntos de prueba lineal y (Rodríguez et al., 2011)	48
Figura 11 Porcentaje de mala clasificación en un conjunto de prueba	50
Figura 12 Resultados de clasificación para la ciudad de Bucaramanga	50
Figura 13 Resultados del método elbow	52
Figura 14 Resultados del método elbow	54
Figura 15 Codificación de la solución ejemplo 4 locaciones 6 clientes	59
Figura 16 Ejemplo operador de mascara binaria	61
Figura 17 Ejemplo operador cambio de bit	61
Figura 18 Resumen de cardinalidad del frente 1 por generación	62
Figura 19 Distancia por generación	63
Figura 20 Vulnerabilidad por generación	63
Figura 21 Soluciones para 1000 generaciones	64
Figura 22 Estructura de la solución MCVRP	67
Figura 23 Operador de cruce OX	69
Figura 24 Operador de mutación intercambio	70
Figura 25 Operador de mutación reverso	70
Figura 26 Cardinalidad de frente 1 por generación	71
Figura 27 Distancia por generación	72
Figura 28 Vulnerabilidad por generación	72
Figura 29 Soluciones para 1000 generaciones	73
Figura 30 Interfaz de la herramienta desarrollada	74
Figura 31 Información disponible para las ubicaciones candidatas	75
Figura 32 Información poblacional disponible	76
Figura 33 Interfaz generador de escenarios	77
Figura 34 Interfaz selección de albergue y asignación de afectados	77
Figura 35 Interfaz distribución de ayudas humanitarias	78
Figura 36 Comparación VAAE	80
Figura 37 Comparación del porcentaje de mala clasificación	81
Figura 38 Tamaño del frente 1 MFLA	82
Figura 39 Valor mínimo de distancia por iteración	82
Figura 40 Valor mínimo de vulnerabilidad por generación MFLA	83
Figura 41 Soluciones para 1000 generaciones MFLA	83
Figura 42 Cardinalidad del frente 1 MCVRP	85

LOGÍSTICA HUMANITARIA

Figura 43 Valor mínimo de distancia por iteración MCVRP	85
Figura 44 Valor mínimo de vulnerabilidad por generación MCVRP	86
Figura 45 Soluciones para 1000 generaciones MCVRP	86

RESUMEN

Título: DISEÑO DE UN SISTEMA DE APOYO A LA TOMA DE DECISIONES - DSS PARA LA GESTIÓN DE LAS ETAPAS PRE-DESASTRE DE SISMOS EN BUCARAMANGA, BASADO EN TÉCNICAS DE APRENDIZAJE AUTOMÁTICO (MACHINE LEARNING)*

Autor: DANIEL ORLANDO MARTÍNEZ QUEZADA **

Palabras Clave: APRENDIZAJE AUTOMÁTICO, SISTEMAS DE APOYO A LA TOMA DE DECISIONES, GESTIÓN DE DESASTRES

Descripción: A lo largo de la historia, la humanidad ha estado expuesta a eventos catastróficos e inesperados tanto naturales como antropogénicos, que han cobrado una gran cantidad de vidas humanas y daños materiales cuantificados en miles de dólares. La comunidad científica en la búsqueda de mitigar el impacto de las pérdidas económicas y humanas ha desarrollado sistemas de información para el apoyo de las actividades relacionadas con la gestión de desastres; dentro de estos sistemas se encuentran los sistemas de apoyo a toma de decisiones (DSS). Las actividades más importantes a realizar en las etapas de preparación y prevención de desastres son: la selección de albergues, planeación de rutas de evacuación y distribución de ayudas humanitarias, las cuales usualmente son abordadas desde el campo de investigación de operaciones a través de problemas de optimización combinatoria tales como problemas de localización de instalaciones, problemas de ruteo de vehículos y combinaciones de los anteriores.

Una dificultad significativa en el desarrollo de herramientas para la toma de decisiones dentro de la gestión de desastres se encuentra en la alta incertidumbre asociada a los resultados de un posible desastre catastrófico y las características del entorno después del evento. Aplicaciones de DSS a la gestión de desastres también conocidos como DSS-DM, han utilizado enfoques de inteligencia artificial IA, sistemas expertos ES y aprendizaje automático ML con el fin de hacer frente a estos problemas. Por lo tanto, en este trabajo se presenta el diseño de un DSS-DM que permita una toma de decisiones en actividades relacionadas a la preparación y mitigación en la ciudad de Bucaramanga, generando escenarios de desastre basados en datos históricos e información georreferenciada utilizando modelos de aprendizaje automático.

* Trabajo de maestría

** Facultad de Ingenierías Físico-Mecánicas. Escuela de Estudios Industriales y Empresariales. Director: Henry Lamos Díaz

ABSTRACT

Title: DESIGN OF A DECISION SUPPORT SYSTEM FOR THE MANAGEMENT OF PRE-DISASTER STAGES OF EARTHQUAKES IN BUCARAMANGA*

Author: DANIEL ORLANDO MARTÍNEZ QUEZADA**

Keywords: MACHINE LEARNING, DECISION SUPPORT SYSTEMS, DISASTER MANAGEMENT

Description: Throughout history, humanity has been exposed to catastrophic and unexpected events both natural and anthropogenic, which have claimed a large amount of human lives and material damage quantified in thousands of dollars. In order to mitigate the impact of these economic and human losses, the scientific community has developed information systems to support activities related to disaster management including the decision support systems (DSS). The most important activities to be carried out in the stages of disaster preparedness and mitigation are the following: shelter selection, evacuation routes planning and humanitarian aid distribution. These activities are usually addressed by the field of operations research through combinatorial optimization to solve facility location problems, vehicle routing problems, and their combinations.

However, there is a significant problem on the development of decision-making tools within disaster management, which lies in the high uncertainty associated with the consequences of the occurrence of a possible catastrophic disaster. To address these issues, the DSS applications for disaster management (DSS-DM) have used different approaches including artificial intelligence (AI), expert systems (ES) and machine learning (ML). Accordingly, this paper presents the design of a DSS-DM that allows the decision-making related to the earthquake preparation and mitigation activities in Bucaramanga, generating disaster scenarios based on historical data and geo-referenced information by means of models of machine learning.

* Master of science thesis

** Faculty of Physicomechanical Engineering, School of Industrial and Management Studies. Directed by Henry Lamos Díaz

INTRODUCCIÓN

De acuerdo a la Red Sismológica Nacional de Colombia, la ciudad de Bucaramanga ubicada en el departamento de Santander es una de las áreas en donde se concentra la mayor actividad sísmica del país, debido a que se encuentra en medio de un sistema de fallas tectónicas; sumado a esto la necesidad de vivienda económica obliga a sus pobladores a edificar en zonas de amplificación sísmica (laderas y coronas de taludes) y a no cumplir los requerimientos mínimos para asegurar construcciones sismo resistentes, ocasionando que ante un evento sísmico las posibles pérdidas y número de afectados sean considerables. La Agencia Federal de Gestión de Emergencias (FEMA) califica como desastre a la ocurrencia de una catástrofe natural, accidente tecnológico, o un evento provocado por el hombre que da lugar a grandes daños a propiedad, muertes y/o heridos. Así mismo, se define como gestión de desastres el conjunto de procesos diseñados para ser implementados antes, durante y después de los desastres, que permitan prevenir o mitigar sus efectos.

Las actividades de gestión de desastres se encuentran enmarcadas en un ciclo conformado por cuatro etapas principales: mitigación, preparación, respuesta y recuperación. Las dos primeras contemplan actividades a realizar previas al evento disruptivo que permiten una reducción de los efectos esperados. Mientras que las dos actividades siguientes toman lugar después de la ocurrencia del desastre y tienen como objetivo principal atender las necesidades básicas de la población en el corto plazo y una completa rehabilitación de la población en el largo plazo (Holguín-Veras, Jaller, Van Wassenhove, Pérez, & Wachtendorf, 2012).

La comunidad científica en la búsqueda de mitigar el impacto de las pérdidas económicas y humanas ha desarrollado sistemas de información para el apoyo de las actividades relacionadas con la gestión de desastres, las cuales se consideran como tareas de alta complejidad tanto en el manejo de la información como del modelado de las realidades en éste contexto. Entre estos sistemas se encuentran: Sistemas de Alerta Temprana (EWS) (Jin & Lin, 2011; Taubenböck et al., 2009; Wenzel & Marmuraenu, 2007), Sistemas de Información Geográfica (GIS) (Mhaske & Choudhury, 2010; Nappi, Alessio, Bronzino, Terranova, & Vilaro, 2008), Sistemas de Observación Terrestre (EOS) (Duda & Abrams, 2012; Gerke & Kerle, 2011; Voigt et al., 2007) y Sistemas de Apoyo a la Toma de Decisiones (DSS)(Kadri, Chaabane, & Tahon, 2014; Rodríguez, Vitoriano, & Montero, 2010; Rodríguez, Vitoriano, Montero, & Kecman, 2011; Rolland, Patterson, Ward, & Dodin, 2010; Zhen, Sheng, Xie, & Wang, 2015).

Sin embargo, el desarrollo de herramientas para la toma de decisiones dentro de la gestión de desastres se encuentra limitada por la alta incertidumbre asociada a los resultados de un posible desastre catastrófico y las características del entorno después del evento (Galindo & Bata, 2013). Aplicaciones de DSS a la gestión de desastres también conocidos como DSS-DM (Wallace & De Balogh, 1985), han utilizado modelos de optimización, herramientas de analítica y minería de datos con el fin de hacer frente a estos problemas (Hristidis, Chen, Li, Luis, & Deng, 2010). Además, algunos DSS-DM vinculan tecnologías de sistemas de información geográficos (GIS) (Kadri et al., 2014; Schneider & Schauer, 2006; Zhao & Liu, 2016) las cuales permiten características de visualización y gestión de información relevante para el proceso de toma de decisiones. En este trabajo se presenta un diseño de un DSS-DM que soporte el proceso de toma de decisiones en las etapas de preparación para la gestión de desastres mediante la generación de

escenarios a través de datos históricos y datos georreferenciados, que serán utilizados como parámetros de modelos de optimización que permitan entregar a un tomador de decisiones un conjunto de soluciones candidatas para la planificación de actividades logísticas inmersas en la gestión de desastres. Este sistema es validado para la ciudad de Bucaramanga ubicada en Colombia.

Este documento se encuentra organizado de la siguiente manera: en el numeral 1 se encuentra la revisión de la literatura sobre el tema de investigación; en la sección 2 se plantea el problema a abordar en la presente investigación. En las secciones 3 y 4 se presentan los objetivos e hipótesis planteadas para el proyecto. La sección 5 se presenta la arquitectura del sistema propuesto, en las secciones 6, 7 y 8 se detallan las unidades de diseño derivadas de la arquitectura; las secciones 9 ,10 y 11 muestran los resultados y la discusión de estos junto con las conclusiones derivadas del proyecto de investigación respectivamente; en la sección 12 se presentan las referencias bibliográficas consultadas.

1. REVISIÓN EN LA LITERATURA

1.1. Gestión de desastres

La Agencia Federal de Gestión de Emergencias (FEMA) califica como desastre a la ocurrencia de una catástrofe natural, accidente tecnológico, o un evento provocado por el hombre que da lugar a grandes daños a propiedad, muertes y/o heridos. Así mismo, se define como gestión de desastres el conjunto de procesos diseñados para ser implementados antes, durante y después de los desastres, que permitan prevenir o mitigar sus efectos. Las actividades de gestión de desastres se encuentran enmarcadas en un ciclo conformado por cuatro etapas principales: mitigación, preparación, respuesta y recuperación. Las dos primeras contemplan actividades a realizar previas al evento disruptivo que permiten una reducción de los efectos esperados. Mientras que las dos actividades siguientes toman lugar después de la ocurrencia del desastre y tienen como objetivo principal atender las necesidades básicas de la población en el corto plazo y una completa rehabilitación de la población en el largo plazo (Holguín-Veras, Jaller, Van Wassenhove, Pérez, & Wachtendorf, 2012).

1.2. Sistemas de información y gestión de desastres

Diferentes sistemas de información han sido desarrollados para el apoyo de actividades de la gestión de desastres dentro de estos se encuentran: sistemas de alerta temprana EWS (Jin & Lin, 2011; Taubenböck et al., 2009; Wenzel & Marmuraenu, 2007), sistemas de información geográfica GIS (Jin & Lin, 2011; Mhaske & Choudhury, 2010; Nappi, Alessio, Bronzino, Terranova, & Vilardo, 2008; Taubenböck et al., 2009; Wenzel & Marmuraenu, 2007), sistemas de observación terrestre EOS (Duda & Abrams, 2012; Gerke & Kerle, 2011; Voigt et al., 2007), sistemas de apoyo a la toma de decisiones DSS (Amailef & Lu, 2013; Kadri, Chaabane, & Tahon, 2014; Rodriguez,

Vitoriano, & Montero, 2010; Rodriguez, Vitoriano, Montero, & Kecman, 2011; Rolland, Patterson, Ward, & Dodin, 2010; Zhen, Sheng, Xie, & Wang, 2015), entre otros (Cimellaro, Scura, Renschler, Reinhorn, & Kim, 2014; Papadopoulou, Savvaidis, & Tziavos, 2011).

1.3. Sistemas de apoyo a la toma de decisiones DSS

Un DSS es entendido como una herramienta informática que analiza datos y los presenta a un tomador o tomadores de decisión de tal forma que permita hacer el proceso de toma de decisiones más sencillo (Holsapple, Jacob, Pakath, & Zaveri, 2008), esta tecnología remonta sus orígenes en los años sesenta (Eom & Lee, 1990) con los trabajos de Morton & Morton, (1967) altamente influenciados por el trabajo de Dantzig & Ramser, (1959), en estos trabajos se propuso el desarrollo de herramientas informáticas que permitan modelar procesos de decisión.

El desarrollo de DSS es un campo multidisciplinario en el cual se incluyen áreas tales como: gestión de bases de datos, inteligencia artificial, métodos de simulación, investigación de operaciones, ingeniería del software y telecomunicaciones. (Bonczek, Holsapple, & Whinston, 1981) plantearon un marco de trabajo teórico para el diseño de un sistema de apoyo a la toma de decisiones, encontrando cuatro subsistemas esenciales como: sistema de lenguaje (LS) en el cual se especifica todos los mensajes que el DSS puede recibir, sistema de presentación (PS) para todos los mensajes que el DSS puede emitir, sistema de conocimiento (KS) almacena y gestiona el conocimiento que el DSS necesita para realizar su función y finalmente el sistema de procesamiento de problemas (PPS) el cual se encarga de reconocer y dar solución a problemas durante el uso del DSS. La anterior lista de elementos es considerada como la arquitectura básica de un sistema de apoyo a la toma de decisiones DSS. La arquitectura anterior define un gran

número de conceptos fundamentales para el desarrollo de un DSS. Algunos casos especiales de arquitecturas genéricas de DSS han sido identificadas en la literatura restringidas a técnicas o representaciones de contenido particulares en los subsistemas de conocimiento (KS) y procesamiento de problemas (PPS); algunas de estas clasificaciones se resumen en la tabla 1.

Tabla 1
Variaciones de DSS

Orientado a	Procesamiento de problemas (PPS)	Conocimiento (KS)
Texto	Permite al usuario manipular y consultar los documentos almacenados en el KS	Consiste en documentos de texto, importantes para el tomador de decisión
Hipertexto	Además de manipular y consultar documentos, permite navegar a través de estos y asociar información adicional a términos clave.	Consiste en documentos de texto, importantes para el tomador de decisión
Bases de datos	Este puede ser de tres tipos: <ol style="list-style-type: none"> 1. Sistema de control 2. Sistema de consulta 3. Personalizados 	Alberga información estructurada.

Orientado a	Procesamiento de problemas (PPS)	Conocimiento (KS)
Hojas de calculo	Permite crear, visualizar y modificar conocimiento asimilado en el KS	Información en estructuras de hojas de calculo
Solver	Un solver es un procedimiento o conjunto de instrucciones que un ordenador puede ejecutar con el fin de solucionar un problema de determinado tipo.	Se encuentran los formatos de los reportes, el procedimiento del solver y parámetros necesarios no suministrados por el usuario.
Reglas	El PPS utiliza las reglas contenidas en el KS para un caso especificado por el usuario.	Una regla es la representación de conocimiento a través de una premisa (If), conclusión (Then) y razón (Because).
Múltiples participantes	Apoya labores de negociación entre los participantes (coordina y controla).	Se encarga de asimilar el conocimiento de cada uno de los participantes.

Fuente: adaptada de Holsapple, (2008)

Variantes como los DSS orientados a reglas han utilizado técnicas propias de los campos de inteligencia artificial y aprendizaje automático. Aplicaciones de DSS orientados a reglas utilizando técnicas de aprendizaje automático supervisado a través de criterio de expertos son conocidos como Sistemas Expertos (Burstein & Carlsson, 2008). En el caso de las variantes de DSS

orientados a solver y múltiples participantes han sido ampliamente estudiadas desde el campo de investigación operativa utilizando enfoques de simulación, multiobjetivo y multicriterio (Altay & Green, 2006).

1.4. Modelos de investigación operativa aplicados a la gestión de desastres

Muchas de las actividades encontradas en la gestión de desastres han sido estudiadas desde el campo de la investigación operativa, abordadas como problemas de optimización cuyos propósitos contemplan la localización de albergues o centros de distribución de recursos (Abounacer, Rekik, & Renaud, 2014; Khayal, Pradhananga, Pokharel, & Mutlu, 2015; Najji-Azimi, Renaud, Ruiz, & Salari, 2012; Rath & Gutjahr, 2014), asignación y distribución de recursos (Hu, 2011; Huang, Smilowitz, & Balcik, 2013; Najafi, Eshghi, & de Leeuw, 2014; Ortuño, Tirado, & Vitoriano, 2011), programación de actividades (Aleskerov, Say, Toker, Akin, & Altay, 2005; Lassiter, Khademi, & Taaffe, 2015; Rachaniotis, Dasaklis, & Pappis, 2012; Yan, Lin, & Chen, 2012; Zheng, Ling, Shi, Chen, & Chen, 2014), gestión de inventarios (Döyen, Aras, & Barbarosoğlu, 2012; Garrido, Lamas, & Pino, 2015; McCoy & Brandeau, 2011; Taskin & Lodree, 2011), entre otros (Najafi, Eshghi, & Dullaert, 2013; Omidvari, Mansouri, & Nouri, 2015; Onan, Ülengin, & Sennaroğlu, 2015; Sahebjamnia, Torabi, & Mansouri, 2015); revisiones literarias sobre investigación operativa aplicada a la gestión de desastres se encuentran en (Altay & Green, 2006; Galindo & Batta, 2013). Debido al entorno dinámico encontrado en las actividades de gestión de desastres es necesario el desarrollo de herramientas que permitan una toma de decisiones ágil. Sin embargo, la investigación en actividades de gestión de desastres presenta dificultades en el desarrollo de herramientas para el tomador de decisiones. Entre las dificultades para el desarrollo de herramientas para la toma de decisiones dentro de la gestión de desastres se encuentra la alta incertidumbre asociada a los resultados de un posible desastre catastrófico (víctimas mortales,

población afectada, áreas afectadas) y características del entorno después del evento (disponibilidad de vías, disponibilidad de recursos)(Galindo & Batta, 2013; Hristidis, Chen, Li, Luis, & Deng, 2010).

1.5. Modelos de aprendizaje automático en la gestión de desastres

El aprendizaje automático (Machine Learning) se define como el campo de estudio que asigna a un computador o maquina la habilidad de aprender sin necesidad de ser programada explícitamente (Ratner, 2011). Enfoques de aprendizaje automático han permitido el desarrollo de estrategias para el análisis rápido de grandes volúmenes de información, en especial para las actividades relacionadas con las fases posteriores al desastre (Wang, Wu, Yen, Guo, & Cheng, 2016), dentro de esto se encuentra el análisis de sentimientos a través de redes sociales tales como Twitter(Chae et al., 2014), análisis espaciales tales como, agrupamiento, asociación, detección de anomalías(Horita, de Albuquerque, Degrossi, Menciondo, & Ueyama, 2015) y el análisis de imágenes en problemas de evaluación de daños (Voigt et al., 2007). En las fases anteriores a la ocurrencia del desastre, se plantean problemas alrededor de la estimación de los efectos esperados frente al evento (Rodriguez et al., 2011) y la identificación del riesgo (Tralli, Blom, Zlotnicki, Donnellan, & Evans, 2005).

1.6. DSS en la gestión de desastres

La aplicación de tecnologías DSS a la gestión de desastres también conocida como DSS-DM, fue identificado en (Wallace & De Balogh, 1985) presentando una detallada revisión de los sistemas de información y tecnologías aplicadas en la gestión de desastres dentro del marco de un proceso de toma de decisiones. Desde el campo de investigación operativa se han desarrollado

trabajos en los cuales se plantean tecnologías DSS-DM; (Arora, Raghu, & Vinze, 2010) plantean un modelo de asignación de recursos para un conjunto de escenarios de pandemias encontrando soluciones óptimas en los mismos, (Nolz, Doerner, & Hartl, 2010) presentan un modelo bi-objetivo en el cual se persigue la minimización de los tiempos de viaje y la distancia entre la población afectada y los puntos de distribución este modelo es solucionado utilizando un algoritmo evolutivo multiobjetivo en cual permite encontrar soluciones de compromiso para un tomador de decisiones, (B. Vitoriano, Ortuno, Tirado, & Montero, 2011) desarrollan un modelo multicriterio para un problema de distribución de ayudas humanitarias y es evaluado para un caso de estudio utilizando el lenguaje de programación GAMS encontrando soluciones óptimas para este. (Rakes, Deane, Rees, & Fetter, 2014) presentan un modelo de asignación de albergues temporales a población afectada este es solucionado con un método heurístico, un modelo multiobjetivo para la planificación de actividades es propuesto por (Chacko et al., 2016) ellos proponen la minimización de pérdidas humanas esperadas y la resiliencia frente a un nuevo evento.

Por otro lado, en el campo de aprendizaje automático se han desarrollado trabajos proponiendo tecnologías DSS-DM; dentro de las aplicaciones de aprendizaje automático se destaca la metodología SEDD (Sistema de Evaluación y Diagnostico de Desastres) presentada en los trabajos de (Rodriguez et al., 2010; Rodriguez, Vitoriano, & Montero, 2012; Rodriguez et al., 2011) esta metodología consiste en la estimación de daños potenciales de un desastre (afectados, pérdidas humanas y económicas) utilizando representaciones lingüísticas a partir de lógica difusa; entre otras contribuciones al campo se encuentran, (De Maio, Fenza, Gaeta, Loia, & Orciuoli, 2011) proponen la utilización de mapas cognitivos difusos para el análisis de información de diferentes fuentes en el caso de una emergencia y con esta apoyar las decisiones relacionadas a la planeación

de las actividades de respuesta; (Liao, Wang, Xia, & Hannam, 2012) diseñan una red neuronal artificial con el fin de a través de características de atmosféricas y de la generación de la emergencia soportar la toma de decisiones en las actividades de respuesta en el caso de incendios. Enfoques de redes Bayesianas han sido aplicados con el fin encontrar dependencias con datos históricos un ejemplo de esto es mostrado en (Qiu, Wang, Ye, Liu, & Dong, 2014) el cual propone un modelo de red bayesiana que permite la estimación de la ocurrencia, características del evento y pérdidas humanas, este modelo es evaluado con datos históricos; otra aplicación de modelos bayesianos es presentada por (Leonelli & Smith, 2015) este trabajo plantea el desarrollo de un sistema experto teniendo en cuenta varios participantes, (Romanowski et al., 2015) plantea una metodología para la sugerencia de procedimientos a través del análisis de escenarios pasados utilizando arboles de decisión.

En las tecnologías DSS-DM diferentes a las desarrolladas bajo enfoques de investigación de operaciones y aprendizaje automático se encuentra el uso de metodologías para la toma de decisiones grupales (Shan, Wang, Li, & Chen, 2012; Yu & Lai, 2011), sistemas basados en conocimiento (Fogli & Guida, 2013) y sistemas de información geográfica (Horita et al., 2015).

1.7.Optimización Multiobjetivo

El modelo matemático de un problema multiobjetivo busca encontrar un vector de variables de decisión $x = \{x_1, x_2, x_3, \dots, x_l\}$ que cumpla con un conjunto de restricciones y optimice M funciones objetivo (1). Usualmente se presenta como:

$$\min: f_m(x), \quad m = 1, 2, \dots, M \quad (1)$$

Sujeto a.


$$g_j(x) \geq 0 \quad j = 1, 2, \dots, J \quad (2)$$

$$h_k(x) = 0 \quad k = 1, 2, \dots, K \quad (3)$$

$$x_i^{min} \leq x_i \leq x_i^{max} \quad i = 1, 2, \dots, I \quad (4)$$

El espacio de solución, representado por todas las combinaciones posibles en el valor de las variables delimitados por el sistema de ecuaciones (2-4), genera un segundo espacio conocido como espacio objetivo Figura 1. Las funciones objetivo representan diferentes criterios para evaluar una solución haciendo inviable una comparación directa con otras soluciones al encontrar multiples funciones objetivo para cada una de estas, por ende, se crea la necesidad de comparar una solución con otra y determinar cuál es mejor. A raíz de esta situación surge el concepto de dominancia, con el fin de clasificar las diferentes soluciones encontradas y determinar aquellas de mejor calidad.

Figura 1
Representación de espacio solución y espacio objetivo



Fuente: Adaptado de Dias & De Vasconcelos, (2002)

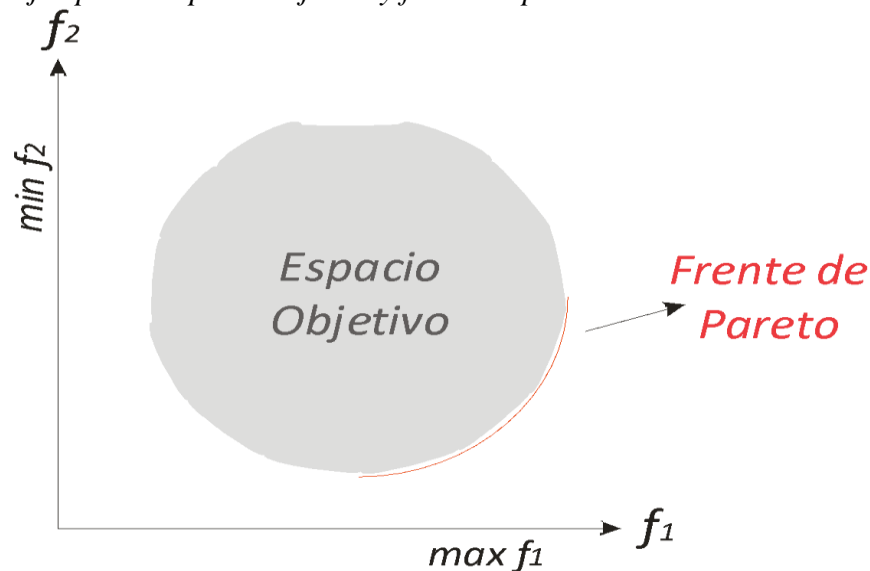
Se dice que una solución $x^{(1)} = \{x_1^{(1)}, x_2^{(1)}, x_3^{(1)}, \dots, x_l^{(1)}\}$ domina a otra solución $x^{(2)} = \{x_1^{(2)}, x_2^{(2)}, x_3^{(2)}, \dots, x_l^{(2)}\}$ si:

La solución $x^{(1)}$ no es de menor calidad que $x^{(2)}$ en todos los objetivos.

La solución $x^{(1)}$ es estrictamente mejor que $x^{(2)}$ en al menos uno de los objetivos.

Aplicando estas dos reglas a todo un conjunto de soluciones factibles de un problema de optimización multiobjetivo, se puede hallar aquellas que son no dominadas (que ninguna otra solución las domina y no hay relación de dominancia entre ellas), las cuales son conocidas como Frente de Pareto. Se ha logrado establecer que el Frente de Pareto siempre está compuesto por soluciones ubicadas en el borde del Espacio de Objetivo (Dias & De Vasconcelos, 2002). En la figura 2, se presenta un ejemplo de Espacio Objetivo de dos funciones y su correspondiente Frente de Pareto.

Figura 2
Ejemplo de espacio objetivo y frente de pareto



Fuente: Adaptado de Dias & De Vasconcelos, (2002)

1.7.1. Algoritmo Genético de Ordenamiento No-dominado segunda generación NSGA-II

Diversos metodos de solución para problemas multiobjetio han sido planteados, siendo uno de estos el Algoritmo Genetico Elitista de Ordenamiento No-dominado de segunda generación NSGA-II propuesto por Deh, Agrawal, Pratap, & Meyarivan, (2000). Inicialmente este algoritmo genera una población de padres P_t , y mediante operadores (cruce y mutación de los algoritmos genéticos convencionales) una segunda población de hijos Q_t es generada, cada población P_t y Q_t tienen tamaño N . Después de esto, a partir de P_t y Q_t se genera un nuevo conjunto $R_t = P_t \cup Q_t$ con tamaño $2N$. Una vez creado este nuevo conjunto R_t se procede a realizar un ordenamiento no dominado sobre R_t modificado a partir del presentado por (Srinivas & Deb, 1994) en la primera versión de NSGA, generando así los diferentes frentes de Pareto F_i . Después del ordenamiento no dominado se genera una nueva población de tamaño N con los primeros frentes de Pareto F_i . De forma general el algoritmo NSGA-II puede ser resumido en los siguientes pasos:

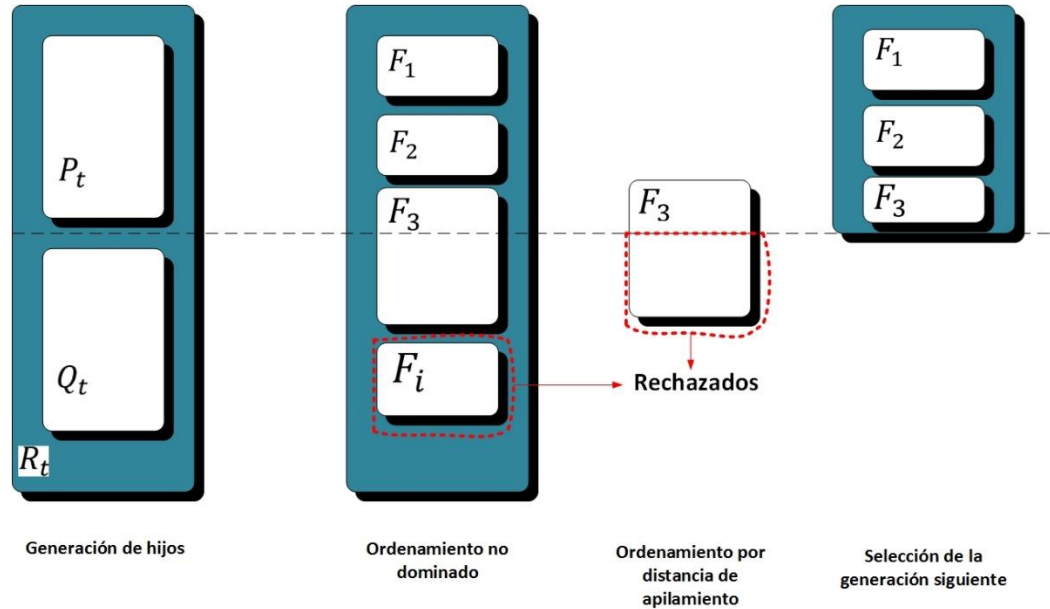
1. Combinar las poblaciones de padres y descendientes para crear $R_t = P_t \cup Q_t$. Realizar el ordenamiento no dominado a R_t e identificar los frentes $F_i, i = 1, 2, \dots etc.$
2. Hacer $P_{t+1} = \emptyset$, e $i = 1$ mientras $|P_{t+1}| + |F_i| \leq N$ hacer $P_{t+1} = P_{t+1} \cup F_i$ e $i = i + 1$.
3. Realizar ordenamiento por apilamiento e incluir en P_{t+1} las $N - |P_{t+1}|$ soluciones más esparcidas usando los valores de distancias de apilamiento asociadas al frente F_i .
4. Crear la población descendiente Q_{t+1} a partir de P_{t+1} usando selección por torneo, cruzamiento y mutación.

Con el fin de crear diversidad en el frente F_i mencionado en el paso 3, es necesario el cálculo de la distancia de apilamiento para cada una de las soluciones pertenecientes al frente mencionado, inicialmente es necesario suponer que $l = |F_i|$ y x_{jk} representa la j -ésima solución en una lista ordenada con respecto a la función objetivo k . En los valores extremos de j es decir $j = 1$ el menor y $j = l$ el mayor se asigna el valor de infinito a la distancia de apilamiento en el objetivo correspondiente, para $j = 2, 3, \dots, (l - 1)$ se tiene:

$$cd_k(x_{j,k}) = \frac{z_k(x_{j+1,k}) - z_k(x_{j-1,k})}{z_k^{max} - z_k^{min}} \quad (5)$$

Una vez calculada la distancia de apilamiento para cada dupla (j, k) es necesario encontrar la distancia total para cada solución x , la cual corresponde a la suma de las distancias de apilamiento para cada objetivo k . El criterio de inclusión a la población P_{t+1} de cualquier solución x perteneciente al frente F_i es la de mayor distancia de apilamiento hasta que $|P_{t+1}| = N$ (Figura 3).

Figura 3
Procedimiento NSGA-II



Fuente: Adaptado de Deh et al., (2000)

1.8. Modelos de aprendizaje automático

Los fundamentos teóricos de este tipo de modelos de aprendizaje automático utilizados en el desarrollo de este proyecto se presentan a continuación.

1.8.1. Regresión lineal múltiple

En general un modelo de regresión lineal múltiple relaciona una variable respuesta y con k características o regresores, tiene una estructura como se muestra en la ecuación (6); comúnmente se usa el método de mínimos cuadrados para la estimación de los parámetros β .

$$y = X\beta + \varepsilon \tag{6}$$

Siendo X las muestras de las variables dependientes como una matriz de orden $n \times (k + 1)$ en la que n representa el tamaño de la muestra de entrenamiento del modelo y k el número de variables independientes, y y ε son vectores de orden n los cuales representan los valores de la muestra de la variable dependiente y el error de estimación para cada valor en y respectivamente. La estimación de los parámetros β por la minimización de cuadrados de ε consiste la solución del problema presentado en (7) el cual tiene una solución conocida (8).

$$\text{Minimizar } S(\beta) = \sum_{i=1}^n \varepsilon_i^2 = \varepsilon' \varepsilon = (y - X\beta)'(y - X\beta) \quad (7)$$

$$\hat{\beta} = (X'X)^{-1}X'y \quad (8)$$

1.8.2. Máquinas de soporte vectorial

Las máquinas de soporte vectorial fueron desarrolladas en 1995 (Cortes & Vapnik, 1995), este clasificador busca encontrar el hiperplano separador óptimo entre dos clases buscando la maximización del margen entre los puntos más cercanos a dicho hiperplano, para encontrar el plano se formula un problema de optimización cuadrática. Las máquinas de soporte vectorial han sido utilizadas para modelos de clasificación múltiple y regresión (Schölkopf, Smola, Williamson, & Bartlett, 2000).

Los modelos de máquinas de soporte vectorial fueron desarrollados inicialmente para problemas de clasificación binaria, pero su aplicación ha sido extendida a problemas de clasificación múltiple y regresión. El objetivo del modelo es encontrar un hiperplano separador que maximice el margen entre este y los puntos adyacentes. Para la determinación del hiperplano

separador se plantea un problema de optimización cuadrática el cual es descrito por las ecuaciones (9-11), para casos de clasificación múltiple se plantea la solución recursiva de varios casos de clasificación binaria. Los parámetros C y ϵ son dados para la solución del problema, el término e corresponde a un vector unidad, y_i corresponde a cada una de las observaciones de la variable dependiente, Q corresponde a una matriz semidefinida positiva en la cual cada $Q_{ij} = y_i y_j K(x_i, x_j)$ siendo $K(x_i, x_j)$ una función de Kernel y α variable dual.

$$\text{Minimizar } \frac{1}{2} \alpha' Q \alpha - e' \alpha \quad (9)$$

Sujeto a.

$$0 \leq \alpha_i \leq C, i = 1, \dots, n \quad (10)$$

$$y' \alpha = 0 \quad (11)$$

La utilización de máquinas de soporte vectorial para modelos de regresión busca la maximización del margen de dos límites los cuales son ajustados apropiadamente con el fin de evitar la inclusión de observaciones atípicas, para esto se propone una función de penalización de error en (12); el modelo propuesto a ajustar es mostrado en (13) para este modelo es necesario estimar b y w .

$$|y - f(x)|_\epsilon = \max\{0, |y - f(x)| - \epsilon\} \quad (12)$$

$$f(x) = K(w, x) + b \quad (13)$$

Al igual que su contraparte en clasificación binaria, el problema de optimización cuadrática propuesto para la estimación de b y w esta dado en función de la variable dual α , este problema dual se presenta en las ecuaciones (14-16),

$$\text{Minimizar } \frac{1}{2}(\alpha - \alpha^*)'Q(\alpha - \alpha^*) + \epsilon \sum_{i=1}^n (\alpha_i - \alpha_i^*) + \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*) \quad (14)$$

Sujeto a.

$$0 \leq \alpha_i, \alpha_i^* \leq C, i = 1, \dots, n \quad (15)$$

$$\sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \quad (16)$$

1.8.3. Redes neuronales artificiales

Las Redes Neuronales Artificiales (ANN) son modelos matemáticos que intentan reproducir el funcionamiento del sistema nervioso humano. Debido a la complejidad del sistema nervioso humano el modelo de redes neuronales artificiales es simplificado con el fin de ser aplicado a una tarea determinada, propuesta inicialmente en (McCulloch & Pitts, 1943). Una ANN relaciona p variables independientes $x_1, x_2, \dots, x_j, \dots, x_p$ con q variables de salida y_1, y_2, \dots, y_q ; el modelo es compuesto para varias capas de variables originales y variables derivadas. La estructura común de ANN está compuesta de tres tipos de capas: capa de entradas las cuales son las variables independientes, las capas ocultas formadas por un conjunto de variables derivadas y la capa de salida corresponde a las variables dependientes.

Las unidades correspondientes a las capas ocultas y de salida son llamados nodos, cada uno de estos nodos tienen una variable derivada asociada, en el caso de los nodos de la primera capa oculta la variable derivada $a_u = \sum_{j=1}^p w_{1ju}x_j + \theta_u$ los parámetros w_{1ju} y θ_u son parámetros desconocidos los cuales se deben estimar. Cada variable derivada correspondiente a los nodos se transforma por medio de una función de activación $g()$ la cual es salida de cada nodo $z_u = g(a_u)$ que sirve como entrada a otros nodos de la red. Métodos como backpropagation y variaciones han sido utilizados para la estimación de los pesos w_{1ju} y θ_u .

El método de backpropagation permite la estimación de los pesos w_{iju} , emplea un ciclo de propagación que actúa de la conocida siguiente forma: se genera inicialmente la señal de salida z_u , eligiendo de manera aleatoria w_{iju} , estos se comparan con los valores de y_i (conocidos) generando una medida de error y evaluando la contribución de cada una de las capas ocultas a este de tal forma que permita actualizar los pesos de cada uno de los arcos con el fin de minimizar el error de estimación.

Para el caso de aplicaciones de clasificación supervisada, las redes neuronales utilizan los mismos métodos que en las aplicaciones de regresión vistos, solo se diferencian en la forma en que se representa la variable independiente, que corresponde a la probabilidad asociada de un individuo a clasificar pertenezca a la i -ésima clase dado x_1, x_2, \dots, x_p las características asociadas.

1.8.4. Árboles de decisión

Un árbol de decisión es una representación posible de los procesos de decisión involucrados en tareas de clasificación, los atributos son utilizados para crear particiones de conjuntos de ejemplos.

Los nodos del árbol corresponden a los nombre o identificaciones de las características, mientras que las ramas de cada nodo representan los posibles valores del atributo asociado en la predicción; las hojas indican los sub conjuntos de las muestras de entrenamiento ya clasificados en la clase predicha. La construcción de un árbol de decisión inicia con la identificación de las características más influyentes en la discriminación por las clasificaciones; se usan medidas de eficiencia como la entropía, chaid, entre otras.

1.8.5. K-medias

Dentro de los algoritmos principales de la clasificación no supervisada se encuentran el algoritmo K-medias que fue utilizado por primera vez por (MacQueen, 1967) en 1967. El algoritmo propuesto de K-medias considera la generación aleatoria de k centroides iniciales, o dicho de forma equivalente a k conglomerados con un único elemento donde k se conoce. A continuación, cada uno de los objetos es asignando al conglomerado con el centroide más próximo, al efectuar las asignaciones correspondientes se recalculan las coordenadas de los nuevos centroides.

2. PLANTEAMIENTO DEL PROBLEMA

Los terremotos son los desastres naturales que más vidas han cobrado en los últimos años; según el Centro para la Investigación sobre la Epidemiología de los Desastres CRED en el periodo de 2010 a 2015, los terremotos cobraron la vida de 259.808 personas y causaron daños por un valor aproximado de 317.263.533 millones de dólares. Uno de los casos más representativos es el sismo de Haití en 2010. Haití se encuentra ubicado sobre la falla tectónica “Enriquillo” y es catalogado como uno de los países más pobres de América ubicado en la posición 163 del escalafón de desarrollo de las Naciones Unidas. El 12 de enero del 2010 a las 4:53 p.m. se registró el sismo de magnitud 7.0 y una profundidad 13 kilómetros afectando principalmente a la ciudad de Puerto Prince (capital de Haití), con un estimado de 230.000 muertos, 300.000 heridos y alrededor de 1 millón de personas afectadas. Para dar respuesta a este evento, se requirió un desplazamiento enorme de recursos por parte de las Naciones Unidas y organismos internacionales, uno de los grandes desafíos fue la consecución de información y procedimientos adecuados para la distribución de recursos y albergue de afectados, el desarrollo de las acciones de respuesta a este evento fue sin precedentes por parte de los organismos internacionales, sin embargo, fueron insuficientes para manejar la escala del desastre, particularmente en el mes siguiente al evento. Lo anterior se debió a la complejidad de la tarea, incertidumbre de los daños generados por el evento y la poca preparación del gobierno de Haití para un evento catastrófico de este tipo (Yates & Paquette, 2011).

De acuerdo con la Red Sismológica Nacional de Colombia, la ciudad de Bucaramanga es una de las áreas en donde se concentra la mayor actividad sísmica del país, debido a que se encuentra ubicada en medio de un sistema de fallas tectónicas. Estas condiciones físicas de la zona

incrementan el riesgo ante un sismo de gran magnitud que podría causar pérdidas económicas y humanas significativas. Es por ello, que se requiere una adecuada gestión de desastres ante un evento sísmico sustentada en herramientas fiables que apoyen a los diferentes actores involucrados en el proceso de toma de decisiones. En el documento de “Estrategias para la Respuesta a Emergencias Bucaramanga 2012” se encuentra que, pese a la identificación del riesgo frente a un evento sísmico, albergues potenciales, transportes disponibles y zonas de riesgo, el municipio no cuenta con herramientas cuantitativas que soporten la toma de decisiones y permita una adecuada preparación ante un evento sísmico.

Una vez ocurrido un evento sísmico de gran magnitud, es difícil la rápida consecución de información fiable debido a múltiples problemas de comunicación, por esto un enfoque de planificación por escenarios es recomendable para los responsables de las actividades de gestión de desastres. En las aplicaciones de investigación de operaciones a tecnologías DSS-DM se encuentran modelos para procesos de decisión altamente complejos, sin embargo, existen limitantes como el requerimiento de parámetros confiables que de acuerdo al contexto son difíciles de obtener; es así que en la mayoría de aplicaciones se utilizan parámetros de escenarios simulados. Por otro lado, las aplicaciones de aprendizaje automático buscan la consecución de parámetros relacionados con el conocimiento del riesgo y el impacto esperado frente a un desastre, lo anterior brinda una oportunidad para el desarrollo de tecnologías DSS-DM mixtas entre enfoques de investigación de operaciones y aprendizaje automático las cuales han brindado buenos resultados en campos diferentes a la gestión de desastres (Holsapple, Jacob, Pakath, & Zaveri, 2008).

De acuerdo a lo mencionado anteriormente, el presente proyecto propone un diseño de un DSS orientado a las fases de pre-desastre de un sismo basado en técnicas de aprendizaje automático y modelos de optimización multiobjetivo para la ciudad de Bucaramanga el cual permite la generación de escenarios de sismos para la ciudad y a su vez permite la selección de estrategias en los procesos de decisión de selección de albergues temporales, planeación de la evacuación y la distribución de recursos pos-desastre para un escenario dado.

3. OBJETIVOS

3.1 Objetivo general:

Diseñar un DSS orientado a las fases de preparación y mitigación de un sismo mediante técnicas de Aprendizaje Automático para la ciudad de Bucaramanga.

3.2 Objetivos específicos:

- Revisar en la literatura la aplicación de sistemas de información en la gestión de desastres naturales para identificar la aplicación de los DSS.
- Definir la arquitectura del DSS basada en los elementos planteados por (Bonczek et al., 1981)
- Identificar las técnicas de aprendizaje automático que soporten los procesos de toma de decisiones críticos en las fases de pre-desastre en un proceso de gestión de sismos.
- Encontrar las diferentes relaciones entre los elementos que conforman el DSS para cada proceso de toma de decisiones.
- Desarrollar un prototipo con el fin de validar las funciones básicas del diseño propuesto.

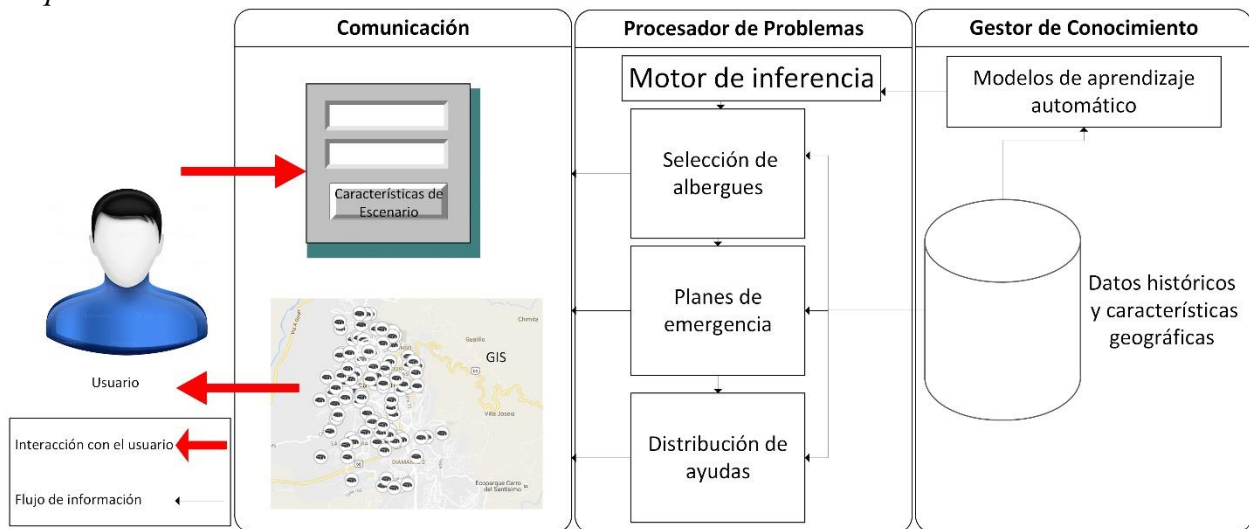
4. HIPÓTESIS

Un DSS mejorado con técnicas de aprendizaje automático permite una mayor adaptabilidad y actividad comparado con un DSS basado netamente en modelos para un contexto de gestión de sismos.

5. ARQUITECTURA PROPUESTA

Teniendo en cuenta los elementos presentados por (Holsapple, 2008) y (Wallace & De Balogh, 1985), en el DSS-DM propuesto se plantea una arquitectura (figura 4) de tres capas denominadas: comunicación, motor de decisión y gestión de conocimiento, la primera corresponde a todas las acciones de entrada o salida que el tomador de decisiones o usuario tiene permitidas, el motor de decisión contempla todos los modelos o procesos predefinidos que ofrecen soluciones o análisis que posteriormente serán presentados al usuario y la capa de gestión de conocimiento almacena y gestiona todos los datos e información necesaria para el funcionamiento del DSS-DM.

Figura 4
Arquitectura DSS-DM



Fuente: Autor

5.1. Comunicación

Esta capa comprende el entorno de comunicación que tiene el usuario con el DSS-DM, en esta el usuario puede ajustar los parámetros del evento sísmico a analizar y a la vez permite al tomador de decisiones visualizar las soluciones disponibles de acuerdo al respectivo proceso de decisión

y el escenario dado; por lo tanto, se considera el uso de un Sistema de Información Geografico SIG para la presentación de este tipo de información.

5.2. Procesador de problemas

El motor de decisión contempla 4 elementos: Selección de albergues, Planes de emergencia, Distribución de ayudas y Motor de inferencia. Los primeros tres elementos corresponden a los procesos de decisión relacionados con actividades logísticas de la gestión de desastres a tratar por el DSS-DM, el cuarto elemento estima los parámetros críticos para los primeros tres elementos. Es de resaltar que las actividades logísticas de los primeros tres elementos se plantean como elementos dependientes uno del otro, es decir para el desarrollo del segundo elemento es necesario la solución del primer elemento. En aplicaciones de investigación de operaciones a la gestión de desastres se evidencia el interes en múltiples objetivos tales como: minimización de costos, tiempos de viaje, riesgos y la maximización confiabilidad de los elementos en la solución; normalmente estos objetivos son contradictorios en algunos contextos, por esto se han aplicado modelos de optimización multiobjetivo en la solución de las actividades logisticas mencionadas.

5.3. Gestor de conocimiento

Esta capa del DSS-DM agrupa toda la información necesaria para el funcionamiento de los elementos descritos en los numerales 5.1 y 5.2, esta capa es desagregada en dos partes: Modelos de aprendizaje automático y bases de datos. La primera parte corresponde a los modelos para determinar los parámetros vulnerabilidad de albergues temporales, vulnerabilidad vial y cantidad de afectados; la segunda contempla los parámetros asociados a cada problema de toma de decisiones mencionados, cada uno de estos elementos se detallan a continuación.

5.3.1. Bases de datos históricos e información geográfica

Actualmente la ciudad de Bucaramanga no cuenta con una microzonificación sísmica, por lo tanto se hace necesario realizar una estimación de parámetros de vulnerabilidad requeridos por el procesador de problemas, a partir de estudios de vulnerabilidad sísmica realizados en la ciudad (Chio & Maldonado, 2007), datos cartográficos consolidados por el grupo de investigación OPALO, que comprenden ubicaciones candidatas para albergues temporales, fallas geológicas, rellenos antrópicos y amenazas naturales. Por otro lado, el Departamento Administrativo Nacional de Estadística de Colombia (DANE) tiene información cartográfica sobre características poblacionales. Bases de datos históricos de organizaciones internacionales y centros de investigación como el Centro de Investigación de la Epidemiología del Desastre (CRED), Centro de Estudios Geológicos de Estados Unidos (USGS) y el Banco Mundial (WB) se encuentran disponibles de acceso abierto. Todas las fuentes de información mencionadas permiten aproximar o estimar los parámetros importantes para cada uno de los escenarios simulados.

5.3.1.1. Datos históricos

Datos históricos de la CRED, WB y USGS fueron consolidados para las variables descritas en la tabla 2. La cantidad de afectados fue tomada de la base de datos EM-Dat, a partir de la densidad poblacional y el índice de desarrollo humano HDI del país de ocurrencia de la base de datos del WB, la profundidad y magnitud del sismo fueron tomadas de los archivos del USGS, aquí solo se tuvo en cuenta el registro con mayor magnitud en la fecha y zona de ocurrencia del desastre.

Tabla 2

Resumen de datos históricos

Variable	Fuente	Descripción
Afectados	CRED	Número de personas afectadas en un desastre sísmico.
Densidad	WB	Densidad poblacional promedio del país en donde el evento ocurrió.
HDI	WB	Índice de desarrollo humano del país en el año del evento.
Profundidad	USGS	Profundidad en kilómetros del sismo que origino el desastre.
Magnitud	USGS	Magnitud del movimiento telúrico que causo el desastre.

5.3.1.2. Datos Cartográficos

Los problemas de decisión abordados en la presente investigación se encuentran elementos comunes, los cuales pueden ser representados a través de elementos cartográficos. Los elementos a considerar son: albergues temporales candidatos, manzanas como puntos de agregación de demanda o clientes y los arcos (i, j) que representan vías de conexión entre albergues y centro de distribución o albergues y puntos de agregación de demanda. Las representaciones cartográficas adoptadas para cada uno de los elementos se muestran en la tabla 3, el resumen de las características asociadas a cada uno de estos se resume en las tablas 4, 5 y 6.

Tabla 3

Resumen de representaciones cartográficas

Elemento	Representación
Albergues	Punto
Manzanas	Polígono
Arcos	Línea

Tabla 4

Resumen de características elemento albergue

Característica	Descripción
Tipo de albergue	Clasificación de cada albergue en las siguientes clases: educativo, zona verde y polideportivo.
Tipo de construcción	Clasificación del albergue en las siguientes clases: tapia, mampostería confinada, mampostería no confinada, pórtico, muro estructural, estructura metálica y ninguno.
Años de construcción	Año de construcción del albergue.
Niveles	Numero de niveles o pisos de la edificación.
Distancia a fallas	Mínima distancia euclidiana entre el albergue y cada una de las fallas de: Chimita, Rio surata y Bucaramanga.
Pertenencia a una zona de amenaza o relleno	Pertenencia o no a una zona de Derrumbes, Caída de rocas, Remoción de masas o rellenos antrópicos o mecánicos.
Capacidad	Cantidad máxima de personas permitidas en el albergue.

Tabla 5

Resumen de características elemento manzana

Característica	Descripción
Perfil de construcción	Porcentaje de construcción según el tipo de construcción distribuido en las siguientes clases: tapia, mampostería, pórtico menor a 3 niveles, pórtico de 4 a 7 niveles, pórtico mayor a 8 niveles, muro estructural.
Distancia a fallas	Mínima distancia euclidiana entre el albergue y cada una de las fallas de: Chimita, Rio surata y Bucaramanga.
Pertenencia a una zona de amenaza o relleno	Pertenencia o no a una zona de Derrumbes, Caída de rocas, Remoción de masas o rellenos antrópicos o mecánicos.
Personas	Cantidad de personas que habitan la manzana de acuerdo al censo del 2005.

Tabla 6

Resumen de características elemento arco

Característica	Descripción
Perfil de construcción promedio	Porcentaje de construcción promedio según el tipo de construcción distribuido en las siguientes clases: tapia, mampostería, pórtico menor a 3 niveles, pórtico de 4 a 7 niveles, pórtico mayor a 8 niveles, muro estructural.
Distancia a fallas	Mínima distancia euclidiana entre el albergue y cada una de las fallas de: Chimita, Rio surata y Bucaramanga.
Pertenencia a una zona de amenaza o relleno	Pertenencia o no a una zona de Derrumbes, Caída de rocas, Remoción de masas o rellenos antrópicos o mecánicos.
Distancia de viaje	Distancia del arco (i, j) .

5.4. Unidades de diseño

Por la complejidad de la estructura propuesta esta se divide en tres unidades con el fin de facilitar el proceso de desarrollo del prototipo. Las unidades consideradas fueron nombradas así: el generador de escenarios (figura 5), la localización de albergues y asignación de afectados (figura 6) y la distribución de ayudas humanitarias (figura 7), estas se detallan en los capítulos siguientes.

Figura 5

Elementos correspondientes a la unidad 1: Generador de escenarios

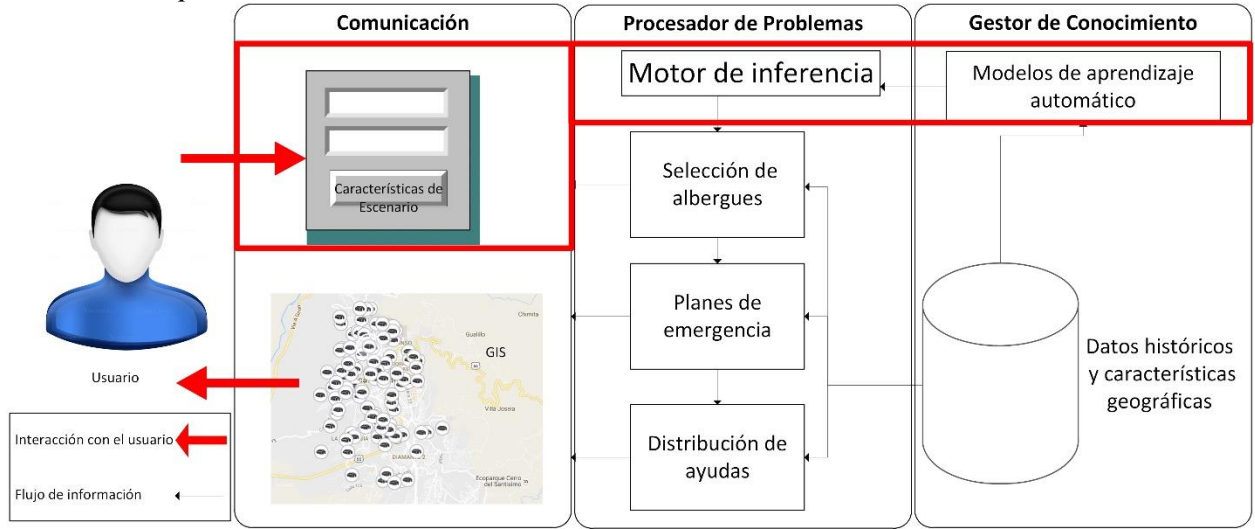


Figura 6

Elementos correspondientes a la unidad 2: localización de albergues y asignación de afectados

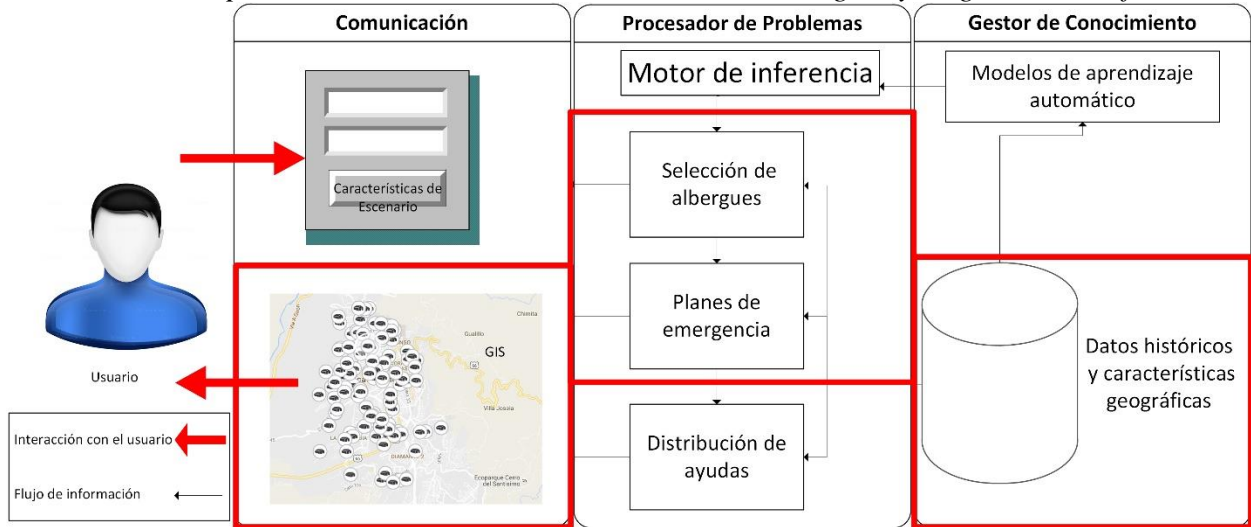
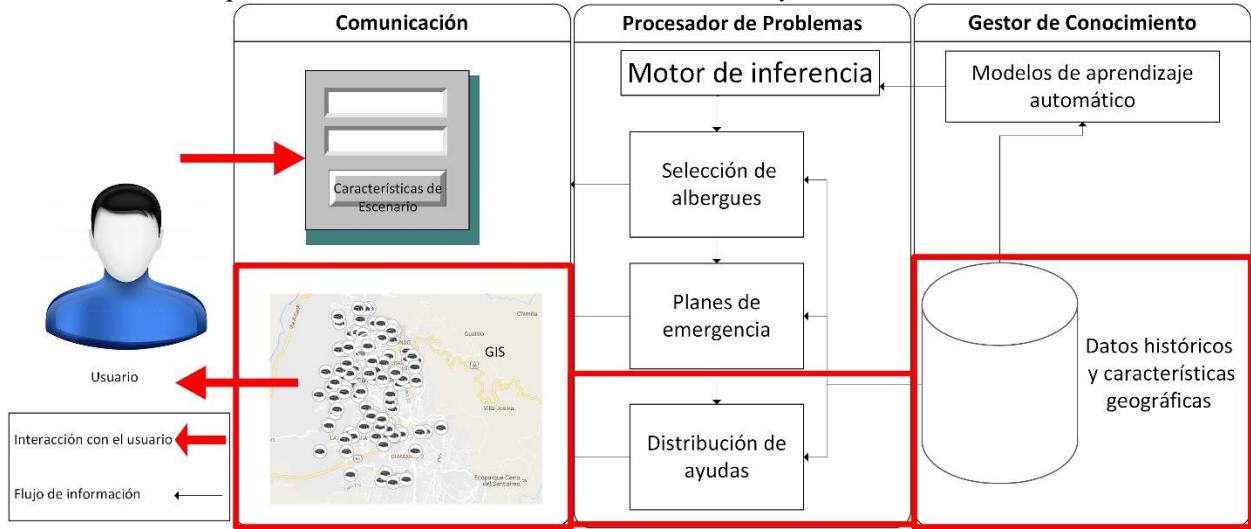


Figura 7

Elementos correspondientes a la unidad 3: distribución de ayudas humanitarias



6. UNIDAD I: GENERADOR DE ESCENARIOS

Para la generación de escenarios se consideraron tres parámetros críticos en los procesos de decisión planteados en la estructura, los parámetros tenidos en cuenta fueron: vulnerabilidad de las ubicaciones candidatas para ser albergues temporales, vulnerabilidad vial frente a un evento sísmico y la cantidad de afectados. Las entradas dadas por el usuario para este caso son: la magnitud y profundidad del sismo, índice de desarrollo humano y la densidad poblacional a considerar para la ciudad de Bucaramanga.

Como consecuencia de la incertidumbre asociada a los desastres, es determinante la planificación eficaz de las operaciones dentro de las etapas del ciclo de la gestión de desastres. Muchas de las decisiones en este ciclo deben ser tomadas con anticipación o poco después de que ocurre un evento, lo que hace posible que la toma de decisiones esté sujeta a errores. El análisis de escenarios es recomendable para este tipo de contextos donde son necesarias herramientas de planeación para las actividades de respuesta, que permitan la generación de escenarios de un evento catastrófico con la mayor exactitud posible a través de características razonables y de fácil acceso. Parámetros críticos en los procesos de decisión planteados en el apartado 5 se encuentran, d_j demanda del nodo cliente j , r_i vulnerabilidad del albergue i y r_{ij} la vulnerabilidad asociada al arco (i, j) ; la estimación de cada uno de estos parámetros se describen a continuación

6.1. Demanda del nodo cliente

El parámetro demanda d_j , representa la cantidad de afectados en el nodo de demanda j , para este caso se ha considerado un nivel de desagregación de manzana censal tenidas en cuenta en el

censo nacional del 2005 (DANE). En el desarrollo del modelo para la estimación de la demanda, se plantea dos submodelos, el primero de estos realizará una estimación global del parámetro, es decir la cantidad de afectados para la ciudad de Bucaramanga, el segundo corresponde a la identificación de la vulnerabilidad asociada a cada manzana censal con el fin de desagregar la cantidad global de afectados en los niveles mas altos de vulnerabilidad.

Datos históricos fueron considerados en el desarrollo del modelo de cantidad de afectados totales para la ciudad de Bucaramanga, consolidados a partir de los registros proporcionados por el Centro de Investigación sobre la Epidemiología del Desastre (CRED), Banco Mundial (WB) y el Centro Geológico de Estados Unidos (USGS). La cantidad de afectados fue tomada de la base de datos EM-Dat, a cada registro se asociaron las características de densidad y HDI del país de ocurrencia de la base de datos del WB, la profundidad y magnitud del sismo fueron tomadas de los archivos del USGS considerando solo el registro con mayor magnitud en la fecha y zona de ocurrencia del desastre. Un total de 440 registros fueron consolidados, el conjunto de datos fue dividido en 352 registros de entrenamiento y 88 registros de prueba. Los datos de entrenamiento se usaron para la construcción tres modelos de regresión: regresión lineal múltiple, máquinas de soporte vectorial y redes neuronales artificiales, mientras que los datos de prueba permitieron evaluar la eficiencia de los modelos.

Un análisis preliminar de los datos de entrenamiento permitió sugerir una transformación de la variable de estudio. De acuerdo a lo mostrado en la figura 8, una prueba Box-Cox sugiere una transformación de tipo $\ln(y)$ es decir $\lambda = 0$. La evaluación del desempeño de cada modelo

propuesto a través de la raíz del error cuadrado medio RMSE en los conjuntos de prueba y entrenamiento es presentada en la figura 9, en esta se encuentra que el modelo con mejor desempeño en los conjuntos de prueba es el modelo de regresión de máquinas de soporte vectorial SVR, pero los resultados son equivalentes al modelo lineal sin interacciones. Por lo tanto, el modelo lineal sin interacciones es elegido para la estimación de la cantidad de afectados y a su vez es comparado con los modelos presentados en (Rodriguez et al., 2011), mostrando un mejor desempeño que los modelos presentados en este último trabajo, a través de la medida del error absoluto promedio de validación VAAE ver figura 10.

Figura 8
Prueba Box-Cox




Figura 9
RMSE conjuntos de prueba y entrenamiento





Figura 10
VAAE conjuntos de prueba lineal y (Rodriguez et al., 2011)



La vulnerabilidad asociada a los nodos clientes correspondientes a las manzanas censales de la ciudad es estimada a partir de características asociadas al tipo de construcción, condiciones físicas y distancia a fallas activas de la zona, un resumen de estas se presenta en la tabla 7. Una vez realizado el levantamiento de información se encuentran 3.071 manzanas de estos se realizó un muestreo aleatorio simple de 50 individuos, esta muestra fue etiquetada por un experto en cinco niveles de vulnerabilidad (1 muy bajo, 2 bajo, 3 medio, 4 alto, 5 muy alto), a partir de ésta muestra se evalúan tres modelos de clasificación múltiple a través de un procedimiento 10-folds distribuyendo 80% y 20% de los individuos para los conjuntos de entrenamiento y prueba respectivamente. Dentro de los modelos evaluados se encuentran: árbol de decisiones, máquinas de soporte vectorial y redes neuronales artificiales. Las medidas promedio del porcentaje de malas clasificaciones en conjuntos de prueba es presentado en la figura 11. El modelo con menor error de clasificación promedio fue el de árboles de decisión; en la figura 12 se presenta los resultados de este modelo para la ciudad de Bucaramanga.

Tabla 7

Resumen de variables de nodos clientes

Característica	Fuente	Descripción
Perfil de construcción	(Maldonado Rondón & Chio Cho, 2011)	Porcentaje de construcción según el tipo de construcción distribuido en las siguientes clases: tapia, mampostería, pórtico menor a 3 niveles, pórtico de 4 a 7 niveles, pórtico mayor a 8 niveles, muro estructural.
Distancia a fallas	Consejo municipal para la gestión del riesgo – Bucaramanga	Mínima distancia euclidiana entre el albergue y cada una de las fallas de: Chimita, Rio surata y Bucaramanga.
Pertenencia a una zona de amenaza o relleno	Consejo municipal para la gestión del riesgo – Bucaramanga	Pertenencia o no a una zona de Derrumbes, Caída de rocas, Remoción de masas o rellenos antrópicos o mecánicos.
Vulnerabilidad	Criterio de experto	Nivel de vulnerabilidad distribuida en 5 niveles (1 muy baja, 2 baja, 3 media, 4 alta, 5 muy alta)

Figura 11
Porcentaje de mala clasificación en un conjunto de prueba
comparación % mala clasificación


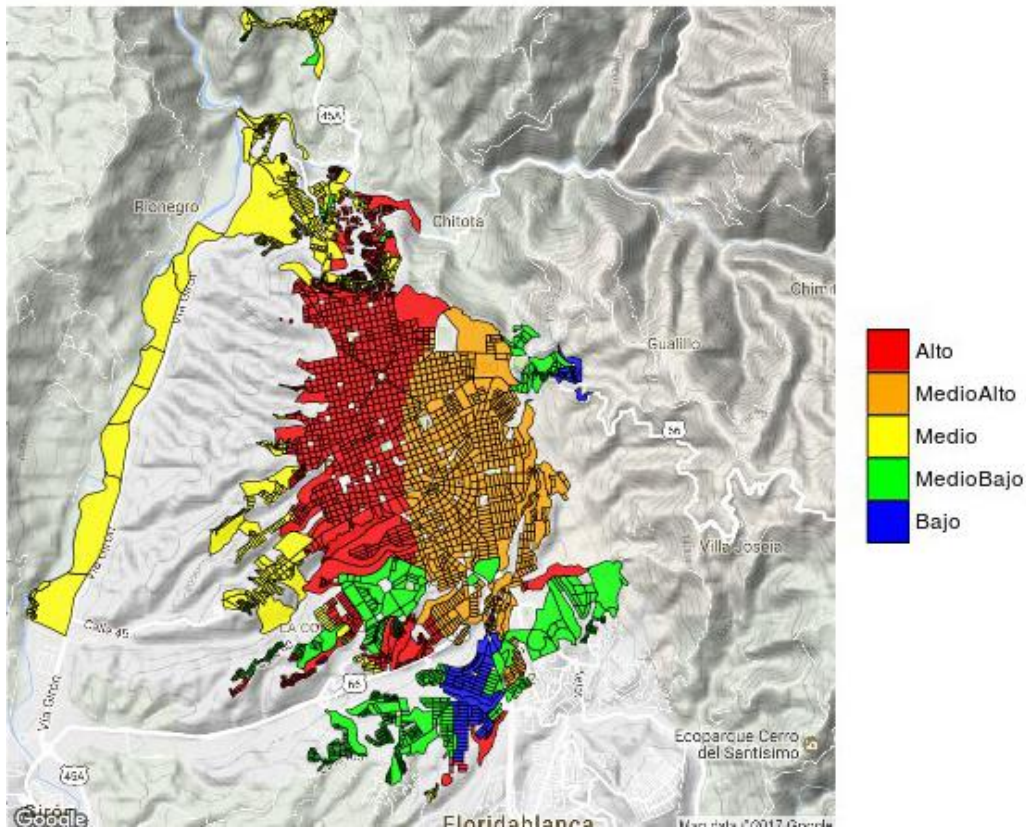


Figura 12
Resultados de clasificación para la ciudad de Bucaramanga
Vulnerabilidad Sísmica



6.2. Vulnerabilidad de los albergues

La estimación del parámetro r_i , la vulnerabilidad del albergue i , se lleva a cabo mediante el método de k-medias. Las características consideradas en el modelo de agrupamiento son descritas en la tabla 8 para un conjunto de 73 registros. La cantidad óptima de grupos a seleccionar se obtuvo mediante el método elbow (figura 13), la solución sugirió elegir 5 niveles de vulnerabilidad, adicionalmente para determinar la combinación de distancia y el algoritmo que genere la mayor separación de grupos (medida con el porcentaje de la suma de cuadrados entre grupos sobre la total) para el conjunto de datos se evaluaron distintas variantes para el algoritmo k-medias y métricas de distancia (tabla 9), la evaluación de las diferentes combinaciones permitió determinar que la mejor combinación para el conjunto de datos fue la distancia Maximun y algoritmo Hartigan-Wong. De acuerdo a los centroides de cada cluster se asignó un nivel de vulnerabilidad (tabla 10).

Tabla 8
Resumen de variables para los albergues

Característica	Descripción
Tipo de albergue	Clasificación de cada albergue en las siguientes clases: educativo, zona verde y polideportivo.
Tipo de construcción	Clasificación del albergue en las siguientes clases: tapia, mampostería confinada, mampostería no confinada, pórtico, muro estructural, estructura metálica y ninguno.
Años de construcción	Año de construcción del albergue.
Niveles	Numero de niveles o pisos de la edificación.
Distancia a fallas	Mínima distancia euclidiana entre el albergue y cada una de las fallas de: Chimita, Rio surata y Bucaramanga.
Pertenencia a una zona de amenaza o relleno	Pertenencia o no a una zona de Derrumbes, Caída de rocas, Remoción de masas o rellenos antrópicos o mecánicos.

Figura 13
Resultados del método elbow




Tabla 9
Porcentaje correspondiente a la SS entre grupos relativo a la SS total

<i>Algoritmos\Distancia</i>	<i>Euclidiana</i>	<i>Máximum</i>	<i>Manhattan</i>	<i>Minkowski</i>
Hartigan-Wong	0.74	0.81	0.79	0.74
Lloyd	0.72	0.80	0.74	0.64
Forgy	0.71	0.53	0.78	0.67
MacQueen	0.74	0.60	0.79	0.69

Tabla 10
Descripción de clusters

<i>Cluster</i>	<i>Observaciones</i>	<i>Vulnerabilidad asociada</i>
1	<i>Colegios, cerca de fallas, en rellenos y media remoción de masa, tipo de construcción mampostería y pórtico dúctil.</i>	3
2	<i>Colegios, cerca de fallas, alta remoción de masa, tipo de construcción mampostería.</i>	4

<i>Cluster</i>	<i>Observaciones</i>	<i>Vulnerabilidad asociada</i>
3	<i>Parques y Polideportivos</i>	<i>1</i>
4	<i>Colegios, pórtico no dúctil, en ninguna zona de amenaza.</i>	<i>2</i>
5	<i>Colegios, cerca de fallas, en zona de amenaza en rellenos, tipo de construcción tapia y mampostería no confinada</i>	<i>5</i>

6.3. Vulnerabilidad de los arcos

Para la estimación del parámetro r_{ij} , la vulnerabilidad asociada al arco (i, j) se utilizó un modelo de clustering particional de k-medias. Debido a que los arcos para los cuales se contempla la vulnerabilidad son los arcos del problema de ruteo de vehiculos el modelo k-medias es aplicado a conjunto de 5402 (correspondientes a 73 albergues y un centro de distribución) registros para los cuales se levantaron características relacionadas con el tipo de construcciones abyacentes esperado, la pertenencia o no a una zona de riesgo y la distancia a fallas activas (tabla 11). La cantidad de clusters óptimo se seleccionó utilizando el metodo elbow (figura 14), proporcionando una solución de 5 clusters. Por otro lado, para la elección de la variante del algoritmo k-medias y la metrica de distancia a utilizar se evaluaron diferentes combinaciones y se evaluó en cada una de estas el porcentaje de SS entre cluster respecto a la SS total dando como resultado un empate para la metrica de distancia “maximun” en las variantes de “Hartigan-Wong”, “Lloyd” y “Macqueen” (tabla 12) para la aplicación fue elegida la variante “Hartigan-Wong”, los centroides de cada cluster fueron analizados y a cada uno de estos se les asignó un nivel de vulnerabilidad como se muestra en la tabla 13.

Tabla 11

Resumen de característica para los arcos

Característica	Descripción
Perfil de construcción promedio	Porcentaje de construcción promedio según el tipo de construcción distribuido en las siguientes clases: tapia, mampostería, pórtico menor a 3 niveles, pórtico de 4 a 7 niveles, pórtico mayor a 8 niveles, muro estructural.
Distancia a fallas	Mínima distancia euclidiana entre el albergue y cada una de las fallas de: Chimita, Rio surata y Bucaramanga.
Pertenencia a una zona de amenaza o relleno	Pertenencia o no a una zona de Derrumbes, Caída de rocas, Remoción de masas o rellenos antrópicos o mecánicos.

Figura 14

Resultados del método elbow

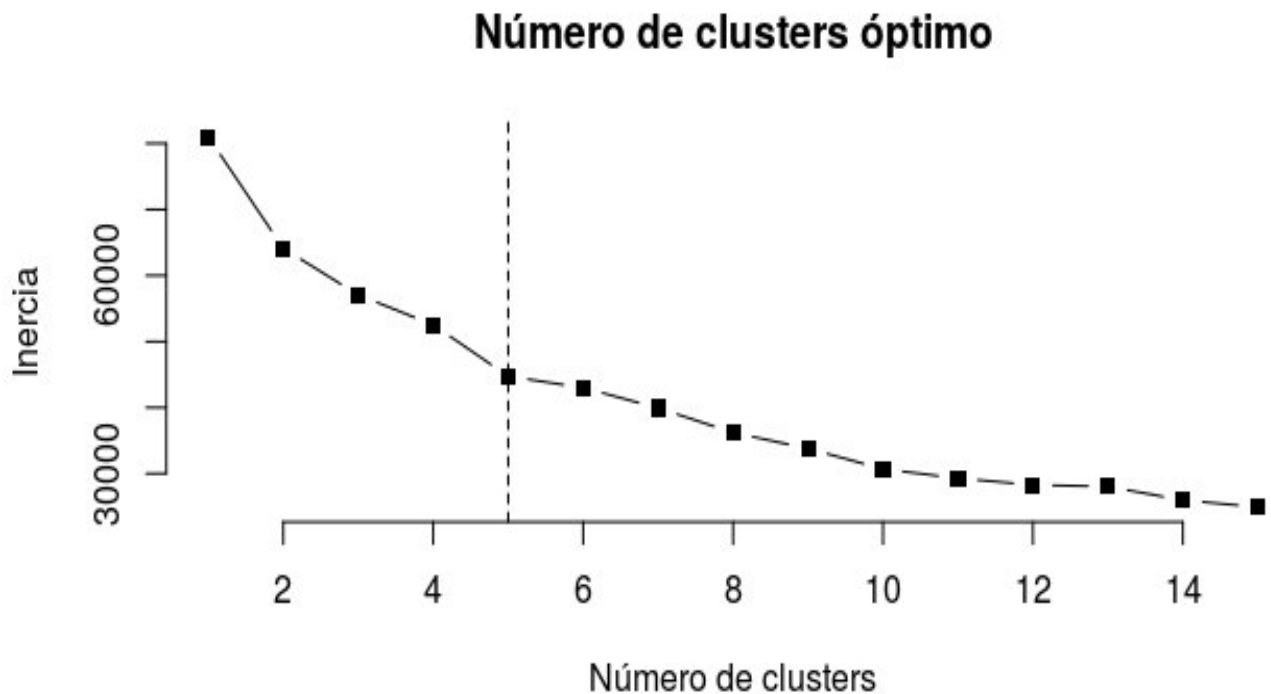


Tabla 12

Porcentaje correspondiente a la SS entre grupos relativo a la SS total

Algoritmos/Distancia	Euclidiana	Máximo	Manhattan	Minkowski
Hartigan-Wong	0.56	0.68	0.60	0.57
Lloyd	0.57	0.68	0.59	0.57
Forgy	0.57	0.67	0.52	0.57
Macqueen	0.57	0.68	0.53	0.57

Tabla 13

Resumen del análisis de centroides por cluster

Cluster	Observaciones	Vulnerabilidad
1	Cerca de fallas activas, en áreas de alta remoción de masa, deslizamientos y reptaciones, edificaciones de mampostería, pórtico de concreto o acero y muro estructural.	5
2	Lejos de fallas, en áreas de alta y media remoción de masa, tipologías de mampostería y muro estructural	2
3	Cerca de fallas, en áreas de alta y media remoción de masa, todas las tipologías menos tapia.	4
4	Lejos de fallas, alta remoción de masa y rellenos, mampostería y muro estructural	1
5	Cerca de fallas, en áreas de rellenos, estructuras de tapia, pórticos y muro estructural.	3

7. UNIDAD II: LOCALIZACIÓN DE ALBERGUES Y ASIGNACIÓN DE AFECTADOS

La selección de albergues temporales, es decir la selección de los lugares que deben ser adecuados para ofrecer refugio a personas afectadas debido a un desastre puede ser abordado como un Problema de Localización de Instalaciones o FLP por sus siglas en inglés. Un FLP consiste en encontrar un subconjunto de instalaciones a partir de un conjunto de instalaciones posibles persiguiendo objetivos tales como la minimización de los tiempos de desplazamiento de clientes a las instalaciones abiertas, las distancias entre los clientes y las instalaciones habilitadas, los costos de apertura y de transporte. Los objetivos están sujetos al cumplimiento de condiciones del contexto tales como capacidad de las instalaciones, criterios de dependencia entre las instalaciones entre otros.

Una vez ocurrido el evento sísmico, es importante llevar a cabo algunas operaciones con el fin de afrontar la emergencia, dentro de estas se deben tener en cuenta la definición de rutas de evacuación, atención de las víctimas. Para el caso de la planificación de la emergencia el conocimiento de la adecuada asignación de la población afectada a cada albergue temporal habilitado es el punto de partida para la planeación de actividades de evacuación, atención de víctimas, distribución de recursos, entre otras. La solución conjunta del problema de la selección de las instalaciones y la asignación de clientes a las mismas es una variante del FLP conocida como Problema de Localización y Asignación de Instalaciones (FLA).

Dentro de las aplicaciones del FLP en la gestión de desastres se han considerado objetivos tales como: costos (Khayal et al., 2015), tiempos de viajes (Altay, 2012), confiabilidad de las

instalaciones (Akgün, Gümüşbuğa, & Tansel, 2015), entre otros. En el presente trabajo se propone, un modelo de FLA con restricciones de capacidad (CFLA) para apoyar los procesos de toma de decisiones de selección de albergues temporales y planificación de la emergencia. A continuación, se detalla la formulación del modelo:

Índices

i Ubicaciones candidatas

j Nodos Cliente

Parámetros

d_j Demanda del cliente j

h_{ij} Distancia entre el albergue i y el cliente j

C_i Capacidad del albergue i

r_i Vulnerabilidad del albergue i

VARIABLES DE DECISIÓN

X_{ij} 1 si el cliente i es servido por el albergue j , 0 en otro caso

Y_i 1 si el albergue i es habilitado, 0 en otro caso

Ecuaciones

$$\text{Minimizar } f_1 = \sum_{i=1}^m \sum_{j=1}^n h_{ij} \times X_{ij} \quad (17)$$

$$\text{Minimizar } f_2 = \sum_{i=1}^m r_i \times Y_i \quad (18)$$

Sujeto a.

$$\sum_{i=1}^m X_{ij} = 1 \quad \forall j \quad (19)$$

$$X_{ij} \leq Y_i \quad \forall i, j \quad (20)$$

$$\sum_{j=1}^n d_i \times X_{ij} \leq C_i \times Y_i \quad \forall i \quad (21)$$

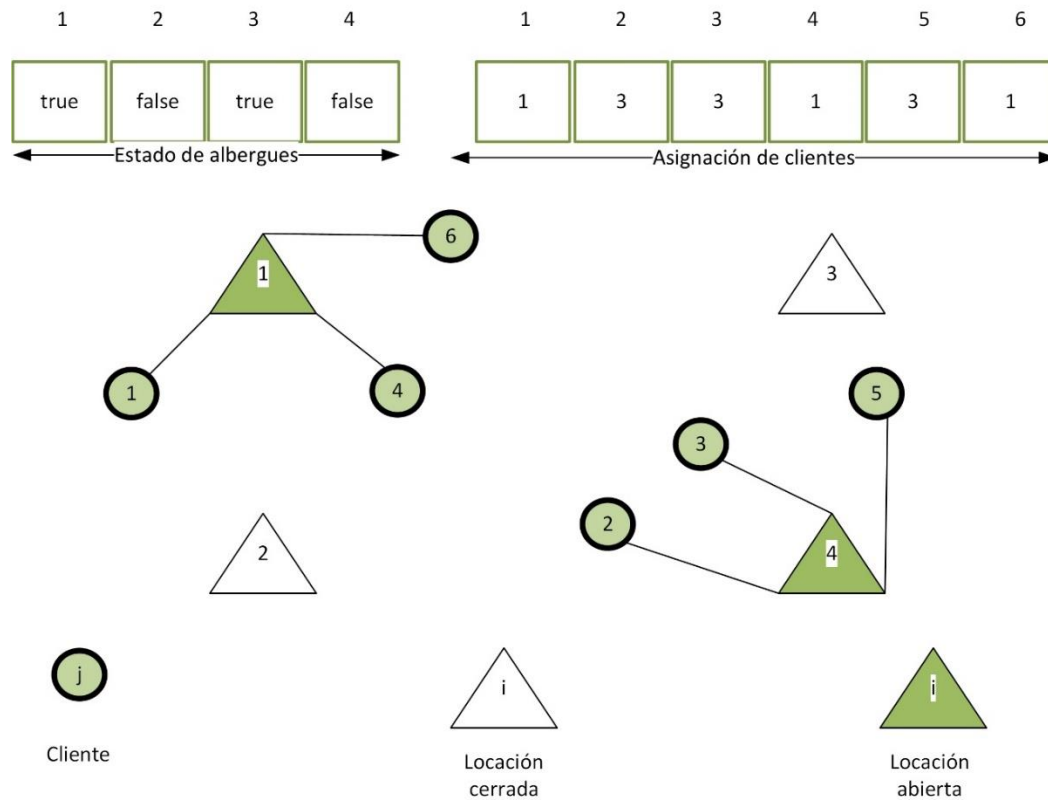
Las ecuaciones (17) y (18) representan las funciones objetivo, que corresponden a la distancia total de viaje de la población afectada a los albergues temporales y la vulnerabilidad total de los albergues habilitados respectivamente. La ecuación (19) hace que cada cliente sea asignado a un único albergue, (20) asegura la asignación de los nodos clientes a los albergues habilitados y la restricción (21) asegura que la capacidad de cada albergue no sea excedida.

Esta unidad involucra la solución del problema de optimización multiobjetivo de localización-asignación, planteado en las ecuaciones (17-21) bajo el escenario dado por la unidad de generación de escenarios y presentar las soluciones de este al usuario. La generación de soluciones de compromiso está dada por un algoritmo genético elitista de ordenamiento no-dominado de segunda generación NSGA-II; el algoritmo de solución planteado en este trabajo es basado de (Aguilar, 2016). elementos como la estructura de la solución, el procedimiento para la generación de la población inicial y operadores genéticos de cruce y mutación son descritos en las secciones siguientes:

7.1. Estructura de la solución

La codificación de las soluciones consiste en un cromosoma de dos sub cadenas, como se muestra en la figura 15. La primera sub cadena consta de un arreglo lógico que corresponde al estado de los m locaciones candidatas, donde el valor de la i -ésima posición indica si la locación es habilitada como albergue (valor true) o no (valor false). Esta sub cadena corresponde a la variable Y_i presentada en el problema de optimización planteado en el modelo (17-21). La segunda sub cadena corresponde a la asignación de n clientes a los albergues habilitados, la j -ésima posición indica que albergue ha sido asignado al cliente j , esta segunda sub cadena corresponde a las parejas (i, j) en donde la variable X_{ij} es igual a 1.

Figura 15
 Codificación de la solución ejemplo 4 locaciones 6 clientes



Fuente: Adaptado de Aguilar, (2016)

7.2. Generación de la población inicial

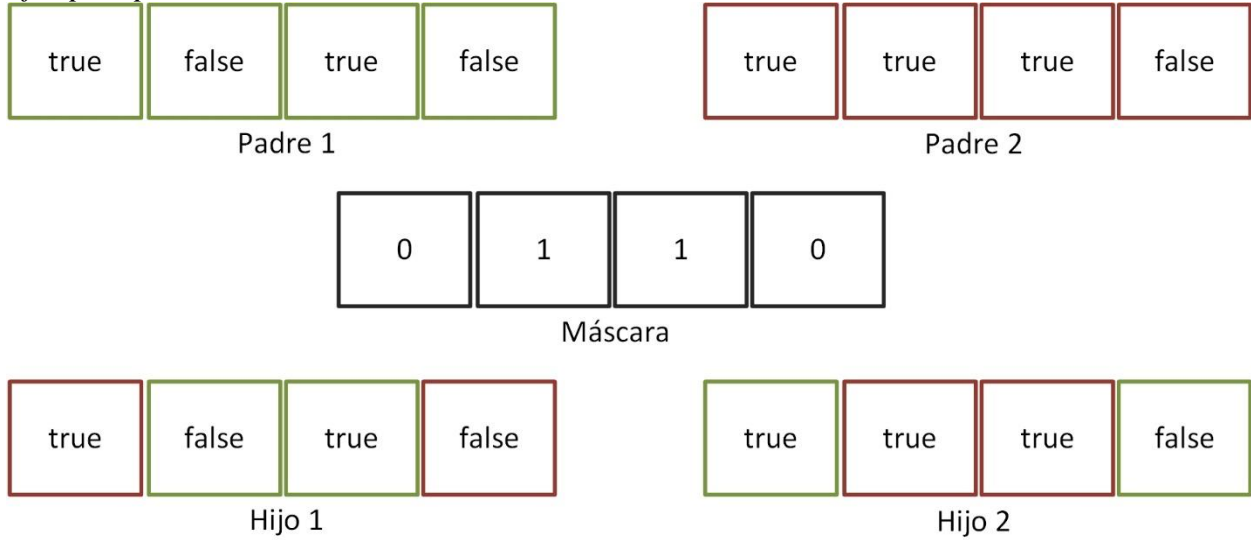
La generación de la población inicial fue tomada como aleatoria, inicialmente la sub cadena de estado de albergues es generada. Una vez generada esta sub cadena la condición de capacidad total mayor a la demanda total es verificada, en el caso de no cumplirse esta condición locaciones son habilitadas aleatoriamente hasta cumplir este criterio. A partir de la sub cadena de albergues habilitados se asignan aleatoriamente los clientes a cada albergue abierto verificando el cumplimiento de la restricción de capacidad $\sum_{j=1}^n d_i \times X_{ij} \leq C_i \times Y_i \quad \forall i$.

7.3. Operadores genéticos

Dos operadores genéticos han sido propuestos para la generación de las poblaciones descendientes Q_t , estos operadores son aplicados a la sub cadena de estado de los albergues, el primero de estos es un operador de cruce llamado operador de máscara binaria el cual genera un arreglo aleatorio de unos y ceros el cual determina que elemento del padre 1 es asignado al hijo 1 (caso 1) y que elemento del padre 2 es asignado al hijo 1 (caso 0), el segundo hijo es generado de forma contraria al hijo 1 de acuerdo a los valores de la máscara, un ejemplo de esto se presenta en la figura 16. El segundo operador genético corresponde a un operador de cambio de bit, este solo es aplicado en el caso de que la sub cadena de estado de albergues del hijo i sea idéntica al padre i , este operador consiste en seleccionar un albergue de forma aleatoria y abrirlo o cerrarlo a partir del valor original como se muestra en la figura 17.

Figura 16

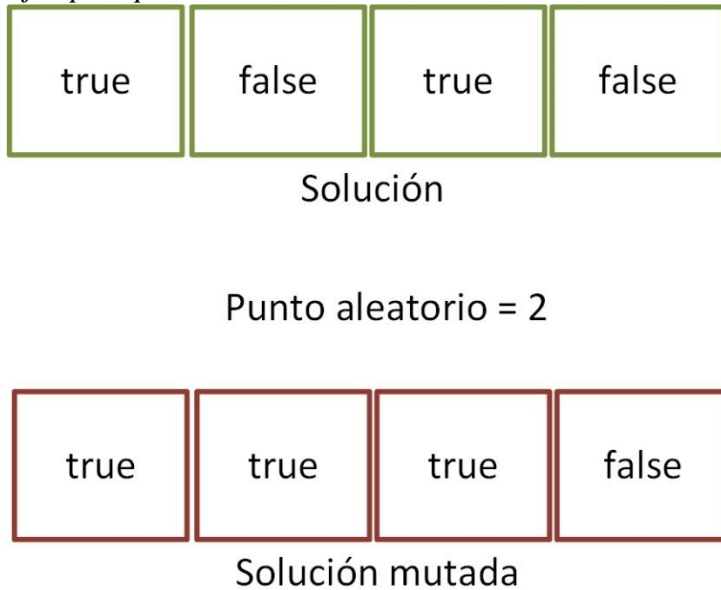
Ejemplo operador de mascara binaria



Fuente: adaptado de Aguilar, (2016)

Figura 17

Ejemplo operador cambio de bit



Fuente: Adaptado de Contreras & Martínez, (2016)

7.4. Evaluación de rendimiento

Con el fin de evaluar el desempeño del algoritmo propuesto, este fue probado con un caso real con el generador de escenarios para un caso de sismo con una magnitud de 8.0, una profundidad de 4 km, un índice de desarrollo humano 0.7 y una densidad poblacional de 30.47. Las métricas de desempeño escogidas fueron la cardinalidad del frente 1, el mínimo y máximo para cada objetivo por cada generación, los resultados para 1000 generaciones y un tamaño de población de 50 se presentan en las figuras 18-20. Los valores de las funciones objetivos dadas por el algoritmo después de 1000 iteraciones se muestran en la figura 21. Los resultados muestran que el algoritmo genera más soluciones en el frente 1 y adicionalmente que estas son mejores teniendo valores más bajos, especialmente para el objetivo de vulnerabilidad.

Figura 18
Resumen de cardinalidad del frente 1 por generación




Figura 19
Distancia por generación




Figura 20
Vulnerabilidad por generación


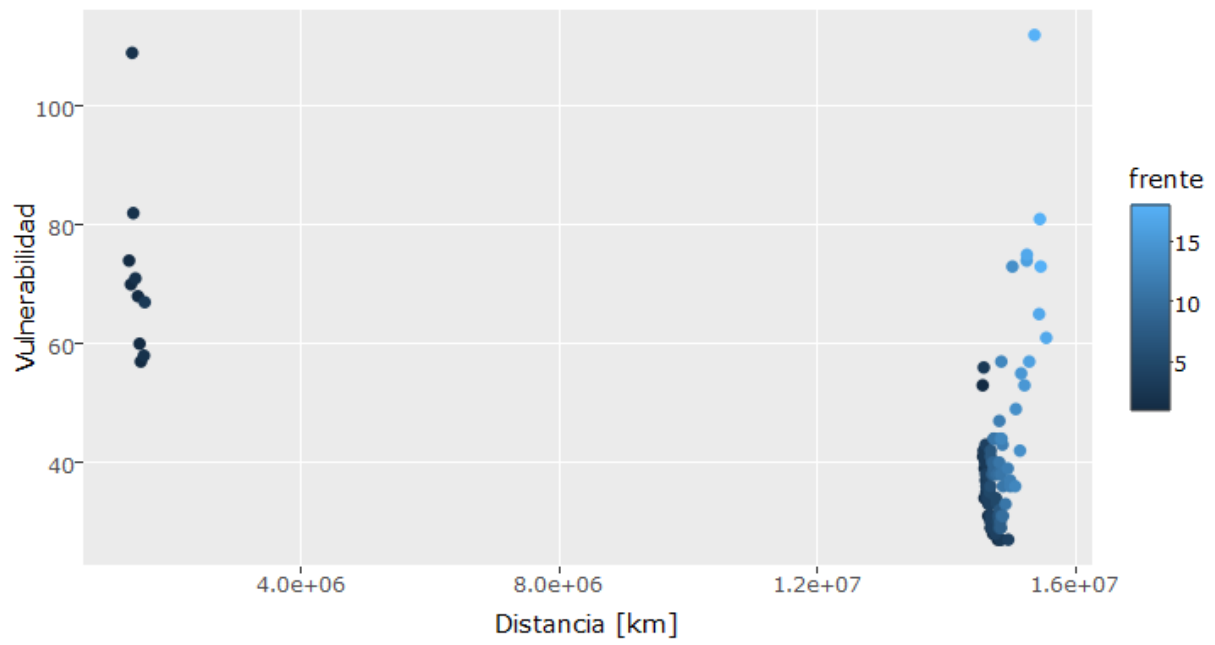


Figura 21

Soluciones para 1000 generaciones

Soluciones para 1000 generaciones



8. UNIDAD III: DISTRIBUCIÓN DE AYUDAS HUMANITARIAS

Investigaciones del Problema de Ruteo de Vehículos (VRP) han sido aplicadas al contexto de distribución de ayudas humanitarias, que tienen en cuenta realidades como variaciones de multiproducto (Akgün et al., 2015; Hu, 2011; Najafi et al., 2014), multiperiodo (Huang et al., 2013; Wohlgenuth, Oloruntoba, & Clausen, 2012), multideposito (B. Vitoriano et al., 2011; Begoña Vitoriano, Ortuno, & Tirado, 2009) y combinaciones de las anteriores (Adivar & Mert, 2010). La eficiencia y el desempeño de la atención de las víctimas no solo depende de la capacidad utilizada de los vehículos y la longitud de las rutas, otros factores tales como la incertidumbre de la disponibilidad de las rutas una vez ocurrido el sismo se deben considerar (Barbarosoğlu & Arda, 2004). Por lo anterior, un modelo de un problema de ruteo de vehículos capacitado bi-objetivo es propuesto, permitiendo la minimización de la distancia de viaje y la vulnerabilidad de las rutas seleccionadas. Este modelo es presentado en las ecuaciones (22-30)

Índices

i, j Nodos de la red

k Vehículos

Parámetros

d_i Demanda del albergue i

d_{ij} Distancia para el arco (i, j)

C Capacidad del vehículo

r_{ij} Vulnerabilidad del arco (i, j)

VARIABLES DE DECISIÓN

X_{ijk} 1 si el arco (i, j) es usado por el vehículo k , 0 en otro caso

Y_{ik} 1 si el albergue i es visitado por el vehículo k , 0 en otro caso

Ecuaciones

$$\text{Minimizar } f_1 = \sum_{i=0}^m \sum_{j=0}^n \sum_{k=1}^K d_{ij} \times X_{ijk} \quad (22)$$

$$\text{Minimizar } f_2 = \sum_{i=0}^n \sum_{j=0}^n \sum_{k=1}^K r_{ij} \times X_{ijk} \quad (23)$$

Sujeto a.

$$\sum_{k=1}^K \sum_{i=0}^n X_{ijk} = 1 \quad \forall j \quad (24)$$

$$\sum_{k=1}^K \sum_{j=0}^n X_{ijk} = 1 \quad \forall i \quad (25)$$

$$\sum_{i=0}^n X_{itk} - \sum_{j=0}^n X_{tjk} = 0 \quad \forall k, t \quad (26)$$

$$\sum_{i=1}^n d_i \times Y_{ik} \leq C \quad \forall k \quad (27)$$

$$\sum_{i \in S} \sum_{j \notin S} X_{ijk} \geq Y_{hk} \quad \forall S \subseteq V, h \in S, k \quad (28)$$

$$\sum_{j=1}^n X_{0jk} \leq 1 \quad \forall k \quad (29)$$

$$\sum_{i=1}^n X_{i0k} \leq 1 \quad \forall k \quad (30)$$

Las funciones (22) y (23) representan las funciones objetivo, las cuales corresponden a la minimización de la distancia de viaje y la vulnerabilidad de las rutas seleccionadas

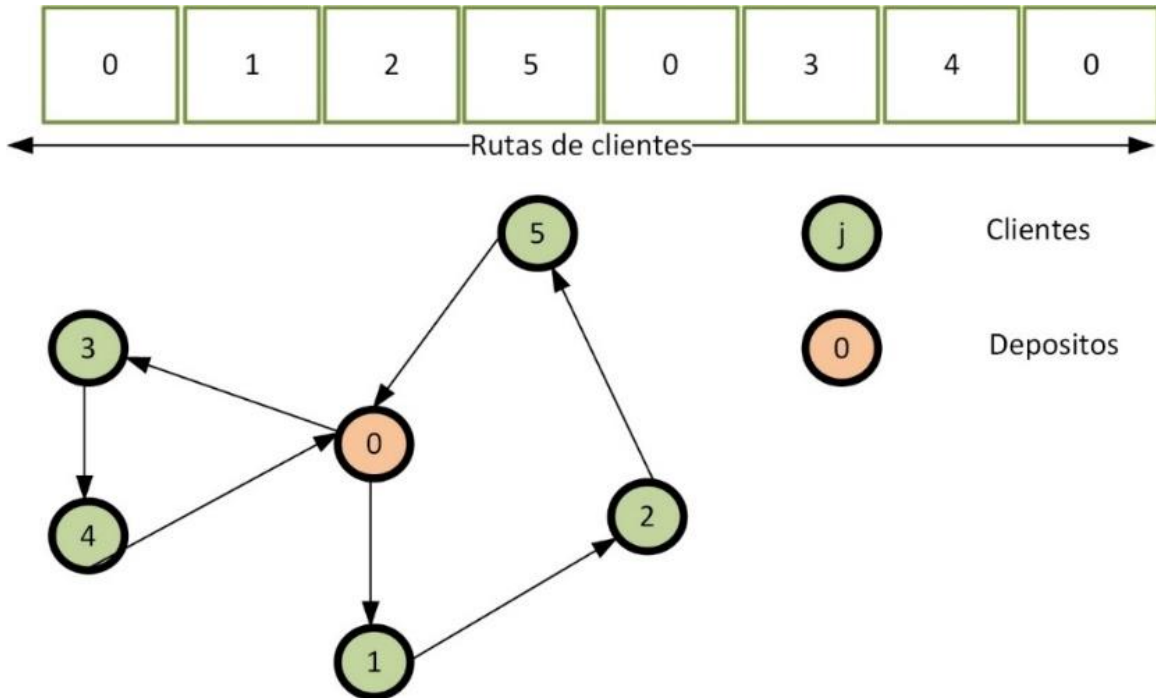
respectivamente. Las ecuaciones (24-26) corresponden a las restricciones de flujo, la restricción (27) asegura que la capacidad del vehículo no sea excedida, la ecuación (28) es conocida como restricción de eliminación de subtours. Las ecuaciones (29-30) aseguran que cada ruta inicie y termine en el nodo de depósito.

Esta unidad involucra la solución del problema de optimización multiobjetivo de ruteo de vehículos capacitado descrito en las ecuaciones (22-30), el cual da soluciones de compromiso al proceso de decisión de distribución de ayudas humanitarias. Las soluciones fueron obtenidas a través de un algoritmo genético de ordenamiento no dominado elitista de segunda generación NSGA-II la estructura de la solución, generación de la población inicial y los operadores genéticos utilizados se describen a continuación.

8.1. Estructura de la solución

La solución del ruteo es representada por una permutación de clientes dividiendo cada ruta por ceros, representando la partida y regreso al depósito. Un ejemplo de solución es presentado en la figura 22, en esta se describe la secuencia de visita para 5 clientes con dos rutas la primera ruta indica la visita de los clientes 1, 2 y 5 en ese orden y para la segunda ruta los clientes 3 y 4, cada dupla de elementos consecutivos en el cromosoma corresponde a los valores de (i, j) para los cuales la variable $X_{ijk} = 1$ de la ruta k correspondiente.

Figura 22
Estructura de la solución MCVRP



Fuente: Adaptado de Barrera & Hernández, (2016)

8.2. Generación de la población inicial

La generación de la población inicial fue completamente aleatoria verificando el cumplimiento de la restricción de capacidad del vehículo $\sum_{i=1}^n d_i \times Y_{ik} \leq C \quad \forall k$. La asignación aleatoria de clientes se realiza hasta no exceder la capacidad del camión, en este caso se asigna este cliente a otra ruta, así hasta asignar todos los clientes.

8.3. Operadores genéticos

Los operadores genéticos utilizados consisten en un operador de cruce de orden (OX) adaptado del problema del agente viajero TSP (figura 23). En el caso de generar hijos iguales a los padres se utiliza un operador de mutación de intercambio y reverso, descritos en las figuras 24 y 25 respectivamente.

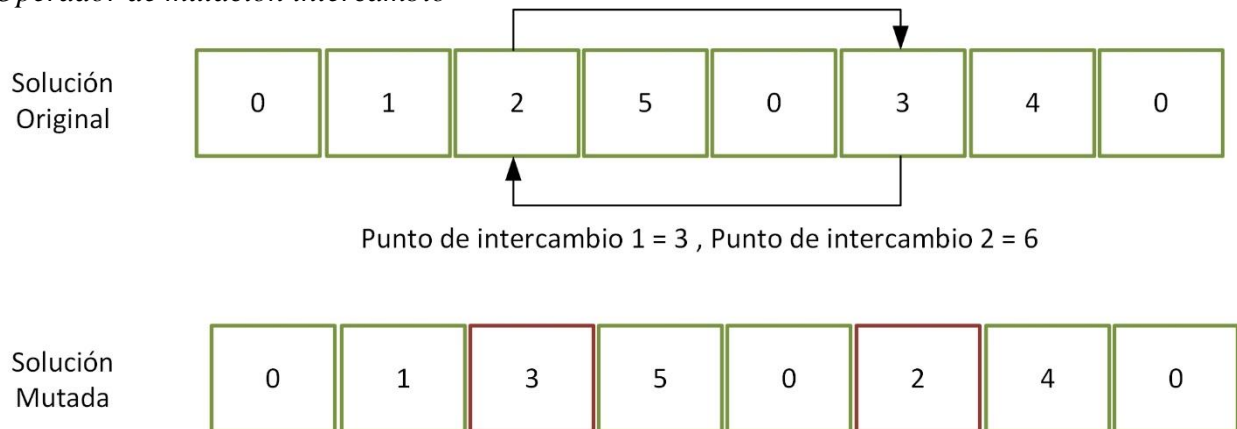
El operador de cruce OX toma aleatoriamente una ruta del cromosoma, esta ruta hará parte del hijo correspondiente y los espacios restantes se completarán con los elementos del cromosoma padre homólogo en el orden de aparición siempre y cuando no haya sido elegido en los elementos heredados directamente. Para el caso del operador de mutación intercambio elige dos puntos aleatorios de la solución y realiza el cambio de los valores en el cromosoma. Por otro lado, el operador reverso selecciona una ruta en particular e invierte el orden de visita de los clientes que en esta se encuentren.

Figura 23
Operador de cruce OX



Fuente: Adaptado de Puljić & Manger, (2013)

Figura 24
Operador de mutación intercambio



Fuente: Adaptado de Barrera & Hernández, (2016)

Figura 25
Operador de mutación reverso



Fuente: Adaptado de Barrera & Hernández, (2016)

8.4.Evaluación del desempeño

Con el fin de evaluar el desempeño del algoritmo propuesto, este fue probado con un caso real el cual corresponde a la primera solución generada por el caso propuesto en la unidad anterior, las medidas propuestas para esta evaluación fueron el tamaño del frente 1 a lo largo de las

generaciones (figura 26), los máximos y mínimos de cada objetivo figura 27 y 28; además los frentes obtenidos para una corrida con un tamaño de población 50 y 1000 generaciones figura 29, es presentado.

Los resultados indican que a lo largo de las generaciones el tamaño del frente 1 disminuye debido a la inclusión de mejores soluciones lo que se traduce en variaciones en los valores mínimos para la distancia y la vulnerabilidad. En el caso de las soluciones presentadas se puede observar el efecto de la selección elitista mostrando dos grupos representativos, los cuales representan a los individuos a ser incluidos en la siguiente generación y los que no siendo estos notablemente distantes uno del otro.

Figura 26
Cardinalidad de frente 1 por generación




Figura 27
Distancia por generación




Figura 28
Vulnerabilidad por generación





Figura 29

Soluciones para generaciones



9. RESULTADOS

Las unidades descritas en los apartados 6,7 y 8 fueron consolidadas en un prototipo el cual fue desarrollado como una aplicación web, junto con las fuentes de información utilizadas para la generación de escenarios. Actualmente este se encuentra disponible en el dominio <http://dssdmbucaramanga.uis.edu.co:8080>, en la figura 30 se muestra la interfaz de la aplicación. En la interfaz de la aplicación se presentan tres opciones principales: Albergues temporales, Población y Planeador logístico. El prototipo desarrollado permite la consulta de información relevante en los procesos de decisión planteados (Albergues y Población) y a su vez dar solución de compromiso para estos (Planeador Logístico).

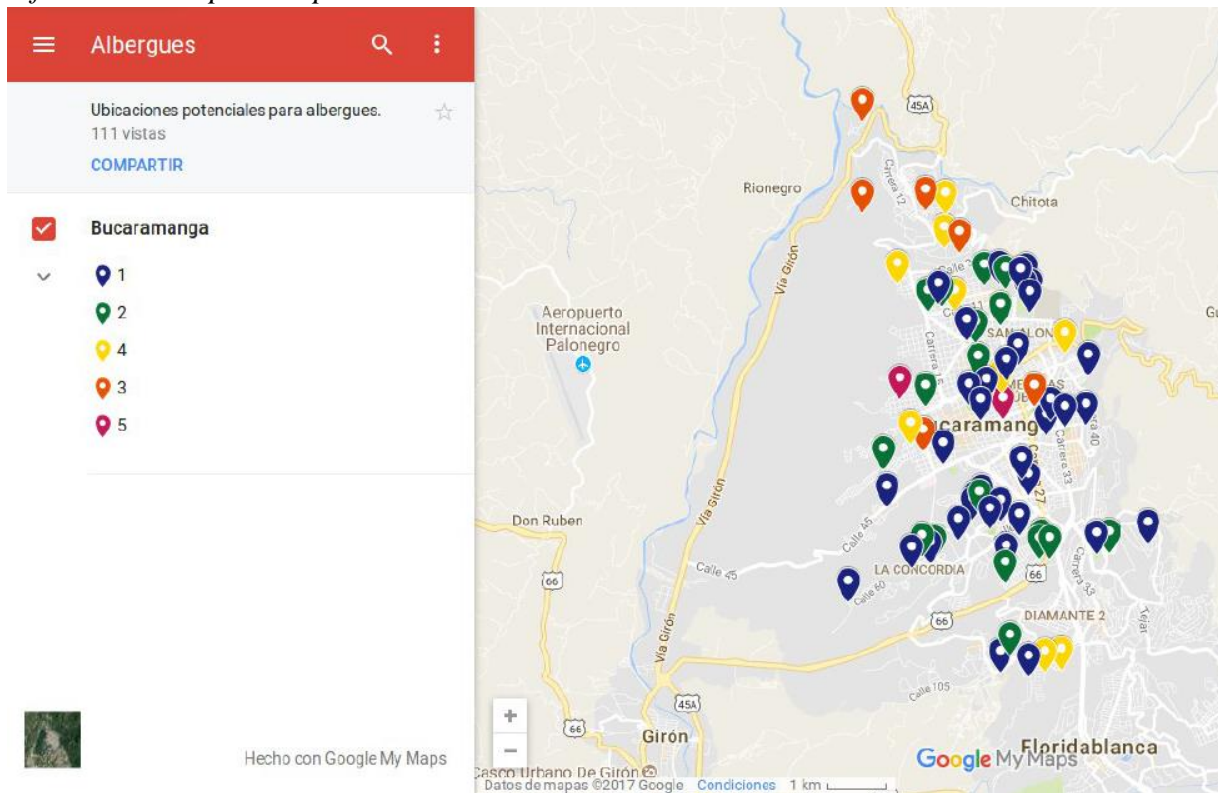
Figura 30
Interfaz de la herramienta desarrollada



9.1. Albergues

Esta opción permite al usuario acceder a la información de los albergues candidatos después de la ocurrencia de un desastre, esta información fue levantada y consolidada en el sistema de información geográfico Google maps figura 31². Dentro de esta se puede encontrar parámetros de capacidad y vulnerabilidad asociada a cada locación candidata.

Figura 31
Información disponible para las ubicaciones candidatas



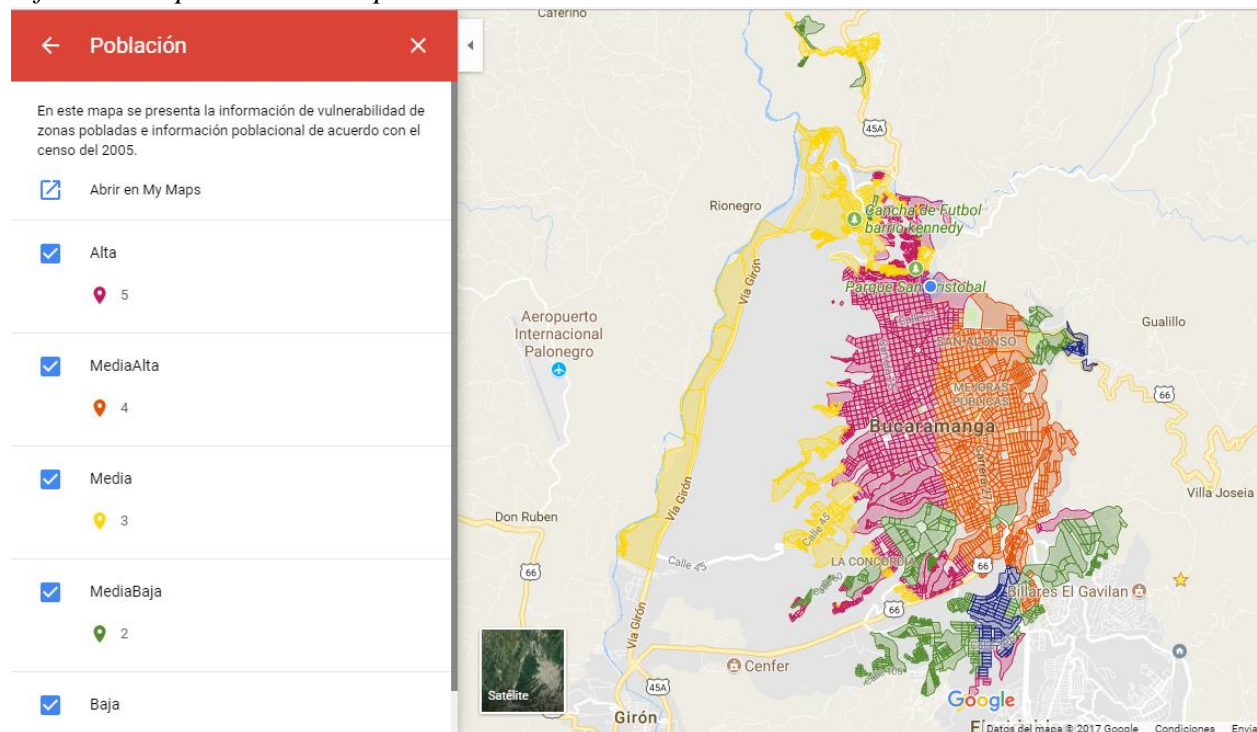
² Disponible en: <https://drive.google.com/open?id=1LtsPTb0iY9dpLhePvoa6w8vdHFW&usp=sharing>

9.2.Población

De forma análoga a los albergues temporales la información poblacional se encuentra disponible para la consulta, esta información fue levantada y consolidada en el sistema de información geográfico Google maps figura 32³. Dentro de esta se encuentran parámetros de vulnerabilidad y cantidad de personas asociada a cada manzana.

Figura 32

Información poblacional disponible



9.3.Planeador logístico

La opción de planeador logístico permite al usuario obtener soluciones de compromiso para los procesos de selección de albergues y asignación de afectados a estos, y para la distribución de

³ Disponible en: https://drive.google.com/open?id=1P_-W_G3vP9j-Qolgrdsdjgr8BN8&usp=sharing

LOGÍSTICA HUMANITARIA

ayudas humanitarias. Esta opción se divide en tres etapas la primera es el generador de escenario figura 33, selección de albergues y asignación de la población afectada figura 34 y finalmente la distribución de ayudas humanitarias figura 35.

Figura 33

Interfaz generador de escenarios

Escenario

Generador de escenarios

Digite la magnitud entre 4 - 10

Digite la profundidad

Digite el indice de desarrollo entre 0 - 1

Digite la densidad poblacional

ATRAS SIGUIENTE

Figura 34

Interfaz selección de albergues y asignación de afectados

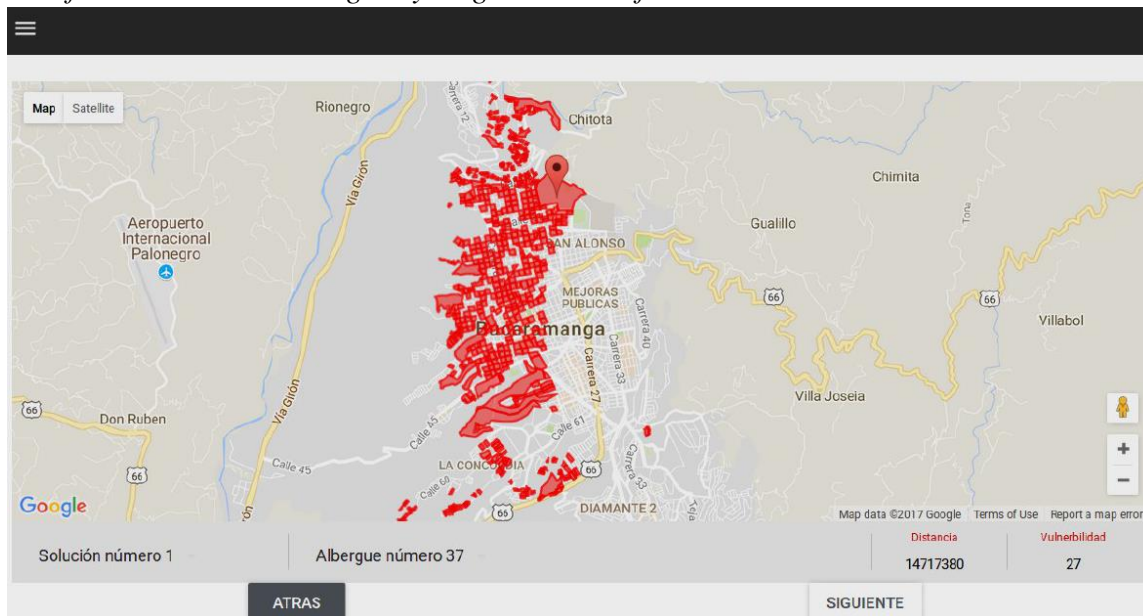
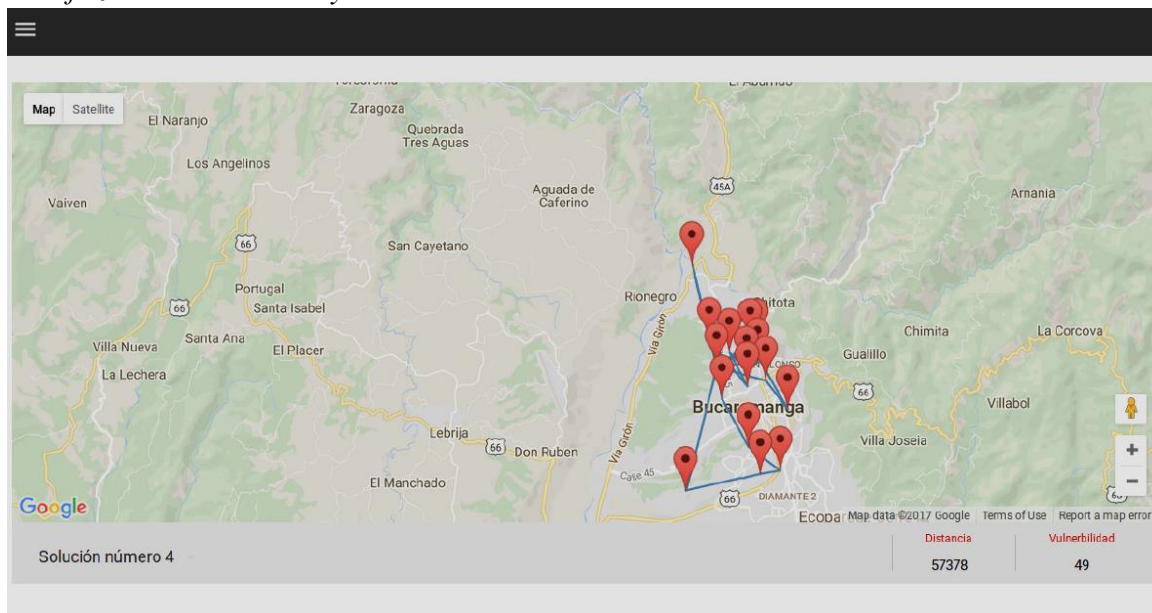


Figura 35
Interfaz distribución de ayudas humanitarias



Cada interfaz fue concebida para cada unidad propuesta en los apartados 6, 7 y 8, la interfaz de generador de escenarios corresponde a la unidad 6 en esta el usuario puede configurar las características del escenario a generar estas se resumen en la magnitud (MI) y profundidad del sismo (Km), índice de desarrollo humano y densidad poblacional (personas/Km²), a partir de estos parámetros la cantidad de afectados es estimada y a su vez desagregada a nivel de manzanas teniendo en cuenta la vulnerabilidad de cada manzana. La información de afectados por manzana es almacenada y tenida en cuenta para las etapas siguientes. La siguiente interfaz presentada al usuario permite al usuario la selección de albergues y asignación de afectados la cual corresponde a la unidad descrita en el apartado 7, en esta interfaz se presentan las soluciones de compromiso teniendo en cuenta los objetivos de vulnerabilidad de albergues y la distancia total de las rutas de las manzanas afectadas a los albergues habilitados.

Una vez el usuario elige una solución de compromiso esta será el insumo para la siguiente unidad; la siguiente interfaz corresponde a la distribución de ayudas humanitarias descrita en el apartado 8, esta unidad presenta las soluciones de compromiso para la distribución de ayudas humanitarias teniendo en cuenta una capacidad homogénea de 3040 personas/vehículo tal como se presenta en (Barrera & Hernandez, 2016) ya que se considera un vehículo el cual puede almacenar 608 kits de ayuda humanitaria el cual abastece los requerimientos básicos para un grupo de 5 personas en un periodo de una semana.

10. ANÁLISIS DE RESULTADOS

10.1. Generador de escenarios

En el apartado 6 se desarrollaron modelos de aprendizaje automático supervisado para los parámetros de cantidad de afectados y vulnerabilidad en zonas pobladas, los resultados de dichos modelos fueron contrastados con los resultados de trabajos anteriores tal como se muestran en las figuras 36 y 37. Para el modelo de cantidad de afectados fue comparado con el trabajo de (Rodríguez et al., 2011) a través de la métrica de error del valor absoluto del error medio o VAAE por sus siglas en inglés de esta comparación (figura 36) se encuentra que los modelos de redes neuronales, lineal sin interacciones y máquinas de soporte vectorial presentaron un desempeño superior a los modelos presentados en (Rodríguez et al., 2011). Por otro lado, los modelos de vulnerabilidad de áreas pobladas fueron comparados con el modelo presentado en el trabajo de (Khamespanah, Delavar, Alinia, & Zare, 2013) (figura 37), de estos resultados se encuentra que los modelos de árbol de decisión y máquinas de soporte vectorial son mejores que el modelo presentado por (Khamespanah et al., 2013).

Figura 36
Comparación VAAE

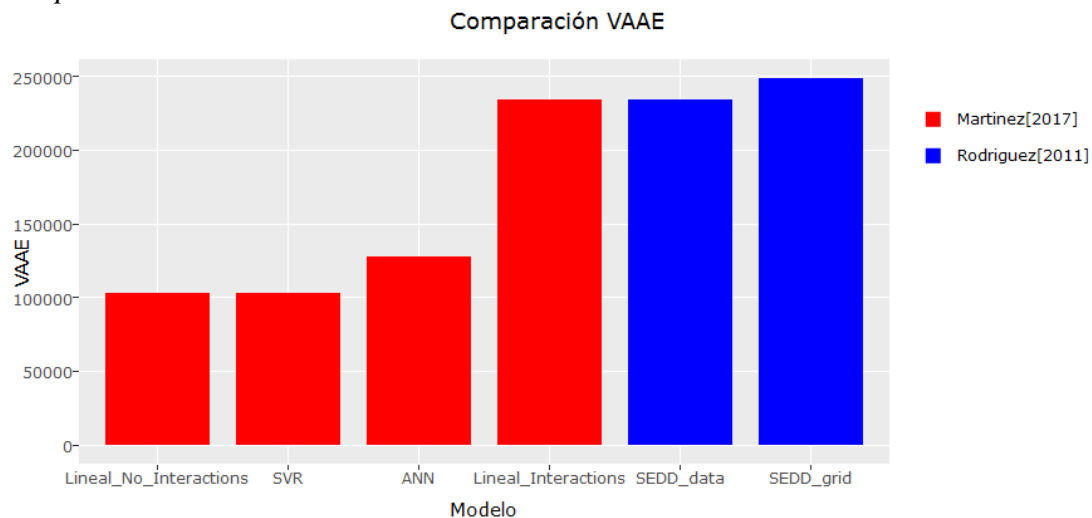



Figura 37

Comparación del porcentaje de mala clasificación

10.2. Localización de albergues temporales y asignación de la población afectada

A partir de los trabajos de (Aguilar, 2016) y (Contreras & Martínez, 2016) se encuentra adecuado utilizar un algoritmo genético de ordenamiento no dominado de segunda generación para la generación de soluciones del problema de localización de albergues temporales y asignación de la población, en estos trabajos se presentan comparaciones con instancias de la literatura las cuales demuestran un rendimiento competitivo. Con el fin de evaluar la consistencia de los datos generados por este algoritmo, se planteó un escenario de prueba a partir del generador de escenarios propuesto en la unidad 6 considerando una magnitud de 8 una profundidad de 4 km, un índice de desarrollo humano 0.7 y una densidad poblacional de 30.47 personas por km cuadrado. En las figuras 38 a 40 se presentan métricas de desempeño del algoritmo por generación y posteriormente en la figura 41 se presenta los resultados de un conjunto de soluciones para un límite de 1000 generaciones y un tamaño de población de 50.

Figura 38
Tamaño del frente 1 MFLA




Figura 39
Valor mínimo de distancia por iteración

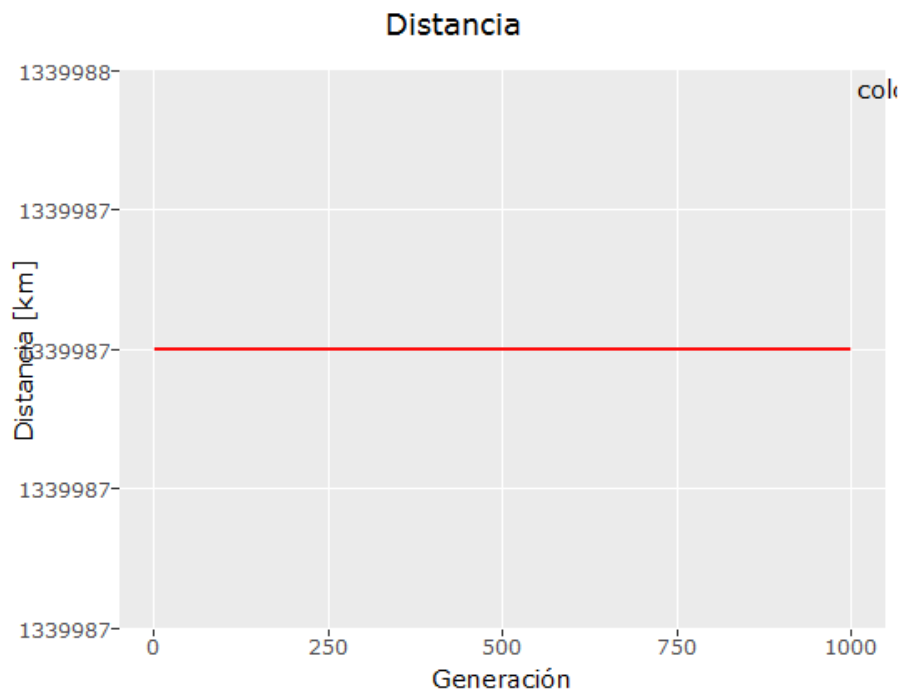


Figura 40
Valor mínimo de vulnerabilidad por generación MFLA
Vulnerabilidad

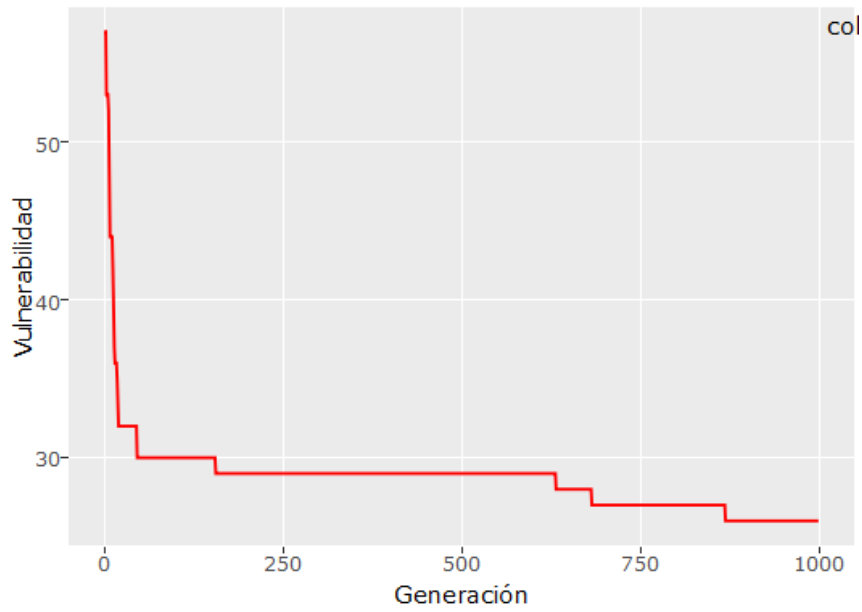



Figura 41
Soluciones para 1000 generaciones MFLA



La cardinalidad del frente 1 por generación (figura 38) permite ver que el algoritmo encontró más soluciones candidatas a pertenecer al frente 1 con el paso de las generaciones y esto debido a que encontró soluciones con mejores medidas de vulnerabilidad que de distancia (figuras 39 y 40). Por otro lado, las soluciones dadas por el algoritmo después de 1000 generaciones (figura 41) permiten encontrar dos grupos, esto puede estar explicado a la mayor intensificación de la búsqueda por el algoritmo en el objetivo de vulnerabilidad que en el de distancia, es por esto que los grupos distan en el eje del objetivo distancia.

10.3. Distribución de ayudas humanitarias

Debido a la complejidad del problema de ruteo de vehículos capacitado este fue solucionado a través de un algoritmo genético de ordenamiento no dominado de segunda generación. Es por esto que se decidió evaluar la consistencia de los resultados del algoritmo a partir de la primera solución dada por la unidad de localización de albergues temporales para el escenario de prueba propuesto en el ítem anterior, con este escenario se evaluó el tamaño del frente 1 por cada generación, el mínimo de las funciones objetivo por generación y finalmente el frente de Pareto dado para el límite de 1000 generaciones, estas medidas son presentadas en las figuras 42 a 45. La cardinalidad del frente 1 por generaciones (figura 42) permite ver que el tamaño de este conjunto decae a lo largo de las generaciones y esto puede estar explicado por la disputa entre los objetivos de distancia y vulnerabilidad a lo largo de las generaciones (figuras 43 y 44), como resultado en las soluciones dadas en la figura 45 se encuentran dos grupos distantes entre sí, pero en igual medida por cada objetivo, diferente al caso del MFLA.

Figura 42
Cardinalidad del frente 1 MCVRP




Figura 43
Valor mínimo de distancia por iteración MCVRP

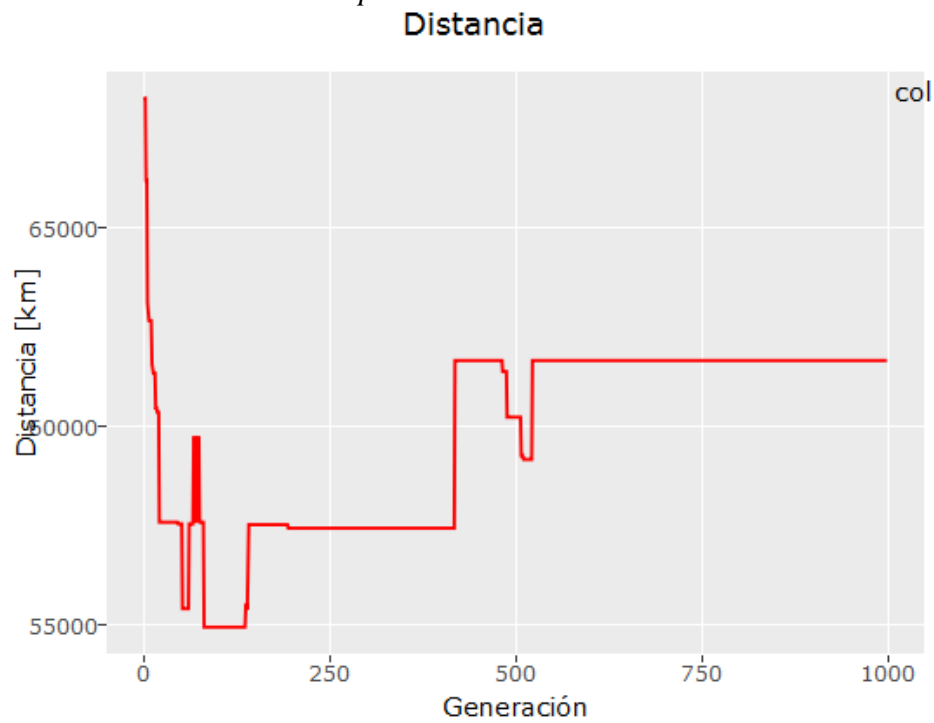


Figura 44
Valor mínimo de vulnerabilidad por generación MCVRP
Vulnerabilidad

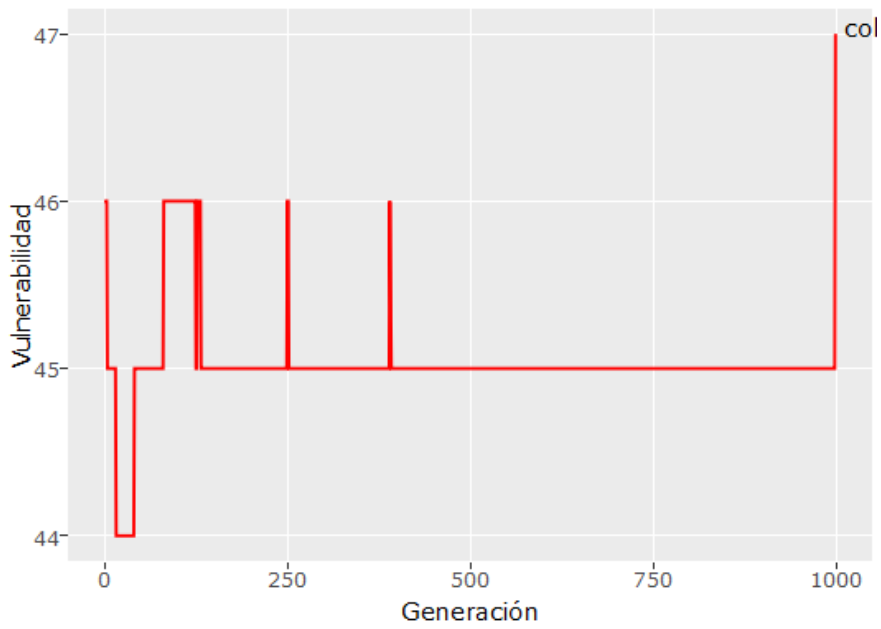



Figura 45
Soluciones para 1000 generaciones MCVRP



10.4. Análisis global

Como se plantea en el trabajo de (Holsapple et al., 2008) un DSS mejorado con técnicas de aprendizaje automático puede agregar características de mayor adaptabilidad y actividad que un DSS basado netamente en modelos. Por consiguiente, el presente trabajo presentó el diseño de un DSS-DM basado en modelos de optimización multiobjetivo mejorado con técnicas de aprendizaje automático, los parámetros para ser generados por técnicas de aprendizaje automático fueron elegidos de acuerdo a las necesidades propuestas en (Altay & Green, 2006; Galindo & Batta, 2013) y a su vez necesidades encontradas en el contexto de la ciudad de Bucaramanga. Estos modelos de aprendizaje automático fueron evaluados en cuanto a desempeño encontrando mejoras respecto a otras aplicaciones encontradas en la literatura, asegurando la calidad de estos parámetros. En el desarrollo de modelos de optimización multiobjetivo debido a aplicaciones anteriores se consideró pertinente la utilización del algoritmo NSGA-II para la generación de soluciones a los modelos planteados.

En los trabajos de (Aguilar, 2016; Barrera & Hernandez, 2016; Barreto & Niño, 2016; Contreras & Martínez, 2016) plantearon problemas de logística humanitaria en contextos de desastres sísmicos para la ciudad de Bucaramanga incluyendo el desarrollo de herramientas que permitieran una adecuada toma de decisiones para cada uno de los problemas propuestos, cada una de estas herramientas requerían que por parte del tomador de decisiones se brindarían parámetros proporcionales a la dimensión de la instancia a evaluar, sumado a esto la incertidumbre asociada a estos parámetros se encontraba directamente relacionada con el nivel de conocimiento del usuario o tomador de decisiones.

El prototipo desarrollado⁴ muestra que la complejidad asignada al tomador de decisiones es constante para cada escenario a considerar debido que para la herramienta desarrollada solo requiere cuatro parámetros de entrada para describir un escenarios (magnitud, profundidad, HDI y densidad) parámetros adicionales como cantidad de personas afectadas, ubicación de estas, vulnerabilidad de los albergues entre son generados automáticamente los cuales en los trabajos anteriormente mencionados eran solicitados al usuario, esto permite un nivel de actividad superior a las herramientas presentadas en los trabajos anteriores mencionados. Por otro lado, el nivel de incertidumbre asociado a los parámetros estimados en el prototipo propuesto en este trabajo fue evaluado y comparado con trabajos previos en aplicaciones similares asegurando un nivel de calidad de los mismos y a su vez independiente del nivel del conocimiento del tomador de decisiones o usuario, haciendo esta herramienta más sensible a cambios del entorno permitiendo un nivel de adaptabilidad superior a las herramientas presentadas en los trabajos anteriores.

⁴ Disponible en: <http://dssdmbucaramanga.uis.edu.co:8080>

11. CONCLUSIONES

En el presente trabajo se propuso el diseño de un Sistema de Apoyo a la Toma de Decisiones para actividades logísticas involucradas en un contexto de desastres sísmicos para la ciudad de Bucaramanga, El diseño presentado combina modelos propios del aprendizaje automático con el fin de determinar parámetros críticos en el contexto de gestión de riesgo de desastres, a partir de estos parámetros se plantearon modelos de optimización multiobjetivo con el fin de brindar soluciones de compromiso a procesos de decisión tales como la selección de albergues temporales, asignación de población afectada a estos y la distribución de ayudas humanitarias.

Dentro de los trabajos revisados se encuentra la importancia de parámetros confiables y de buena calidad para los modelos de optimización encontrados en el campo de investigación de operaciones y utilizados en la toma de decisiones en actividades logísticas humanitaria (Galindo & Batta, 2013). Es por esto que la principal contribución de este trabajo es el desarrollo de una herramienta que utiliza modelos de optimización con parámetros mejorados, permitiendo un ambiente más amigable para un tomador de decisiones y a su vez una representación más fiel del contexto.

La construcción de modelos de aprendizaje supervisado y no supervisado permitieron la comparación de diferentes enfoques y encontrar así un modelo adecuado para cada parámetro estudiado. Sin embargo, el desarrollo de los modelos propuestos partió de características disponibles en estudios pasados las cuales pueden variar a través del tiempo es por esto que se

considera necesario un plan de gestión de datos para que este sistema entre en producción incluyendo procedimientos para la actualización de datos y el re-entrenamiento de los modelos planteados en el caso de ser necesario.

En el desarrollo de los modelos para la estimación de afectados totales para un desastre debido a un sismo se encuentra que este parámetro tiene una relación mayor con la magnitud que con la profundidad del sismo. Por otro lado, las características como la densidad poblacional e índice de desarrollo humano permiten una buena aproximación del nivel de exposición en riesgo y un nivel de vulnerabilidad asociado a las edificaciones, pero al solo encontrarse datos históricos de los promedios por país se recomienda considerar varios valores posibles para una región de estudio ya que los valores reales de las zonas afectadas de los desastres tenidos en cuenta en los registros históricos pueden diferir con el valor promedio del país.

La vulnerabilidad asociada a las manzanas censales permitió identificar zonas de víctimas potenciales, análisis posteriores permitieron encontrar que de acuerdo al censo nacional del 2005 aproximadamente el 32% de la población de Bucaramanga reside en una zona de vulnerabilidad muy alta. Modelos de aprendizaje no supervisado fueron utilizados para las vulnerabilidades de arcos y albergues temporales, en estos se determinó la combinación variante-distancia con la mayor separación entre grupos es decir que la varianza total sea explicada en una mayor proporción por la diferencia entre grupos que por la diferencia de individuos por cada grupo, la utilización de este criterio generó tendencias diversas para ambos parámetros. Sin embargo, al ser un enfoque no supervisado no requiere de un conocimiento a priori, pero puede generar clasificaciones con ruido

debido a que la selección de las categorías se hace de acuerdo a un criterio determinado por el algoritmo de agrupamiento y la métrica de distancia el cual puede ser similar pero no corresponda exactamente al criterio dado por un experto.

El desarrollo de algoritmos genéticos para la generación de soluciones de compromiso para un escenario propuesto permite la evaluación de estas por parte de un tomador de decisiones. Contribuyendo a la reducción de la complejidad del proceso de toma de decisiones sin dejar a un lado el papel del tomador de decisiones en el proceso. Por otro lado, para los modelos de localización asignación y ruteo de vehículos se utilizaron una representación de arcos la cual considera todas las posibles rutas para un origen y destino específico como un único elemento, esto permitió reducir la complejidad al momento de asociar las características necesarias para la estimación de la vulnerabilidad. Para futuras investigaciones se recomienda considerar una representación que permita identificar diferentes sub-rutas y adicionalmente asociar característica de vulnerabilidad a cada una de estas sub-rutas. Adicionalmente para los modelos planteados MFLA y MCVRP se propone evaluar otras funciones asociadas a la vulnerabilidad ya que actualmente permite soluciones con niveles de vulnerabilidad extremos (niveles mínimos y máximos) minimizando el total pero no siendo apropiado para una aplicación real, en el caso particular de los modelos de localización asignación se recomienda también estudiar diferentes funciones de distancia ya que al igual que los objetivos de vulnerabilidad se asignan manzanas afectadas tanto cercanas como lejanas a los albergues habilitados.

Finalmente, como herramienta de toma de decisiones para actividades logística humanitaria, se encuentra adecuado la utilización de modelos de aprendizaje automático con el fin de mejorar parámetros de modelos de optimización multiobjetivo en procesos de decisión propios de la gestión del riesgo de desastres. Por lo tanto, se recomienda en investigaciones futuras aplicar este enfoque para otro tipo de desastres y procesos de decisión, tales como la programación de actividades de búsqueda y rescate, gestión de inventarios, entre otras.

12. REFERENCIAS

- Abounacer, R., Rekik, M., & Renaud, J. (2014). An exact solution approach for multi-objective location–transportation problem for disaster response. *Computers & Operations Research*, *41*, 83-93.
- Adivar, B., & Mert, A. (2010). International disaster relief planning with fuzzy credibility. *Fuzzy Optimization and Decision Making*, *9*(4), 413-433.
- Aguilar, K. (2016). *Un modelo multiobjetivo de localización-ruteo para la planeación logística en la fase de preparación a sismos en Bucaramanga*. (Master en Ingeniería Industrial), Universidad Industrial de Santander.
- Akgün, İ., Gümüşbuğa, F., & Tansel, B. (2015). Risk based facility location by using fault tree analysis in disaster management. *Omega*, *52*, 168-179.
- Aleskerov, F., Say, A. I., Toker, A., Akin, H. L., & Altay, G. (2005). A cluster-based decision support system for estimating earthquake damage and casualties. *Disasters*, *29*(3), 255-276.
- Altay, N. (2012). Capability-based resource allocation for effective disaster response. *IMA Journal of Management Mathematics*, dps001.
- Altay, N., & Green, W. G. (2006). OR/MS research in disaster operations management. *European journal of operational research*, *175*(1), 475-493.
- Amailef, K., & Lu, J. (2013). Ontology-supported case-based reasoning approach for intelligent m-Government emergency response services. *Decision Support Systems*, *55*(1), 79-97. doi: 10.1016/j.dss.2012.12.034
- Arora, N., Raghu, T. S., & Vinze, A. (2010). Resource allocation for demand surge mitigation during disaster response. *Decision Support Systems*, *50*(1), 304-315. doi: 10.1016/j.dss.2010.08.032
- Barbarosoğlu, G., & Arda, Y. (2004). A two-stage stochastic programming framework for transportation planning in disaster response. *Journal of the operational research society*, *55*(1), 43-53.
- Barrera, A., & Hernandez, A. (2016). *Un algoritmo evolutivo para el problema de distribución de recursos post-desastres sísmicos en la ciudad de Bucaramanga*. (Ingeniero Industrial), Universidad Industrial de Santander.
- Barreto, M., & Niño, N. (2016). *Un algoritmo memético para el problema de localización-ruteo con ventanas de tiempo para la atención de desastres sísmicos en la ciudad de Bucaramanga*. (Ingeniera Industrial), Universidad industrial de Santander, Bucaramanga Santander. Retrieved from <http://tangara.uis.edu.co/biblioweb/tesis/2016/165444.pdf>
- Bonczek, R. H., Holsapple, C. W., & Whinston, A. B. (1981). *Foundations of decision support systems*: Academic Press.
- Burstein, F., & Carlsson, S. A. (2008). Decision support through knowledge management *Handbook on Decision Support Systems 1* (pp. 103-120): Springer
- Cimellaro, G. P., Scura, G., Renschler, C., Reinhorn, A., & Kim, H. (2014). Rapid building damage assessment system using mobile phone technology. *Earthquake Engineering and Engineering Vibration*, *13*(3), 519-533.
- Contreras, M., & Martínez, A. (2016). *Un problema de localización multiobjetivo en la fase de preparación para desastres por sismos en la ciudad de Bucaramanga*. (Ingeniero Industrial), Universidad Industrial de Santander.
- Chacko, J., Rees, L. P., Zobel, C. W., Rakes, T. R., Russell, R. S., & Ragsdale, C. T. (2016). Decision support for long-range, community-based planning to mitigate against and recover from potential multiple disasters. *Decision Support Systems*, *87*, 13-25. doi: 10.1016/j.dss.2016.04.005
- Chae, J., Thom, D., Jang, Y., Kim, S., Ertl, T., & Ebert, D. S. (2014). Public behavior response analysis in disaster events utilizing visual analytics of microblog data. *Computers & Graphics-Uk*, *38*, 51-60. doi: 10.1016/j.cag.2013.10.008
- Chio, G., & Maldonado, E. (2007). *Vision Estructural De Las Edificaciones De La Ciudad De Bucaramanga*.
- De Maio, C., Fenza, G., Gaeta, M., Loia, V., & Orciuoli, F. (2011). A knowledge-based framework for emergency DSS. *Knowledge-Based Systems*, *24*(8), 1372-1379. doi: 10.1016/j.knosys.2011.06.011

- Dias, A. H., & De Vasconcelos, J. A. (2002). Multiobjective genetic algorithms applied to solve optimization problems. *IEEE Transactions on Magnetics*, 38(2), 1133-1136.
- Döyen, A., Aras, N., & Barbarosoğlu, G. (2012). A two-echelon stochastic facility location model for humanitarian relief logistics. *Optimization Letters*, 6(6), 1123-1145.
- Duda, K. A., & Abrams, M. (2012). Aster satellite observations for international disaster management. *Proceedings of the IEEE*, 100(10), 2798-2811.
- Fogli, D., & Guida, G. (2013). Knowledge-centered design of decision support systems for emergency management. *Decision Support Systems*, 55(1), 336-347. doi: 10.1016/j.dss.2013.01.022
- Galindo, G., & Batta, R. (2013). Review of recent developments in OR/MS research in disaster operations management. *European Journal of Operational Research*, 230(2), 201-211.
- Garrido, R. A., Lamas, P., & Pino, F. J. (2015). A stochastic programming approach for floods emergency logistics. *Transportation research part E: logistics and transportation review*, 75, 18-31.
- Gerke, M., & Kerle, N. (2011). Automatic structural seismic damage assessment with airborne oblique Pictometry© imagery. *Photogrammetric Engineering & Remote Sensing*, 77(9), 885-898.
- Holguín-Veras, J., Jaller, M., Van Wassenhove, L. N., Pérez, N., & Wachtendorf, T. (2012). On the unique features of post-disaster humanitarian logistics. *Journal of Operations Management*, 30(7-8), 494-506. doi: <http://dx.doi.org/10.1016/j.jom.2012.08.003>
- Holsapple, C. W. (2008). DSS architecture and types *Handbook on Decision Support Systems 1* (pp. 163-189): Springer
- Holsapple, C. W., Jacob, V. S., Pakath, R., & Zaveri, J. S. (2008). Adaptive Decision Support Systems via Problem Processor Learning *Handbook on Decision Support Systems 1* (pp. 659-696): Springer
- Horita, F. E. A., de Albuquerque, J. P., Degrossi, L. C., Mendiondo, E. M., & Ueyama, J. (2015). Development of a spatial decision support system for flood risk management in Brazil that combines volunteered geographic information with wireless sensor networks. *Computers & Geosciences*, 80, 84-94. doi: 10.1016/j.cageo.2015.04.001
- Hristidis, V., Chen, S. C., Li, T., Luis, S., & Deng, Y. (2010). Survey of data management and analysis in disaster situations. *Journal of Systems and Software*, 83(10), 1701-1714. doi: 10.1016/j.jss.2010.04.065
- Hu, Z.-H. (2011). A container multimodal transportation scheduling approach based on immune affinity model for emergency relief. *Expert Systems with Applications*, 38(3), 2632-2639.
- Huang, M., Smilowitz, K. R., & Balcik, B. (2013). A continuous approximation approach for assessment routing in disaster relief. *Transportation Research Part B: Methodological*, 50, 20-41.
- Jin, D., & Lin, J. (2011). Managing tsunamis through early warning systems: A multidisciplinary approach. *Ocean & Coastal Management*, 54(2), 189-199.
- Kadri, F., Chaabane, S., & Tahon, C. (2014). A simulation-based decision support system to prevent and predict strain situations in emergency department systems. *Simulation Modelling Practice and Theory*, 42, 32-52. doi: 10.1016/j.simpat.2013.12.004
- Khamespanah, F., Delavar, M. R., Alinia, H. S., & Zare, M. (2013). Granular Computing and Dempster-Shafer Integration in Seismic Vulnerability Assessment *Intelligent Systems for Crisis Management* (pp. 147-158): Springer
- Khayal, D., Pradhananga, R., Pokharel, S., & Mutlu, F. (2015). A model for planning locations of temporary distribution facilities for emergency response. *Socio-Economic Planning Sciences*, 52, 22-30.
- Lassiter, K., Khademi, A., & Taaffe, K. M. (2015). A robust optimization approach to volunteer management in humanitarian crises. *International Journal of Production Economics*, 163, 97-111.
- Leonelli, M., & Smith, J. Q. (2015). Bayesian decision support for complex systems with many distributed experts. *Annals of Operations Research*, 235(1), 517-542. doi: 10.1007/s10479-015-1957-7
- Liao, Z. L., Wang, B., Xia, X. W., & Hannam, P. M. (2012). Environmental emergency decision support system based on Artificial Neural Network. *Safety Science*, 50(1), 150-163. doi: 10.1016/j.ssci.2011.07.014
- MacQueen, J. (1967). 5th Berkeley symposium on mathematical statistics and probability. *Berkeley, CA*.

- Maldonado Rondón, E., & Chio Cho, G. (2011). Estimación de las funciones de vulnerabilidad sísmica en edificaciones en tierra. *Revista Científica Ingeniería y Desarrollo*, 25(25).
- McCoy, J. H., & Brandeau, M. L. (2011). Efficient stockpiling and shipping policies for humanitarian relief: UNHCR's inventory challenge. *OR spectrum*, 33(3), 673-698.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- Mhaske, S. Y., & Choudhury, D. (2010). GIS-based soil liquefaction susceptibility map of Mumbai city for earthquake events. *Journal of Applied Geophysics*, 70(3), 216-225.
- Najafi, M., Eshghi, K., & de Leeuw, S. (2014). A dynamic dispatching and routing model to plan/re-plan logistics activities in response to an earthquake. *OR spectrum*, 36(2), 323-356.
- Najafi, M., Eshghi, K., & Dullaert, W. (2013). A multi-objective robust optimization model for logistics planning in the earthquake response phase. *Transportation Research Part E: Logistics and Transportation Review*, 49(1), 217-249.
- Naji-Azimi, Z., Renaud, J., Ruiz, A., & Salari, M. (2012). A covering tour approach to the location of satellite distribution centers to supply humanitarian aid. *European Journal of Operational Research*, 222(3), 596-605.
- Nappi, R., Alessio, G., Bronzino, G., Terranova, C., & Vilardo, G. (2008). Contribution of the SISCam Web-based GIS to the seismotectonic study of Campania (Southern Apennines): an example of application to the Sannio-area. *Natural Hazards*, 45(1), 73-85.
- Nolz, P. C., Doerner, K. F., & Hartl, R. F. (2010). Water distribution in disaster relief. *International Journal of Physical Distribution & Logistics Management*, 40(8-9), 693-708. doi: 10.1108/09600031011079337
- Omidvari, M., Mansouri, N., & Nouri, J. (2015). A pattern of fire risk assessment and emergency management in educational center laboratories. *Safety science*, 73, 34-42.
- Onan, K., Ülengin, F., & Sennaroglu, B. (2015). An evolutionary multi-objective optimization approach to disaster waste management: A case study of Istanbul, Turkey. *Expert Systems with Applications*, 42(22), 8850-8857.
- Ortuño, M. T., Tirado, G., & Vitoriano, B. (2011). A lexicographical goal programming based decision support system for logistics of Humanitarian Aid. *Top*, 19(2), 464-479.
- Papadopoulou, I. D., Savvaiddis, P., & Tziavos, I. N. (2011). Using the SyNaRMa system as a disaster management tool. *Natural Hazards*, 57(2), 453-464.
- Qiu, J. N., Wang, Z. Q., Ye, X., Liu, L. L., & Dong, L. L. (2014). Modeling method of cascading crisis events based on merging Bayesian Network. *Decision Support Systems*, 62, 94-105. doi: 10.1016/j.dss.2014.03.007
- Rachaniotis, N. P., Dasaklis, T. K., & Pappis, C. P. (2012). A deterministic resource scheduling model in epidemic control: A case study. *European Journal of Operational Research*, 216(1), 225-231.
- Rakes, T. R., Deane, J. K., Rees, L. P., & Fetter, G. M. (2014). A decision support system for post-disaster interim housing. *Decision Support Systems*, 66, 160-169. doi: 10.1016/j.dss.2014.06.012
- Rath, S., & Gutjahr, W. J. (2014). A math-heuristic for the warehouse location-routing problem in disaster relief. *Computers & Operations Research*, 42, 25-39.
- Ratner, B. (2011). *Statistical and machine-learning data mining: Techniques for better predictive modeling and analysis of big data*: CRC Press.
- Rodriguez, J. T., Vitoriano, B., & Montero, J. (2010). A natural-disaster management DSS for Humanitarian Non-Governmental Organisations. *Knowledge-Based Systems*, 23(1), 17-22. doi: 10.1016/j.knosys.2009.07.009
- Rodriguez, J. T., Vitoriano, B., & Montero, J. (2012). A general methodology for data-based rule building and its application to natural disaster management. *Computers & Operations Research*, 39(4), 863-873. doi: 10.1016/j.cor.2009.11.014
- Rodriguez, J. T., Vitoriano, B., Montero, J., & Kecman, V. (2011). A disaster-severity assessment DSS comparative analysis. *Or Spectrum*, 33(3), 451-479. doi: 10.1007/s00291-011-0252-5
- Rolland, E., Patterson, R. A., Ward, K., & Dodin, B. (2010). Decision support for disaster management. *Operations Management Research*, 3(1-2), 68-79. doi: 10.1007/s12063-010-0028-0

- Romanowski, C., Raj, R., Schneider, J., Mishra, S., Shivshankar, V., Ayengar, S., & Cueva, F. (2015). Regional response to large-scale emergency events: Building on historical data. *International Journal of Critical Infrastructure Protection*, 11, 12-21. doi: 10.1016/j.ijcip.2015.07.003
- Sahebjamnia, N., Torabi, S. A., & Mansouri, S. A. (2015). Integrated business continuity and disaster recovery planning: Towards organizational resilience. *European Journal of Operational Research*, 242(1), 261-273. doi: 10.1016/j.ejor.2014.09.055
- Shan, S. Q., Wang, L., Li, L., & Chen, Y. (2012). An emergency response decision support system framework for application in e-government. *Information Technology & Management*, 13(4), 411-427. doi: 10.1007/s10799-012-0130-0
- Srinivas, N., & Deb, K. (1994). Multiobjective optimization using nondominated sorting in genetic algorithms. *Evolutionary computation*, 2(3), 221-248.
- Taskin, S., & Lodree, E. (2011). A Bayesian decision model with hurricane forecast updates for emergency supplies inventory management. *Journal of the Operational Research Society*, 62(6), 1098-1108.
- Taubenböck, H., Goseberg, N., Setiadi, N., Lämmel, G., Moder, F., Oczipka, M., . . . Strunz, G. (2009). "Last-Mile" preparation for a potential disaster—Interdisciplinary approach towards tsunami early warning and an evacuation information system for the coastal city of Padang, Indonesia. *Natural hazards and earth system sciences*, 9(4), 1509-1528.
- Tralli, D. M., Blom, R. G., Zlotnicki, V., Donnellan, A., & Evans, D. L. (2005). Satellite remote sensing of earthquake, volcano, flood, landslide and coastal inundation hazards. *ISPRS Journal of Photogrammetry and Remote Sensing*, 59(4), 185-198.
- Vitoriano, B., Ortuno, M. T., Tirado, G., & Montero, J. (2011). A multi-criteria optimization model for humanitarian aid distribution. *Journal of Global Optimization*, 51(2), 189-208. doi: 10.1007/s10898-010-9603-z
- Vitoriano, B., Ortuno, T., & Tirado, G. (2009). HADS, a goal programming-based humanitarian aid distribution system. *Journal of Multi-Criteria Decision Analysis*, 16(1-2), 55-64.
- Voigt, S., Kemper, T., Riedlinger, T., Kiefl, R., Scholte, K., & Mehl, H. (2007). Satellite image analysis for disaster and crisis-management support. *IEEE transactions on geoscience and remote sensing*, 45(6), 1520-1528.
- Wallace, W. A., & De Balogh, F. (1985). Decision support systems for disaster management. *Public Administration Review*, 134-146.
- Wang, J., Wu, Y., Yen, N., Guo, S., & Cheng, Z. (2016). Big Data Analytics for Emergency Communication Networks: A Survey. *IEEE Communications Surveys & Tutorials*, 18(3), 1758-1778.
- Wenzel, F., & Marmuraenu, G. (2007). Rapid earthquake information for Bucharest. *Pure and Applied Geophysics*, 164(5), 929-939.
- Wohlgemuth, S., Oloruntoba, R., & Clausen, U. (2012). Dynamic vehicle routing with anticipation in disaster relief. *Socio-Economic Planning Sciences*, 46(4), 261-271.
- Yan, S., Lin, C., & Chen, S. (2012). Optimal scheduling of logistical support for an emergency roadway repair work schedule. *Engineering Optimization*, 44(9), 1035-1055.
- Yates, D., & Paquette, S. (2011). Emergency knowledge management and social media technologies: A case study of the 2010 Haitian earthquake. *International Journal of Information Management*, 31(1), 6-13. doi: 10.1016/j.ijinfomgt.2010.10.001
- Yu, L., & Lai, K. K. (2011). A distance-based group decision-making methodology for multi-person multi-criteria emergency decision support. *Decision Support Systems*, 51(2), 307-315. doi: 10.1016/j.dss.2010.11.024
- Zhen, L., Sheng, S. P., Xie, Z. H., & Wang, K. (2015). Decision rules for ambulance scheduling decision support systems. *Applied Soft Computing*, 26, 350-356. doi: 10.1016/j.asoc.2014.10.001
- Zheng, Y.-J., Ling, H.-F., Shi, H.-H., Chen, H.-S., & Chen, S.-Y. (2014). Emergency railway wagon scheduling by hybrid biogeography-based optimization. *Computers & Operations Research*, 43, 1-8.