

**OPTIMIZACIÓN MULTIOBJETIVO SOBRE REDES
ÓPTICAS EN TRANSMISIÓN MULTICAST**

**MARGARITA ROSA CORONELL CAMARGO
LUIS CARLOS TOVAR GARRIDO**

**INSTITUTO TECNOLÓGICO Y DE ESTUDIOS SUPERIORES
DE MONTERREY
UNIVERSIDAD AUTÓNOMA DE BUCARAMANGA
UNIVERSIDAD TECNOLÓGICA DE BOLÍVAR
BARRANQUILLA
2006**

**OPTIMIZACIÓN MULTI OBJETIVO SOBRE REDES
ÓPTICAS EN TRANSMISIÓN MULTICAST**

**MARGARITA ROSA CORONELL CAMARGO
LUIS CARLOS TOVAR GARRIDO**

Monografía de Grado

Director: Ing. YEZID DONOSO MEISEL

**INSTITUTO TECNOLÓGICO Y DE ESTUDIOS SUPERIORES
DE MONTERREY
UNIVERSIDAD AUTÓNOMA DE BUCARAMANGA
UNIVERSIDAD TECNOLÓGICA DE BOLÍVAR
BARRANQUILLA
2006**

Corrector	

Corrector	

Jurado	

Jurado	

A Dios, por guiar mis pasos...

A mi esposo, José Duván, por su apoyo incondicional

A mi hijo, Miguel Ángel, por iluminar mi vida

A mi familia, por acompañarme durante este camino.

A Dios, cuyo amor y misericordia me guían siempre.

A mi madre, por enseñarme que la educación es la mejor herencia.

A Dayana, cuya felicidad me llena.

A Maria Paula, mi hija, herencia de Dios y plenitud de gozo.

AGRADECIMIENTOS

La actual investigación se pudo realizar gracias a la colaboración de diferentes personas, algunas de ellas mencionamos a continuación:

Ing. Yezid Donoso Meisel por la orientación brindada durante la realización del proyecto.

Universidad del Norte por facilitarnos oficinas y laboratorios en donde pudimos adelantar nuestro trabajo y recolectar suficiente información.

Corporación Universitaria de la Costa por facilitarnos su infraestructura y algunos de sus equipos para las ejecuciones de las pruebas.

Edwin González Alandete por estar siempre pendiente de las fechas de entrega y mantener un buen canal de comunicación entre el grupo y la directiva de Bucaramanga.

Universidad Tecnológica de Bolívar, Universidad Autónoma de Bucaramanga e Instituto Tecnológico de Monterrey, por brindarnos los recursos necesarios, los que unidos al apoyo dado por los docentes, ayudaron a la culminación de nuestra formación en maestría.

RESUMEN

La masificación del uso de Internet por parte de empresas y personas naturales ha creado una ampliada variedad de tráfico de contenido en la red. Adicionalmente, nuevos servicios sobre Internet como video por demanda, televisión, teleconferencias y telefonía, entre otras; requieren cada vez más recursos. La Segunda Generación de la Internet Óptica (SGOI) representa una solución a los problemas de demanda de recursos en Internet, así como una aproximación más eficiente para proporcionar servicios IP en la parte alta de la capa óptica mediante GMPLS.

En la presente investigación se plantea y soluciona un Modelo de Optimización Multiobjetivo (MOP) en donde se consideraron las siguientes variables de decisión: atenuación en la fibra óptica, retardo extremo a extremo, el número de longitudes de onda utilizadas, número de saltos y ancho de banda. Dicho modelo fue planteado con la inclusión de lógica difusa para simular la incertidumbre o desconocimiento del modelador al plantearlo. De esta misma forma se desconfía de los resultados obtenidos. El modelo difuso se resolvió mediante un algoritmo propuesto que inserta lógica difusa en el algoritmo evolutivo Strength Pareto Evolutionary Algorithm 2 (SPEA2), por lo que el nuevo algoritmo fue llamado Fuzzy Strength Pareto Evolutionary Algorithm (FSPEA2).

TABLA DE CONTENIDO

GLOSARIO	XVII
<u>1 INTRODUCCIÓN</u>	<u>1</u>
1.1 PLANTEAMIENTO DEL PROBLEMA	1
1.2 OBJETIVOS	5
1.2.1 Objetivo General	5
1.2.2 Objetivos Específicos	5
1.3 CONTRIBUCIONES	6
1.4 ORGANIZACIÓN DEL DOCUMENTO	6
<u>2 MARCO TEÓRICO</u>	<u>9</u>
2.1 MULTICASTING	9
2.2 MULTIPROTOCOL LABEL SWITCHING (MPLS)	12
2.3 REDES ÓPTICAS	16
2.3.1 Wave Division Multiplexing (WDM)	16
2.3.2 Relación entre Redes Ópticas y la Operación de MPLS [BLA02]	18
2.4 GENEALIZED MULTIPROTOCOL LABEL SWITCHING (GMPLS)	19
2.4.1 Mapeo Entre Las Etiquetas MPLS Y La Longitud De Onda	19
2.4.2 Consideraciones De La Interrelación De Los Niveles 1 Y 2 En Redes GMPLS	21
<u>3 ESTADO DEL ARTE</u>	<u>23</u>
<u>4 PROBLEMAS DE OPTIMIZACIÓN MULTI OBJETIVO</u>	<u>28</u>
4.1 MÉTODOS PARA LA SOLUCIÓN DE PROBLEMAS MULTI OBJETIVO	29
4.1.1 Métodos Según el Tratamiento del Problema Multiobjetivo	30
4.1.2 Métodos Según las Interacciones	33

4.1.3	Clasificación Según los Métodos de Optimización	33
4.1.4	¿Cuál método escoger para solucionar un problema multiobjetivo?	34
4.2	ALGORITMOS EVOLUTIVOS MULTIOBJETIVOS	37
4.3	ALGORITMOS EVOLUTIVOS MULTIOBJETIVOS EN AMBIENTES MULTICAST	39
4.3.1	NSGA2: Non dominated Sort Genetic Algorithm 2	40
4.3.2	cNSGA2: Controlled Non dominated Sort Genetic Algorithm 2	41
4.3.3	SPEA: Strength Pareto Evolutionary Algorithm	42
4.3.4	SPEA2: Strength Pareto Evolutionary Algorithm 2	43
4.3.5	Escogencia del Mejor Método en Ambiente Multicast	44
4.4	MÉTODOS BASADOS EN LÓGICA DIFUSA PARA LA SOLUCIÓN DE PROBLEMAS MULTIOBJETIVOS	45
4.4.1	Método de Reardon	45
4.4.2	Método de Sakawa	47
5	<u>FORMULACIÓN MATEMÁTICA DEL PROBLEMA</u>	53
5.1	MODELO MATEMÁTICO	54
5.1.1	Longitudes de Onda	54
5.1.2	Atenuación	54
5.1.3	Retardo	55
5.1.4	Número de Saltos	57
5.1.5	Ancho de Banda	58
5.1.6	Modelo Matemático	59
5.2	MODELO DIFUSO	64
6	<u>APLICACIÓN DEL ALGORITMO EVOLUTIVO SPEA2 PARA RESOLVER EL PROBLEMA</u>	67
6.1	REPRESENTACIÓN DE LOS INDIVIDUOS	67
6.2	CRUZAMIENTO	67
6.3	MUTACIÓN	72

<u>7 APLICACIÓN DEL SPEA2 DIFUSO (FSPEA2) PARA RESOLVER EL PROBLEMA</u>	<u>74</u>
7.1 CÁLCULO DEL VALOR DE CERTIDUMBRE MÍNIMO (α)	74
7.2 FUNCIONES OBJETIVO	75
7.3 CÁLCULO DEL FITNESS	76
7.3.1 Función de Membresía	76
7.3.2 Cálculo de Strenght y RawFitness	76
7.3.3 Fitness	76
7.4 ANALISIS DE COMPLEJIDAD	77
<u>8 ANALISIS COMPARATIVO</u>	<u>79</u>
8.1 DISEÑO DEL EXPERIMENTO	79
8.1.1 Objetivo	80
8.1.2 Métricas a Analizar	80
8.1.3 Número de Repeticiones	82
8.1.4 Factores y Procedimientos	82
8.1.5 Recursos y Materiales Disponibles	92
8.2 COMPARACIÓN DE RESULTADOS	93
8.2.1 Diferencia normalizada de las medias de los valores extremos (DNME)	93
8.2.2 Generación de vectores no dominados (GVND)	95
8.2.3 Distancia Generacionales (DG)	99
8.2.4 Spacing (S)	102
8.2.5 Tiempo Computacional	105
8.2.6 Análisis de Correlación	106
8.2.7 Intervalo de Confianza	112
8.3 CASOS DE PRUEBA	115
8.3.1 Aumento en Cantidad de Generaciones	115
8.3.1.1 Diferencia normalizada de las medias de los valores extremos (DNME)	115
8.3.1.2 Generación de vectores no dominados (GVND)	116
8.3.1.3 Distancia Generacionales (DG)	116
8.3.1.4 Spacing (S)	117

8.3.1.5	Tiempo Computacional	117
8.3.2	Nivel de Certidumbre	118
8.3.2.1	Diferencia normalizada de las medias de los valores extremos (DNME)	118
8.3.2.2	Generación de vectores no dominados (GVND)	119
8.3.2.3	Distancia Generacionales (DG)	119
8.3.2.4	Spacing (S)	120
8.3.2.5	Tiempo Computacional	120
9	<u>CONCLUSIÓN Y TRABAJOS FUTUROS</u>	<u>122</u>
9.1	CONCLUSIÓN	122
9.2	TRABAJOS FUTUROS	123
	<u>BIBLIOGRAFÍA</u>	<u>125</u>

LISTA DE FIGURAS

Figura 1-1 Ancho de banda de red excedido con tráfico Multicast [WIL00]	2
Figura 2-1 Árbol Origen desde el Host A. [WIL00].....	10
Figura 2-2 Árbol Compartido Unidireccional.....	10
Figura 2-3 Árbol Compartido Bidireccional.....	11
Figura 2-4 Dos LSPs en una Red Conmutada de Paquetes MPLS [JER01].....	14
Figura 2-5 Multiplexación por División de Longitud de Onda [BLA02].....	17
Figura 2-6 Multiprotocol Lambda Switching [BLA02].....	18
Figura 2-7 Planos de Control Óptico y MPLS [BLA02]	20
Figura 2-8 Plano de datos Óptico [BLA02].....	20
Figura 2-9 Procesamiento de Tráfico de un Usuario [BLA02].....	21
Figura 4-1 Primer Nivel de Clasificación Jerárquica.....	31
Figura 4-2 Segundo Nivel de Clasificación Jerárquica.....	32
Figura 4-3 Jerarquía según el Tratamiento MOP.....	32
Figura 4-4 Jerarquía Según las Interacciones.....	33
Figura 4-5 Clasificación según los Métodos de Optimización	34
Figura 4-6 Algoritmo NSGA2	41
Figura 4-7 Algoritmo cNSGA2.....	42
Figura 4-8 Algoritmo SPEA	43
Figura 4-9 Algoritmo SPEA2	44
Figura 4-10 Función de Membresía de Reardon.....	46
Figura 6-1 Representación del individuo [CAR05]	68
Figura 6-2 Ejemplo de cruzamiento de dos árboles [CAR05].	69
Figura 6-3 Cruzamiento de dos caminos [CAR05].....	69
Figura 6-4 Individuos de ejemplo [CAR05].	70
Figura 6-5 Conjuntos [CAR05]	71
Figura 6-6 Resultados [CAR05]	72
Figura 6-7 Mutación del Camino [CAR05].....	73

Figura 7-1 Algoritmo FSPEA2	74
Figura 7-2 Comportamiento del nivel de Certidumbre (α).....	75
Figura 7-3 Número Triangular Difuso Simétrico $f(x_i)$	75
Figura 7-4 Análisis de Complejidad FSPEA2	77
Figura 8-1 Topología MCI.....	84
Figura 8-2 Topología NSF – 1991	87
Figura 8-3 Topología Sprint – 2001.....	89

LISTA DE TABLAS

Tabla 4-1 Clasificación de Métodos Escalares	35
Tabla 4-2 Clasificación de Métodos Interactivos.....	36
Tabla 4-3 Clasificación de Métodos Difusos.....	36
Tabla 4-4 Clasificación de Métodos Interactivos.....	37
Tabla 8-1 MCI F - Nodos Topología - Potencia del Láser	84
Tabla 8-2 MCI - Nodos Destinos.....	85
Tabla 8-3 MCI – Matriz de la red	85
Tabla 8-4 NSF - Nodos Topología - Potencia del Láser	87
Tabla 8-5 NSF - Nodos Destinos	87
Tabla 8-6 NSF – Matriz de la Red	88
Tabla 8-7 Sprint – Nodos Topologías Potencia de Láser.....	89
Tabla 8-8 Sprint – Nodos Destinos	90
Tabla 8-9 Sprint – Matriz de la Red.....	90
Tabla 8-10 DNME – Grafo Topología MCI	93
Tabla 8-11 DNME – Grafo Topología NSF	94
Tabla 8-12 DNME – Grafo Topología Sprint	95
Tabla 8-13 GVND – Cantidad Nodos destinos: 20%	95
Tabla 8-14 GVND – Cantidad Nodos destinos: 30%	96
Tabla 8-15 GVND – Cantidad Nodos destinos: 40%	96
Tabla 8-16 GVND – Cantidad Nodos destinos: 50%	97
Tabla 8-17 GVND – Cantidad Nodos destinos: 60%	97
Tabla 8-18 GVND – Cantidad Nodos destinos: 70%	98
Tabla 8-19 GVND – Cantidad Nodos destinos: 80%	98
Tabla 8-20 GVND – Cantidad Nodos destinos: 90%	99
Tabla 8-21 DG – Cantidad Nodos destinos: 20%	99

Tabla 8-22 DG – Cantidad Nodos destinos: 30%	99
Tabla 8-23 DG – Cantidad Nodos destinos: 40%	100
Tabla 8-24 DG – Cantidad Nodos destinos: 50%	100
Tabla 8-25 DG – Cantidad Nodos destinos: 60%	100
Tabla 8-26 DG – Cantidad Nodos destinos: 70%	100
Tabla 8-27 DG – Cantidad Nodos destinos: 80%	101
Tabla 8-28 DG – Cantidad Nodos destinos: 90%	101
Tabla 8-29 DG – Topología MCI PF_{true} SPEA2	101
Tabla 8-30 DG – Topología NSF PF_{true} SPEA2	102
Tabla 8-31 DG – Topología NSF PF_{true} SPEA2	102
Tabla 8-32 Spacing – Cantidad Nodos destinos: 20%	103
Tabla 8-33 Spacing – Cantidad Nodos destinos: 30%	103
Tabla 8-34 Spacing – Cantidad Nodos destinos: 40%	103
Tabla 8-35 Spacing – Cantidad Nodos destinos: 50%	103
Tabla 8-36 Spacing – Cantidad Nodos destinos: 60%	104
Tabla 8-37 Spacing – Cantidad Nodos destinos: 70%	104
Tabla 8-38 Spacing – Cantidad Nodos destinos: 80%	104
Tabla 8-39 Spacing – Cantidad Nodos destinos: 90%	104
Tabla 8-40 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 20%	105
Tabla 8-41 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 30%	105
Tabla 8-42 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 40%	105
Tabla 8-43 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 50%	105
Tabla 8-44 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 60%	106
Tabla 8-45 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 70%	106
Tabla 8-46 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 80%	106
Tabla 8-47 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 90%	106
Tabla 8-48 Coeficientes de Correlación de Funciones Objetivo – Topología MCI, destinos 20%	109
Tabla 8-49 Coeficientes de Correlación de Funciones Objetivo – Topología MCI, destinos 50%	110
Tabla 8-50 Coeficientes de Correlación de Funciones Objetivo – Topología MCI, destinos 90%	111
Tabla 8-51 Intervalos de Confianza – Topología MCI, destinos 20%	112

Tabla 8-52 Intervalos de Confianza – Topología MCI, destinos 30%.....	112
Tabla 8-53 Intervalos de Confianza – Topología MCI, destinos 40%.....	113
Tabla 8-54 Intervalos de Confianza – Topología MCI, destinos 50%.....	113
Tabla 8-55 Intervalos de Confianza – Topología MCI, destinos 60%.....	113
Tabla 8-56 Intervalos de Confianza – Topología MCI, destinos 70%.....	114
Tabla 8-57 Intervalos de Confianza – Topología MCI, destinos 80%.....	114
Tabla 8-58 Intervalos de Confianza – Topología MCI, destinos 90%.....	114
Tabla 8-59 DNME – Grafo Topología NSF – 150 Generaciones.....	115
Tabla 8-60 GVND – Topología NSF – 150 Generaciones	116
Tabla 8-61 DG – Topología NSF – 150 Generaciones	116
Tabla 8-62 DG – Topología NSF – 150 Generaciones PF_{true} SPEA2	117
Tabla 8-63 Spacing – Topología NSF – 150 Generaciones.....	117
Tabla 8-64 Tiempo Computacional (ms) – Topología NSF – 150 Generaciones.....	118
Tabla 8-65 DNME – Grafo Topología NSF – 150 Generaciones.....	118
Tabla 8-66 GVND – Topología NSF – Certidumbre 0.9.....	119
Tabla 8-67 DG – Topología NSF – Certidumbre 0.9.....	119
Tabla 8-68 DG – Topología NSF – Certidumbre 0.9 PF_{true} SPEA2.....	120
Tabla 8-69 Spacing – Topología NSF – Certidumbre 0.9	120
Tabla 8-70 Tiempo Computacional (ms) – Topología NSF – Certidumbre 0.9	121

GLOSARIO

BGP: Border Gateway Protocol.

CBT: Core-based tree.

Conjunto Pareto Óptimo y Frente Pareto Óptimo: Dado el conjunto de vectores de decisión factibles X_f . Se denomina X_{true} al conjunto de vectores de decisión no dominados que pertenecen a X_f , es decir:

$$X_{true} = \{ x \in X_f \mid x \text{ es no dominado con respecto a } X_f \}$$

El conjunto X_{true} también es conocido como el conjunto Pareto óptimo. Mientras que el conjunto correspondiente de vectores objetivo $Y_{true} = f(X_{true})$ constituye el frente Pareto óptimo.

Dominancia de Pareto: Un vector $u = (u_1, u_2, u_3, \dots, u_k)$ domina a otro $v = (v_1, v_2, v_3, \dots, v_k)$ (denotado mediante $u \succ v$) si y sólo si u es mayor a v en un ambiente de maximización, o también si u es menor que v en un ambiente de minimización. Por otra parte, se dice que u y v no son comparables (denotado mediante $u \sim v$) si y sólo si $u \not\geq v \wedge v \not\geq u$ en un ambiente de maximización o si y sólo si $u \not\leq v \wedge v \not\leq u$ en un ambiente de minimización.

DR: Designated Router.

DVMRP: Distance Vector Multicast Routing Protocol.

FEC: Forwarding Equivalence Class.

Función Objetivo: Nombre que se le da a la función $f(x)$, también se le conoce como función de costo o criterio de optimización. Hace referencia a la función para la cual el algoritmo de optimización intentará encontrar un óptimo.

IETF: Internet Engineering Task Force.

IGMP: Internet Group Membership Protocol.

LSP: Label Switching Path.

LSR: Label Switching Router.

MBGP: Multicast Border Gateway Protocol.

MBone: Multicasting Backbone.

MOP: Multi-Objective Problem.

MOEA: Multi-Objective Evolutive Algorithms.

Mínimo Global: Un vector x^* es un mínimo global de la función objetivo f , si se tiene que $f(x^*) < f(x)$ para cualquier x tal que $x^* \neq x$.

Mínimo Local: Un vector x^* es un mínimo local de la función objetivo f , si se tiene que $f(x^*) \leq f(x)$ para cualquier $x \in V(x^*)$ y $x^* \neq x$, donde $V(x^*)$ define un vecindario del vector x^* .

Mínimo Local Fuerte: Un vector x^* es un mínimo local fuerte de la función objetivo f , si se tiene que $f(x^*) < f(x)$ para cualquier $x \in V(x^*)$ y $x^* \neq x$, donde $V(x^*)$ define un vecindario del vector x^* .

MPLS: Multiprotocol Label Switching.

Optimalidad Global en el Sentido Pareto: Un vector x es globalmente óptimo en el sentido Pareto (u óptimo en el sentido Pareto) si no existe un vector x' tal que x' domine el vector x .

Optimalidad Local en el Sentido Pareto: Un vector $x \in R^n$ es localmente óptimo en el sentido Pareto si existe un real $\delta > 0$ tal que no hay un vector x' el cual domine al vector x con $x' \in R^n \cap B(x, \delta)$, donde $B(x, \delta)$ representa una taza de centro x y radio δ .

OSPF: Open Shortest Path First.

Relación de Dominación: Se dice que un vector x_1 domina a un vector x_2 si:

x_1 es al menos tan bueno como x_2 para todos los objetivos, y

x_1 es estrictamente mejor que x_2 para al menos un objetivo.

PIM: Protocol Independent Multicasting.

PIM – DM: PIM Dense Mode.

PIM – SM: PIM Sparse Mode.

RIP: Routing Information Protocol.

RPF: Reverse Path Forwarding.

SPT: Shortest Path Tree.

SVC: Switched Virtual Circuit.

SVP: Switched Virtual Path.

Variables de Decisión: Hace referencia a las variable que se encuentran reunidas en el vector de decisión x , modificando este vector es que se desarrolla la búsqueda de un óptimo para la función $f(x)$.

VC: Virtual Circuit.

VP: Virtual Path.

1 INTRODUCCIÓN

1.1 PLANTEAMIENTO DEL PROBLEMA

Los cambios trascendentales en la forma en que las empresas realizan negocios y procesan información, hoy día, han estado inducidos por los cambios en la tecnología de redes y al mismo tiempo han dirigido dichos cambios. De forma análoga, el uso de Internet tanto por parte de empresas como por parte de individuos refleja esta dependencia cíclica: la disponibilidad de nuevos servicios basados en imágenes o voz en Internet ha tenido como consecuencia un incremento del número total de usuarios y del volumen de tráfico generado por cada usuario. Esto a su vez ha generado la necesidad de incrementar la velocidad y la eficiencia de Internet. Por otra parte, es únicamente esa velocidad mejorada lo que hace que el uso de aplicaciones Web sea atractivo para el usuario final.


Internet y el Protocolo de Interred (IP) se diseñaron de modo que proporcionaran un servicio que realizara el mejor esfuerzo en la entrega (BE). En este mecanismo del mejor esfuerzo, Internet (o una intranet privada) tratan por igual a todos los paquetes de datos. Conforme crece el nivel de tráfico en las redes y se produce congestión, la entrega de todos los paquetes se ralentiza; si la congestión llega a ser severa, se descartan paquetes más o menos de forma aleatoria para aliviar dicha congestión. No se hace ninguna distinción en términos de la importancia relativa de ningún tipo de tráfico o en sus requisitos de temporización, pudiéndose provocar la pérdida de datos críticos [STA04, WAK03].

En la definición del protocolo IP, se crea la opción de manejar cierto tipo de aplicaciones con varios destinos, conocido como Multicast (figura 1); en lugar del

tráfico tradicional de un origen a un destino. Este tipo de servicio ha demostrado ser muy eficiente (en cuanto al consumo de ancho de banda) para la transmisión de audio, video, conferencias, simulaciones, juegos y en general el envío de datos en tiempo real a múltiples destinos (aplicaciones de misión crítica) [WIL00]. Sin embargo, la demanda de estos servicios en Internet ha crecido en gran medida, requiriéndole a la misma el tratamiento diferencial de cada aplicación y aún cuando IP podía diferenciar los tipos de servicios, nunca lo usaron con tal fin.

La presencia de tráfico elástico (aquel que permite el retardo) y no elástico (aplicaciones de misión crítica) hace que se maneje el concepto de calidad de servicio (QoS), con el cual se puede garantizar los recursos que una aplicación requiere. Así, se puede controlar las variaciones de retardo, rendimiento y pérdida de paquetes en una interred.

Figura 1-1 Ancho de banda de red excedido con tráfico Multicast [WIL00]



Con el actual incremento del volumen de tráfico, y con la introducción de nuevas aplicaciones de tiempo real, multimedia y de multicast, los protocolos y servicios tradicionales de Internet de primera generación son inadecuados. El único tipo de red que se diseñó desde el principio para soportar tanto tráfico tradicional TCP y UDP, así como el tráfico en tiempo real y características de QoS es ATM. Sin embargo, el

uso de ATM supone o bien construir una segunda infraestructura de red para el tráfico en tiempo real, o bien la sustitución de la configuración existente basada en IP por ATM, y ambas son alternativas costosas [STA04].

Lo anterior y el aumento explosivo de requerimiento de ancho de banda actual, han llevado al desarrollo de investigaciones, que como esta, buscan alternativas para ofrecer esos anchos de banda y manejo de QoS por medio de los últimos avances de tecnología óptica sobre la Multiplexación por División de Onda (WDM) o la Multiplexación por División de Onda en Modo Denso (DWDM) las cuales proveen un ancho de banda por fibra del orden de los Tera bits por segundos (Tbps).

Según Lucas Valcarenghi [VAL01], la evolución de Internet está estrictamente relacionada a la evolución fundamental de la capa física óptica, la cual es el enlace entre la primera y segunda generación de redes ópticas y la primera y segunda generación de la Internet óptica.

La Primera Generación de Redes Ópticas (FGON) consistía de cualquier estándar bien establecido (Ej. SONET) o nuevas propuestas interesantes (Ej. Gigabit Ethernet) donde las señales ópticas padecen conversiones eléctricas/ópticas (O/E/O) en cada nodo que encuentran en la ruta desde el origen hasta el destino. Por otra parte, la Segunda Generación de Redes Ópticas (SGON) presenta características típicas de las capas más altas del modelo de referencia OSI tales como networking, multiplexación y capacidades de transporte tales como los lightpaths (circuito óptico establecido entre nodos de la red para crear conexiones transparentes totalmente ópticas). SGON representa, además, el futuro de las comunicaciones ópticas.

La Primera Generación de la Internet Óptica (FGOI) está basada en FGON el cual proporciona canales ópticos punto a punto estáticos y semi-estáticos entre enrutadores IP. Consecuentemente en FGOI, el empeño de investigación esta enfocado a la implementación de una capa de enlace entre IP y la capa óptica (capa WDM) que provea encapsulamiento eficiente de datagramas IP. Tanto IP sobre SONET (POS)

como IP sobre Gigabit Ethernet, están siendo considerados como posibles candidatos para la interfaz entre IP y el dominio óptico [VAL01].

La Segunda Generación de la Internet Óptica (SGOI) representa un avance en el ofrecimiento de una aproximación más eficiente para proporcionar servicios IP en la parte alta de la capa óptica. Realmente, la capa óptica provee la obtención dinámica de recursos para la altamente variable demanda IP. Consecuentemente, se alcanza un alto grado de flexibilidad, puesto que un ancho de banda dado puede ser más eficientemente manejado por la capa IP cliente en la parte de arriba de WDM. Por otra parte, la capa intermedia entre IP y WDM las cuales proporcionarían granularidad en la obtención del recurso (ATM/SONET) ya no son necesarias. Así, se obtienen dos beneficios en el uso de IP sobre WDM: reducción de la complejidad y gastos generales, y más alta flexibilidad [VAL01].

En la arquitectura de dos capas, IP sobre WDM, visionada en SGOI cada capa puede proporcionar su propio esquema independiente y elástico. Esquemas de Restauración/Protección pueden ser implementados en la capa IP (posiblemente usando la subcapa Conmutación Multiprotocolo de Etiqueta, MPLS) y en la capa WDM (utilizando también el plano de control de MPLS Generalizado o MPλS) [VAL01].

Precisamente, la presente investigación se desarrolla tendiente a encontrar un modelo de optimización para la transmisión multicast en redes GMPLS, siendo un aporte hacia el desarrollo de la Internet Óptica de Segunda Generación.

Aparte de los avances realizados en aumentar la velocidad de entrega de la información, con el fin de disminuir la congestión en la red, se hace necesario iniciar procesos en pro de la optimización de la misma, estudiando diferentes variables que afectan el tráfico. En los trabajos desarrollados hasta el momento, muchos están trabajando en la optimización de una función, dejando de lado la posibilidad de obtener un mejor rendimiento si se trabajan varios aspectos al tiempo, lo cual es conocido como problema de optimización multiobjetivo (MOP, por sus siglas en

inglés). En la investigación propuesta se presenta una solución a un MOP en donde las distintas variables de decisión son la atenuación, el retardo y las longitudes de onda. Así, no sólo se dará una propuesta para mejorar la transmisión sobre el medio óptico sino que se optimizaría dicha transmisión. En investigaciones previas, se ha logrado demostrar que este tipo de problemas pertenece a la categoría de NP-Duro (no tienen solución en tiempo polinomial); por tal motivo, el problema se resuelve a través de metaheurísticas, utilizando algoritmos evolutivos; con los cuales se logra alcanzar una solución en tiempo polinomial. Más específicamente, en esta propuesta se emplea un algoritmo que combina la lógica difusa con el algoritmo evolutivo SPEA2, por lo que se le ha llamado FSPEA2.

1.2 OBJETIVOS

1.2.1 Objetivo General

Desarrollar un modelo analítico de optimización multiobjetivo en redes ópticas para la transmisión multicast, el cual se solucionará mediante algoritmos evolutivos.

1.2.2 Objetivos Específicos

- Identificar las características inherentes al medio óptico para la transmisión multicast.
- Establecer un modelo matemático que permita la optimización de las transmisiones multicast en el medio óptico (GMPLS), teniendo en cuenta variables tales como retardo, atenuación y longitud de onda.
- Comprobar la eficiencia del modelo mediante la utilización de Algoritmos Evolutivos.

1.3 CONTRIBUCIONES

A continuación se listan las contribuciones del presente trabajo de investigación:

- Se desarrolló un modelo analítico difuso, el cual resuelve un problema multi-objetivo en transmisión multicast con árboles estáticos Origen-Destino, sobre redes GMPLS.
- El problema multiobjetivo planteado, se solucionó mediante metaheurística con algoritmos evolutivos, específicamente el SPEA2, resolviendo un problema NP-Hard en tiempo polinomial.
- Se implementó un algoritmo evolutivo difuso, basado en el algoritmo evolutivo SPEA2, para resolver el modelo desarrollado
- Se analizó el comportamiento del algoritmo propuesto (FSPEA2) frente al algoritmo original (SPEA2) .

1.4 ORGANIZACIÓN DEL DOCUMENTO

En el capítulo 2 se presenta las bases teóricas que soportan las redes objetivo de este estudio. Es así como se explica el concepto de Multicasting y sus protocolos de enrutamiento; se abordan las redes MPLS y la transmisión multicast sobre estas redes para finalizar con el estudio de la capa uno: las redes ópticas. De manera general se abarca la transmisión multicast en MPLS sobre redes ópticas, lo que conlleva al estudio de GMPLS.

Seguidamente, en el capítulo 3, se realiza una exploración de las investigaciones relacionadas con el tema central del presente trabajo. Es así como se enuncian investigaciones tendientes a mejorar el tráfico en redes en Internet; algunas de las

investigaciones están relacionadas con la optimización del uso de lambdas, la optimización en el diseño, la creación de nuevas formas de enrutamiento y extensiones de protocolos entre otros temas. Se finaliza la exploración mencionando los trabajos adelantados por el Ing. Yezid Donoso en el campo de la optimización multiobjetivo de redes ópticas con transmisión multicast.

Luego del estado del arte y como preparación a la presentación de la investigación como tal, en el capítulo 4, se aborda toda la teoría concerniente a los problemas de optimización multiobjetivo, incluyendo los métodos más frecuentes empleados para dar solución a este tipo de problemas y la clasificación propuesta por Collette y Siarry. Se realiza un especial énfasis en los algoritmos evolutivos multiobjetivos y se destaca la superioridad de los MOEAs de segunda generación en la solución de problemas en ambientes multicast, por lo que se realiza una descripción de cada uno de ellos y se destaca la superioridad del SPEA y el SPEA2. Seguidamente se estudian los métodos basados en lógica difusa para la solución de problemas multiobjetivos, presentando específicamente los métodos de Reardon y Sakawa.

Después de presentar las distintas formas de solución de problemas multiobjetivos, en el capítulo 5, se presenta la formulación matemática del problema con base en las investigaciones realizadas por el Ing. Yezid Donoso. El aporte de esta investigación queda plasmado en la conversión del problema de optimización multiobjetivo en redes ópticas con transmisión multicast a un problema $G\alpha$ -MONLP.

En el capítulo 6 se presenta la forma como el problema multiobjetivo es solucionado mediante la utilización del SPEA2, se describe la forma como se representan los individuos así como la manera como se realizan los cruzamientos y las mutaciones.

En el capítulo 7 se explica la forma como se soluciona MOP aplicando el algoritmo propuesto en esta investigación: FSPEA2 (Fuzzy SPEA2). Se explica algunos parámetros utilizados, propios de la lógica difusa, así como los cambios que se

realizan al SPEA2 para soportar la lógica difusa en concordancia al método de Sakawa.

Seguidamente, capítulo 8, se realiza el respectivo análisis comparativo de resultados producto de las soluciones generadas por el SPEA2 y el FSPEA2. Las métricas de comparación que se consideraron fueron: diferencia normalizada de las medias de los valores extremos, generación de vectores dominados, distancias generacionales, spacing y tiempo computacional.

Para terminar, en el capítulo 9 se presentan las conclusiones de la investigación realizada y se proponen trabajos futuros.

2 MARCO TEÓRICO

En este capítulo se presentan los conocimientos fundamentales necesarios para el desarrollo de la presente investigación, tales como Multicasting, Multiprotocol Label Switching sobre redes Multicast, Redes Ópticas y Generalized Multiprotocol Label Switching.

2.1 MULTICASTING

La transmisión de información en redes Multicast se realiza a través de los árboles de distribución, los cuales pueden ser de dos tipos:

- **Árboles Origen.** Son los árboles cuya raíz es el nodo que inicia el tráfico multicast y las ramas son el árbol de expansión a partir de éste. Debido a que en este tipo de árboles se utiliza el Shortest Path, es conocido como el Shortest Path Tree (SPT) (figura 2 – 1).
- **Árboles Compartidos.** Estos árboles tienen una única raíz, conocida como Rendezvous Point (RP) o Core, por lo que comúnmente los árboles compartidos se les llaman RP Tree (RPT) o Core-Based Tree (CBT). Adicionalmente, se dividen en unidireccionales y bidireccionales, cuyo comportamiento se muestra en las figuras 2 – 2 y 2 – 3.

Figura 2-1 Árbol Origen desde el Host A. [WIL00]

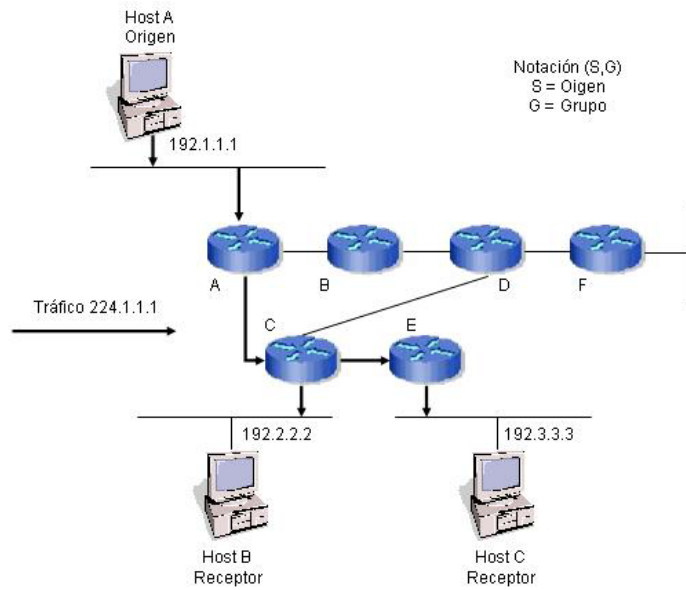


Figura 2-2 Árbol Compartido Unidireccional

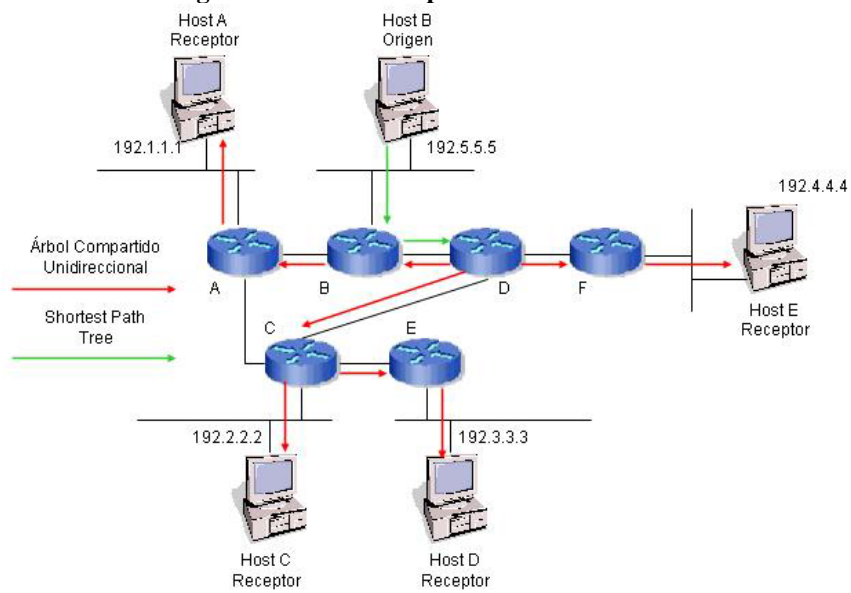



Figura 2-3 Árbol Compartido Bidireccional



PROTOCOLOS DE ENRUTAMIENTO MULTICAST

Así como se pueden utilizar diferentes árboles para distribución multicast de la información, también pueden emplearse diferentes protocolos de enrutamiento multicast a saber:

- **Distance Vector Multicast Routing Protocol (DVMRP).** El DVMRP es uno de los más antiguos protocolos de enrutamiento multicast, se basa en el Protocolo de Información de Enrutamiento (RIP) del tráfico unicast, cuyas principales características son [WIL00]: Utiliza el algoritmo de vector distancia para calcular las rutas, realiza actualizaciones periódicas cada 60 segundos, un destino se considera inalcanzable si su métrica es superior a 32, la actualización de rutas incluye la máscara. Adicionalmente, este protocolo sigue el mecanismo Flood-and-Prune (Inundar-y-Podar); el cual consiste en establecer el árbol de distribución, y en el momento de enviar el tráfico multicast, si un nodo detecta que no tiene receptores para ese grupo multicast en específico, envía un mensaje de poda (prune) de tal manera que deja de

recibir los mensajes. Si en una subred se encuentran dos (2) o más enrutadores conectados, se escoge a uno de ellos como el enrutador designado (DR), el cual será el encargado de hacer la difusión en la red LAN.

- **Protocol Independent Multicasting – Dense Mode (PIM-DM)** . Este es un protocolo que nace como mejora al DVMRP, y sus principales características son [WIL00]: es independiente del protocolo, debido a que usa la tabla de enrutamiento unicast para la verificación RPF; protocolo de enrutamiento multicast no separado; utiliza el mecanismo Flood-and-Prune en ciclos de tres (3) minutos.
- **Protocol Independent Multicasting – Sparse Mode (PIM-SM)** Este protocolo tiene como principales características [WIL00]: independiente del protocolo, debido a que utiliza la tabla de enrutamiento unicast para la verificación del RPF; no hay un protocolo de enrutamiento multicast separado; define un comportamiento de “Join” explícito. Este protocolo no utiliza el mecanismo Flood-and-prune como los dos (2) protocolos anteriormente descritos. A diferencia, utiliza un mecanismo de “Join” explícito el cual consiste en que cada uno de los miembros de un grupo de distribución multicast debe unirse al árbol, mediante mensajes *join* enviados a los vecinos ascendentes hasta llegar a la raíz.

2.2 MULTIPROTOCOL LABEL SWITCHING (MPLS)

Esta tecnología se desarrolló basada en paquetes y rápidamente ha sido la clave para su uso en las redes troncales (backbone) tanto para voz como para datos. Su finalidad es realizar la entrega de la información a alta velocidad, teniendo en cuenta el ancho de banda disponible y los distintos requerimientos de calidad de servicio (QoS – Quality of Service) [JER01].

Esta tecnología se vale de los enrutadores de conmutación de etiquetas (LSR – Label Switching Routers) para enviar la información de un sitio a otro, el proceso que siguen es el siguiente [RFC3031]:

1. Cuando se desea enviar un paquete y llega al LSR, éste analiza la dirección de destino, con el fin de determinar a qué Clase de Equivalencia de Reenvío (FEC – Forwarding Equivalente Class) se asocia dicho paquete. Este proceso se efectúa buscando cuál FEC es la que más encaja con la dirección de destino, basados en la longitud de la dirección. Una vez que la FEC se identifica, el paquete se etiqueta y se envía al próximo salto.

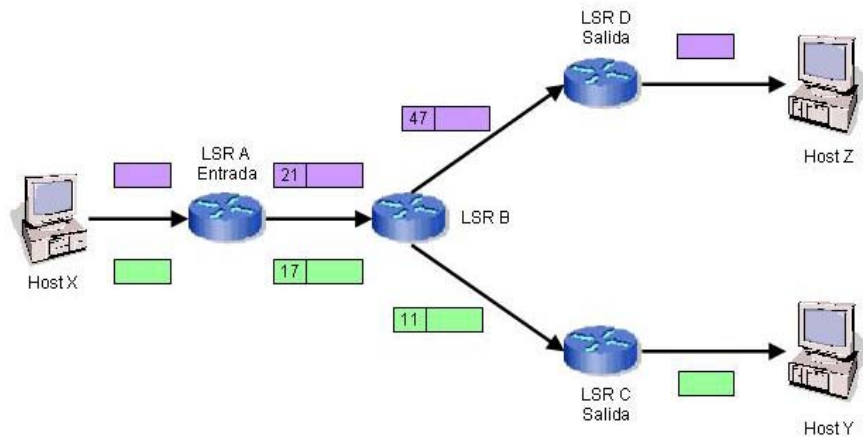
De acuerdo con la decisión de envío, los diferentes paquetes que son mapeados con la misma FEC no se distinguen; adicionalmente, todos los paquetes que pertenecen a una misma FEC y que viajan desde un nodo determinado seguirán el mismo camino; a este camino se le conoce como Camino de Conmutación de Etiquetas (LSP – Label Switched Path).

2. En los saltos siguientes (LSR) no se revisa el paquete a nivel de red, en su lugar, se verifica la etiqueta de entrada con el fin de conocer el próximo salto, y ésta se sustituye por una nueva.

En la Figura 2 – 4 se muestran dos flujos de datos desde el Host X, los que van dirigidos hacia los Host Y y Z. A continuación se describe el procedimiento a seguir [JER01]:

- El LSR A es un punto de entrada de la red MPLS para los datos del dispositivo X. Cuando recibe paquetes desde X, el LSR A determina la FEC de cada paquete, deduce el LSP a usar y añade una etiqueta al paquete. Después el LSR A envía el paquete a la interfaz apropiada del LSP.

Figura 2-4 Dos LSPs en una Red Conmutada de Paquetes MPLS [JER01]



- El LSR B es intermedio en la red MPLS. Simplemente toma cada paquete etiquetado y usa el par {interfaz de entrada, valor de etiqueta} para decidir el par {interfaz de salida, valor de etiqueta} con el que enviar el paquete. Este procedimiento puede usar una simple tabla de búsqueda y se puede realizar en hardware, junto con el canje del valor de la etiqueta y el enrutamiento del paquete. Esto permite que las redes MPLS se construyan con el hardware existente de conmutación de etiquetas como ATM y Frame Relay. En el ejemplo cada paquete con valor de etiqueta 21 será enviado por la interfaz hacia el LSR D con el valor de etiqueta 47. Los paquetes con el valor de etiqueta 17 serán re-etiquetados con el valor 11 y enviados hacia el LSR C.
- El LSR C y LSR D actúan como los LSRs de salida de la red MPLS. Estos LSRs realizan la misma búsqueda que los LSRs intermedios, pero el par {interfaz de entrada, valor de etiqueta} marca el paquete como saliendo por el LSP. Los LSRs de salida eliminan las etiquetas de los paquetes y los envían usando enrutamiento de nivel 3.

La forma en que trabajan las redes MPLS tiene varias ventajas [RFC3031]:

- El envío MPLS puede ser hecho por conmutadores que son capaces de poner etiqueta y sustituirla, pero no son capaces de analizar las cabeceras de nivel de red, ni son capaces de analizar las cabeceras a nivel de red a la velocidad adecuada.
- Desde que un paquete es asignado a una FEC cuando entra en la red, el enrutador de entrada puede usar, al determinar la asignación, cualquier información que tiene el paquete, aunque esa información no pueda ser recogida de la cabecera de nivel de red.
- Un paquete que entra en la red por un enrutador determinado puede ser etiquetado diferentemente si el mismo paquete entra a la red por otro enrutador y como resultado de las decisiones de envío que dependen del enrutador de entrada se puede hacer más fácil. Esto no puede ser hecho con el envío convencional, ya que la identidad del enrutador de entrada del paquete no viaja con el paquete.
- Las consideraciones que determinan como un paquete es asignado a una FEC pueden llegar a ser aún más y más complicadas, sin impacto en todos los enrutadores que meramente envían paquetes etiquetados.
- En ocasiones es deseable forzar un paquete a seguir una determinada ruta que es explícitamente elegida o antes de que el paquete entre a la red, antes de que se elija por el algoritmo normal dinámico de enrutamiento como debe viajar por la red el paquete. Esto se puede hacer como un asunto de política o soporte de la ingeniería de tráfico. En MPLS, se puede usar una etiqueta para representar la ruta, así que la identidad de la ruta explícita no necesita ser llevada con el paquete.

En MPLS, cuando un determinado enrutador LSR es un nodo en un determinado árbol multicast, se enlaza una etiqueta a este árbol. Entonces, se distribuye este

enlace a su padre en el árbol multicast. Si el nodo está en una LAN, y tiene hermanos en ésta, también debe distribuir el enlace a sus hermanos. Esto permite al padre usar un único valor de etiqueta cuando envíe tráfico multicast a todos los hijos de la LAN [RFC3031].

2.3 REDES ÓPTICAS

Como se muestra en [RAJ03] y [SEM00], las redes ópticas han evolucionado rápidamente en términos de funciones y capacidades.

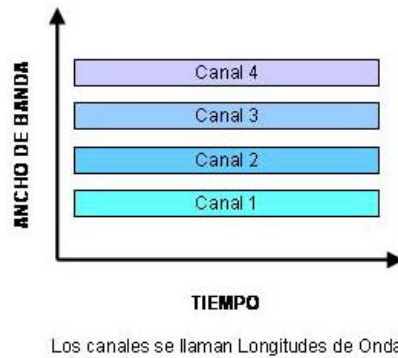
Las redes ópticas deben ser perdurables, flexibles y controlables; razón por la cual, hoy día, se introduce inteligencia en el plano de control de las redes ópticas para hacerlas más versátiles; lo que las haría capaces de iniciar y enrutar las conexiones a nivel óptico en tiempo real, y al mismo tiempo, suministrar capacidades que mejoren la supervivencia de la red. Esto trae como consecuencia la interoperabilidad de los diferentes fabricantes de red óptica [RAJ03].

2.3.1 Wave Division Multiplexing (WDM)

La multiplexación por división de longitud de onda, se basa en la muy conocida multiplexación por división de frecuencia (FDM – Frequency Division Multiplexing). Esta tecnología permite que múltiples señales ópticas operen en diferentes longitudes de onda y que éstas se multiplexen y se transporten en una única fibra óptica en paralelo [BLA02]. En general, cada longitud de onda óptica puede transportar datos digitales de clientes a diferentes velocidades y en diferentes formatos (SONET, Ethernet y ATM entre otros) [RAJ03].

En las redes WDM, cada canal se llama *longitud de onda*, debido a que estos operan en frecuencias y longitudes de onda diferentes. La notación que se suele utilizar para la longitud de onda es la letra griega Lambda (λ) [BLA02].

Figura 2-5 Multiplexación por División de Longitud de Onda [BLA02]



Las longitudes de onda en la fibra se separan por una parte del espectro que no se utiliza, lo cual ayuda a prevenir la interferencia con las demás.

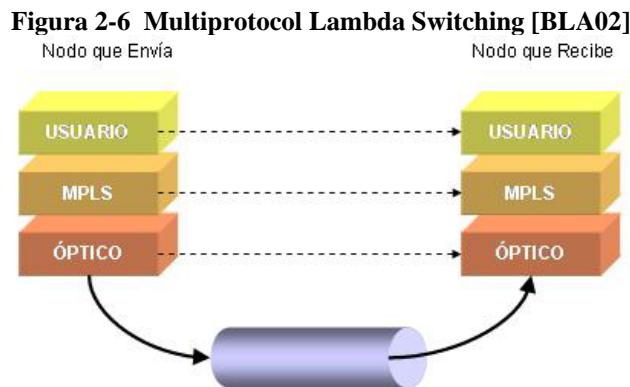
Es importante observar que los enlaces WDM se afectan por los siguientes factores [SEM03]:

- El número de longitudes de onda en una única fibra.
- La velocidad serie por longitud de onda.
- El tipo de fibra.
- El mecanismo de amplificación.
- El número de nodos por los que pasa la señal antes de alcanzar el nodo de salida o antes de su regeneración.

Todos estos factores constituyen las características físicas del dominio de las redes de transporte ópticas.

2.3.2 Relación entre Redes Ópticas y la Operación de MPLS [BLA02]

En la Figura 2 – 6 se muestra una forma conveniente de ver la relación entre MPLS y las redes ópticas; donde las primeras operan entre los niveles 2 y 3, mientras que las segundas corresponden al nivel 1.



El plano de datos que un LSR utiliza para transferir un paquete etiquetado es un puerto de entrada con un puerto de salida. El plano de datos de un conmutador óptico es una matriz que conecta un camino conmutado óptico (OSP – Optical Switched Path) de un puerto de entrada a un puerto de salida. El OSP se extiende desde una interfaz de salida de un nodo a una interfaz de entrada de un nodo adyacente.

El tráfico de una aplicación de un usuario en una capa superior se puede enviar ya sea por el plano de datos o de control de la capa inferior MPLS en el lado de la transmisión, con la ocurrencia de una operación inversa en el lado del receptor.

Un LSR realiza la conmutación de etiquetas estableciendo una relación entre el puerto de entrada u una etiqueta de entrada, y un puerto de salida y una etiqueta de salida. Del mismo modo, un conmutador óptico aprovisiona un canal óptico estableciendo la relación entre un puerto de entrada y un canal óptico, y un puerto de salida con un canal óptico de salida. En el LSR, la entrada de reenvío de etiqueta del próximo salto (NHLFE – Next Hop Label Forwarding Entry) de un LFIB (Label

Forwarding Information Base – Base de Información de Reenvío de Etiqueta) mantiene estas relaciones de entrada/salida.

En un conmutador óptico, el controlador del conmutador configura la interconexión interna (llamada una tabla de cross-conexión del OSP o una base de información de reenvío de longitudes de onda – WFIB) para establecer la relación entre MPLS y los canales ópticos.

Los planos de control de MPLS incluyen descubrimiento, manejo de conexión y manejo de la operación. El plano de control de un nodo óptico son descubrir, distribuir y mantener la información de estado relevante asociada con los OSPs y establecer y mantener estos OSPs bajo varias políticas y reglas de ingeniería de tráfico de interred óptica.

Una diferencia significativa entre los LSRs actuales y los conmutadores ópticos es que con los LSRs la información de reenvío es explícitamente parte de las etiquetas adicionadas a los paquetes, mientras que en los segundos, la información de conmutación es implícita en la longitud de onda o en la fibra óptica.

2.4 GENEALIZED MULTIPROTOCOL LABEL SWITCHING (GMPLS)

Como se menciona en [BAN01], el GMPLS, también conocido como MP λ S, soporta dispositivos que realizan conmutación de paquetes, conmutación en los espacios de tiempo, de la longitud de onda y del espacio.

2.4.1 Mapeo Entre Las Etiquetas MPLS Y La Longitud De Onda

El aspecto clave es la correlación entre las etiquetas MPLS y las longitudes de onda ópticas; por lo tanto, un plano de control como el GMPLS o el Protocolo de Manejo

de Enlace (LMP – Link Management Protocol) se pueden usar en un nodo para informar a sus vecinos acerca del mapeo entre una etiqueta específica con una longitud de onda específica; de tal forma que el nodo óptico no necesita preocuparse por el procesamiento de las etiquetas MPLS.

Figura 2-7 Planos de Control Óptico y MPLS [BLA02]

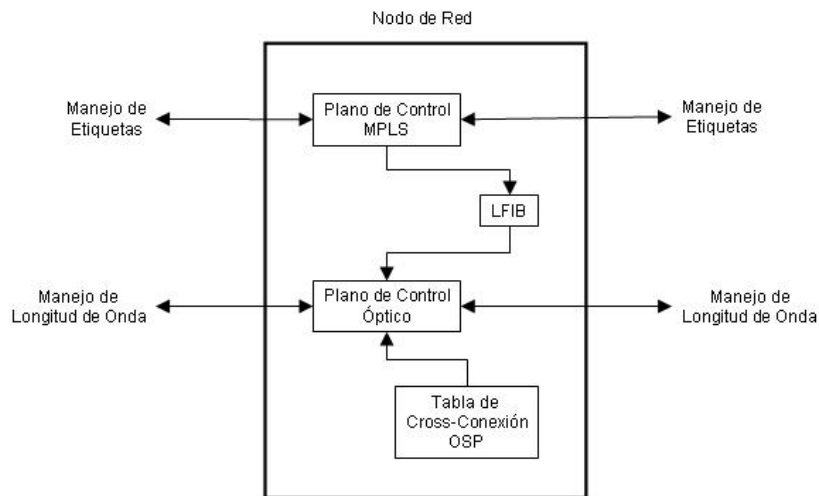
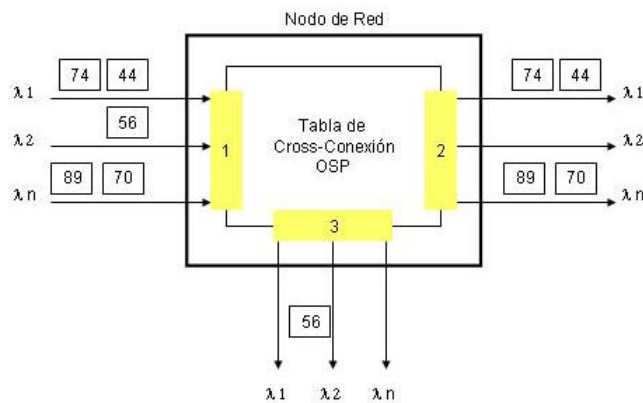


Figura 2-8 Plano de datos Óptico [BLA02]

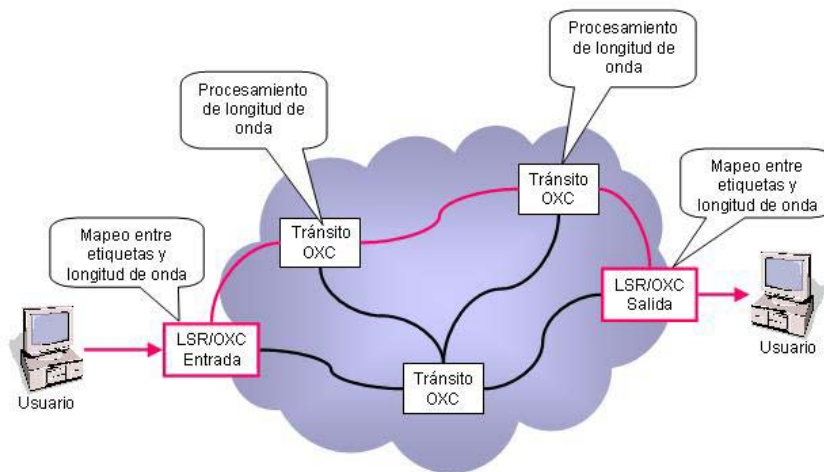


La figura 2 – 8 es un ejemplo de un plano de datos óptico en un dispositivo O/O/O (lo que significa que la entrada es óptica, el procesamiento es óptico y la salida

también lo es). En este ejemplo la λ_2 , que entra por la interfaz 1, se conmuta (refleja) con la interfaz 3; mientras que las demás se conmutan con la interfaz 2. En este caso, el conmutador no examina las etiquetas, ya que en ese caso, el dispositivo sería O/E/O (entrada óptica, procesamiento eléctrico, salida óptica).

El funcionamiento de este tipo de redes se muestra en la figura 2 – 9, en la que un usuario genera tráfico en la red, al pasar por el LSR de entrada, éste no sólo adiciona la etiqueta, sino que la correlaciona con una longitud de onda específica; de tal manera que al entrar a la red de conmutadores ópticos éstos puedan conmutar (reflejar) los haces de luz de la forma apropiada hasta llegar al LSR de salida.

Figura 2-9 Procesamiento de Tráfico de un Usuario [BLA02]



2.4.2 Consideraciones De La Interrelación De Los Niveles 1 Y 2 En Redes GMPLS

En [BLA02], se listan ciertas consideraciones entre la conmutación óptica (nivel 1) y su correlación con las etiquetas MPLS, a saber:

- Los nodos de circuitos conmutados pueden tener miles de enlaces físicos (puertos). Un asunto clave en las redes GMPLS es la configuración y manejo de

estos puertos y las longitudes de onda de los puertos. En lo más posible, es deseable no ejecutar funciones O/E/O en el plano de datos. Por lo tanto, el ideal es que el camino de luz utilice la misma longitud de onda de extremo a extremo.

- Los nodos vecinos de nivel 1 no necesitan conocer el número identificador del puerto interno de sus vecinos; sin embargo, sí necesita conocer el identificador del canal en el puerto, con el fin de reconocer cada parte del tráfico.
- Muchas de las características de los conmutadores de circuito se configuran manualmente y la operación se mantiene estática. La correcta operación de las redes GMPLS requiere que la red sea dinámica, en lugar de estática; con el fin de poder encontrar nuevas rutas en caso de que exista alguna falla física en el medio.

3 ESTADO DEL ARTE

En años recientes se han desarrollado algunos trabajos en pro del desarrollo de Internet de Segunda Generación (basada en redes ópticas), dichas investigaciones se han incrementado después de la emisión del RFC3031 en enero de 2001, algunas tratan en forma específica de IP sobre MPLS, de multiplexación y muy pocos tocan el tema de optimización multiobjetivo, basándose sólo en optimizaciones de costo que no dejan de ser de un solo objetivo como la presentada en [BAE00]. A continuación se describe cronológicamente las investigaciones desarrolladas en las áreas que se consideran relacionadas con la presente investigación.

Yinghua Ye, en [YE00], presenta una alternativa para el uso de la multiplexación por longitud de onda en modo denso (DWDM) para soportar la demanda explosiva de Internet, además de proveer un método de multiplexación del medio óptico como una nueva fase en la construcción de la infraestructura de ancho de banda con optimización del uso de lambdas; para lo cual, combina la ingeniería de tráfico de MPLS con la tecnología de conexiones ópticas.

Por otra parte, en Junio 2001 Vincent Wong en su trabajo de investigación doctoral [WON01], menciona la necesidad de aplicar un proceso de de-layering en redes DWDM y hacer de la capa IP la nueva capa de convergencia, a fin de transportar paquetes de datos de manera más eficiente; lo cual permitiría el desarrollo de un esquema de aprovisionamiento de caminos de luz dinámicos. También presenta un esquema de agregación de tráfico en nodos ópticos como una mejora al esquema de MPLS.

Seis meses después, en Diciembre de 2001, Luca Valcarenghi [VAL01] presenta una solución a los problemas de restauración de fallas en redes IP sobre WDM. Encontrándose que se debía utilizar IP sobre GMPLS, lo que permitió la creación de esquemas de Restauración Pre-Planeada Estocástica; los cuales se inician luego de una notificación de falla desde un nodo maestro de la red interrumpida. Valcarenghi logra demostrar en su investigación que los esquemas presentados son una solución robusta para las fallas en las redes cuyo tráfico cambia constantemente, ya que brinda un tiempo de respuesta menor que otras tecnologías ya implementadas.

En el año 2002, en [WAJ02] se presenta una solución, a través de formulación matemática formal y solución heurística para optimizar el diseño de una red de área metropolitana minimizando los costos. Para brindar resultados, se compararon cuatro conexiones Digitales y Ópticas, encontrándose que la solución digital es útil cuando el número de subcanales de longitudes de onda no es muy grande o muy pequeño; mientras que la solución óptica brinda una mejor solución para otros casos. Sin embargo, una arquitectura mixta podría alcanzar el máximo beneficio debido a que se logra combinar los alcances de ambas tecnologías.

Luego, en [XIN02] se describe el uso de protocolos IP sobre MPLS/GMPLS, teniendo en cuenta mecanismos para enrutamiento de la luz en medios ópticos, señalización, protección y restauración de una red óptica. Además, se comparan esquemas de control distribuido y centralizado, encontrándose que el esquema de control distribuido tiene el mismo desempeño que uno centralizado con un costo aceptable.

Por otro lado, Abadallah A. Shami, [SHA03], se centra en el estudio del aprovisionamiento de canales ópticos en redes de datos ópticas basadas en el híbrido IP sobre DWDM. Para tal fin, se concentra en el desarrollo de algoritmos y modelos de señalización y enrutamiento con el esquema GMPLS para la provisión de gran cantidad de longitudes de onda.

En el mes siguiente, [LIA03] presenta tres extensiones del protocolo TCP, con las que se pretende brindar una entrega confiable y eficiente de los paquetes multicast que hoy día se difunden en la Internet. Estas extensiones (extensión de tiempo real TCP-RTM, extensión de enmarcado TCP-Framing y extensión multicast TCP-SMO) se probaron en un kernel de Linux; obteniéndose como resultado que éstas son tanto eficaces como eficientes en la entrega de tráfico multicast con varios tipos de aplicaciones en las que se probaron, a un bajo costo.

En junio del mismo año, se presentaron los resultados de dos investigaciones. La primera de ellas, desarrollada por Chadi M. Assi, titulada “Optical networking and real-time provisioning: An integrated vision for a next generation survivable optical Internet” y la segunda, desarrollada por Kang Bin Wang, titulada “Multicasting in MPLS networks”.

Chadi Assi, [ASS03], divide su trabajo en dos fases. La primera, se concentra en la señalización y enrutamiento dinámico asociado con el aprovisionamiento, mantenimiento y restauración de todos los canales ópticos (camino de luz) de la capa física. Para ello, se desarrollaron dos algoritmos en los que se dispone de información parcial o global para que el algoritmo de enrutamiento pueda tomar su decisión. Para probar su exactitud, los algoritmos se evaluaron mediante comparaciones numéricas con resultados de simulación. La segunda fase se concentra en la señalización y enrutamiento dinámico asociado al aprovisionamiento, mantenimiento y restauración de los flujos de tráfico de baja velocidad de la capa lógica (IP/MPLS). En este escenario, los enrutadores IP/MPLS y los clientes de la red óptica se conectan a través de conmutadores ópticos dinámicos. Se desarrollaron varios algoritmos de enrutamiento que aprovisionaban conexiones en la capa lógica; los resultados de la simulación mostraron que los flujos de tráfico de baja velocidad tienen un mejor comportamiento con el aprovisionamiento dinámico en la capa lógica. Sin embargo, para la restauración de las conexiones se desarrolló un esquema de protección para garantizar la restauración en los caminos establecidos en redes WDM con IP/MPLS.

Kang Bin Wang [WAK03], por su parte, se centra en el estudio de la agregación de tráfico multicast en redes MPLS, proponiendo un mecanismo para lograrlo y además evitar los bucles que se pueden generar en esta tarea; para lo que adicionalmente estudia los algoritmos PIM-SM, PIM-DM y DVMRP. Además de tratar la agregación de tráfico multicast y la prevención de bucles, tiene en cuenta la Diferenciación de Servicio (DiffServ) en las redes MPLS. Para el estudio realizado, se tomaron en cuenta estructuras de árboles y árboles compartidos, analizándose los resultados a través de simulaciones donde el tráfico se origina desde la raíz del árbol o cuando se origina desde una de las hojas.

En agosto de 2003, [WU03] estudia cómo aplicar GMPLS para construir una red óptica conmutada automáticamente (ASON); para ello divide su estudio en tres partes: la implementación de GMPLS en ASON construyendo una red óptica conmutada automáticamente basada en GMPLS (GASON), una red óptica basada en esquemas de simulación para evaluar los algoritmos de enrutamiento de longitud de onda en ASON, por último, la gestión de las conexiones ópticas en GASON, esto es, la estructura de la red óptica y el plano de control de GMPLS.

En diciembre del mismo año, [HAN03] desarrolla un conjunto de protocolos para manejar la construcción y mantenimiento del árbol multicast usando unicast, donde los árboles pueden estar desbalanceados dependiendo de las características de los clientes. El propósito de estos protocolos es conectar a los nodos de una red o subred lo más cercanos posibles, tratando de maximizar el ancho de banda disponible y minimizando el tiempo de latencia dentro de la red o subred respectivamente.

En Colombia, se destaca la investigación que ha realizado el Ing. Yezid Donoso Meisel desde el año 2003 [DON03a, DON03b], en la que presenta un conjunto de árboles óptimos en la transmisión de tráfico multicast, donde se tiene en cuenta la minimización de la máxima utilización de los enlaces; mientras que se minimiza la cantidad de saltos, ancho de banda consumido y el retardo. Demuestra, además, que la función objetivo se puede reproducir mediante el árbol de caminos más corto,

asignándole pesos a los enlaces, presentando no solo la demostración del modelo, sino que se logra la construcción de un algoritmo, cuya solución es en tiempo polinomial.

Por otro lado, los ingenieros Luis F. Caro y Pierre Rosado [CAR05], presentaron los resultados de su investigación titulada “Optimización Multi-Objetivo En Transmisiones Multicast Sobre Redes Ópticas Usando Algoritmos Evolutivos, Meméticos Y Ant-Colony”, en la que contrastaron el comportamiento de tres (3) algoritmos: SPEA2, MACOMTO y MSPEA2, siendo éste último un algoritmo propuesto; encontrando que el algoritmo que tuvo el mejor comportamiento es el MACOMTO.

No obstante, ni siquiera en las últimas investigaciones mencionadas y a la fecha de finalización de la exploración bibliográfica, no se detectó investigación alguna en donde se utilizara lógica difusa en algoritmos evolutivos para la optimización de tráfico multicast en redes GMPLS.

4 PROBLEMAS DE OPTIMIZACIÓN MULTI OBJETIVO

Los problemas de optimización del mundo real son naturalmente multiobjetivo. Es decir, suelen tener dos o más funciones objetivos que deben satisfacerse simultáneamente y que posiblemente están en conflicto entre sí, lo cual quiere decir que la mejora de uno repercute en el deterioro de otro. De manera general [DUA01] un problema multiobjetivo puede ser representado como:

$$\begin{aligned} \text{Optimizar} \quad & \mathbf{y} = \mathbf{f}(\mathbf{x}) = (f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_k(\mathbf{x})) \\ \text{sujeto a} \quad & \mathbf{e}(\mathbf{x}) = (e_1(\mathbf{x}), e_2(\mathbf{x}), \dots, e_m(\mathbf{x})) \leq \mathbf{0} \\ \text{donde} \quad & \mathbf{x} = (x_1, x_2, \dots, x_n) \in \mathbf{X} \\ & \mathbf{y} = (y_1, y_2, \dots, y_k) \in \mathbf{Y} \end{aligned} \tag{4.1}$$

Siendo \mathbf{x} el vector de decisión e \mathbf{y} el vector objetivo. El espacio de decisión se denota por \mathbf{X} , y al espacio objetivo por \mathbf{Y} . Optimizar, dependiendo del problema, puede significar igualmente, minimizar o maximizar. El conjunto de restricciones $\mathbf{e}(\mathbf{x}) \leq \mathbf{0}$ determina el conjunto de soluciones factibles \mathbf{X}_f y su correspondiente conjunto de vectores objetivo factibles \mathbf{Y}_f .

En la última década el planteamiento y solución de problemas multiobjetivo a cobrado gran importancia, de ahí la notoria aplicación en campos del conocimiento tan diversos como la aeronáutica, las telecomunicaciones, las ingenierías ambiental y aeroespacial, la electrónica y la eléctrica entre otras.

A continuación se presenta una explicación de los términos utilizados en el planteamiento y solución de problemas multiobjetivos según los presenta [COE02a], [COL03] y [DUA01].

4.1 MÉTODOS PARA LA SOLUCIÓN DE PROBLEMAS MULTIOBJETIVO

Actualmente, según [COE02b], existen unas 30 técnicas de optimización multiobjetivo en la literatura de investigación de operaciones. Sin embargo, la mayoría de ellas están limitadas a frentes de Pareto convexos (como ocurre con el caso del método de la suma de funciones con pesos) o suelen requerir un punto inicial de búsqueda (método de distancia a un objetivo referencia). Adicionalmente, suelen generar una solución por ejecución; y además, muchos de estos problemas tienden a modelarse como mono-objetivo, bien sea porque combinan las funciones objetivos en una o porque usan sólo una de las funciones originales como objetivo y manejan las adicionales como restricciones.

Por este motivo se ha intentado hacer una clasificación de los métodos para la solución de problemas multiobjetivo. No obstante, realizar una clasificación única ha sido difícil debido tanto a la diversidad de los problemas a resolver como a la forma como éstos se resuelven. [COL03] plantea diversa clasificaciones, algunas de las cuales se presentan a continuación.

Primero, Collette y Siarry [COL03] presenta una diferencia entre las expresiones:

- Método de tratamiento multiobjetivo
- Método de optimización
- Método de optimización multiobjetivo

“Método de tratamiento multiobjetivo” hace referencia a los métodos que transforman el problema multiobjetivo original para adaptarlos a un método de

solución específico, generalmente, aunque no necesariamente, se refiere a aquellos métodos que transforman el problema original a uno mono-objetivo, como por ejemplo el método de la suma de funciones objetivos con pesos. Con el término “Método de optimización” se refiere a los métodos de búsqueda usados para resolver un problema multiobjetivo, por ejemplo el método de recocido simulado. Y “Método de optimización multiobjetivo”, refiriéndose a la combinación de un método de tratamiento multiobjetivo con un método de optimización.

Luego, plantea una primera clasificación la cual llama Aproximación Matemática en la que sólo tiene en cuenta la forma como un problema de optimización multiobjetivo es transformado en otro problema de optimización multiobjetivo el cual es adaptado para poder ser resuelto mediante la utilización de un método de optimización. Un ejemplo es el método Tchebychev.

Por último, se presenta una clasificación jerárquica de métodos de optimización multiobjetivo, el inconveniente aquí es el alto nivel de jerarquías que se pueden generar debido al gran número de elementos distintos que describen a un método de optimización. La clasificación jerárquica se lleva a cabo por tres dimensiones a saber:

- Jerarquía según el tratamiento que recibe el problema multiobjetivo.
- Jerarquía según las interacciones.
- Jerarquía según los métodos de optimización.

A continuación se describen cada una de estas jerarquías.

4.1.1 Métodos Según el Tratamiento del Problema Multiobjetivo

Se refiere a la clasificación de acuerdo al conocimiento que se tiene del problema a resolver, en tal caso el problema puede ser resuelto de tres formas:

- A priori, cuando se tiene un amplio conocimiento del problema y es posible dar una preferencia en relación con la función objetivo.
- A posteriori, cuando no se tiene mucho conocimiento del problema; en tal caso se intenta descubrir el frente Pareto mediante la búsqueda de un número finito de soluciones, luego el tomador de decisiones escoge una solución.
- Progresiva, se establece un diálogo con el método de optimización a fin de guiarlo por las preferencia del tomador de decisiones.


De estos tres casos se obtiene el primer nivel de la clasificación tal como se muestra en la Figura 4 – 1. No obstante, cabe destacar que los métodos con tratamiento progresivo del problema difieren sustancialmente de los otros dos debido al proceso de interacción durante el desarrollo del mismo, por consiguiente la clasificación para este método difiere a partir del tercer nivel.

Figura 4-1 Primer Nivel de Clasificación Jerárquica



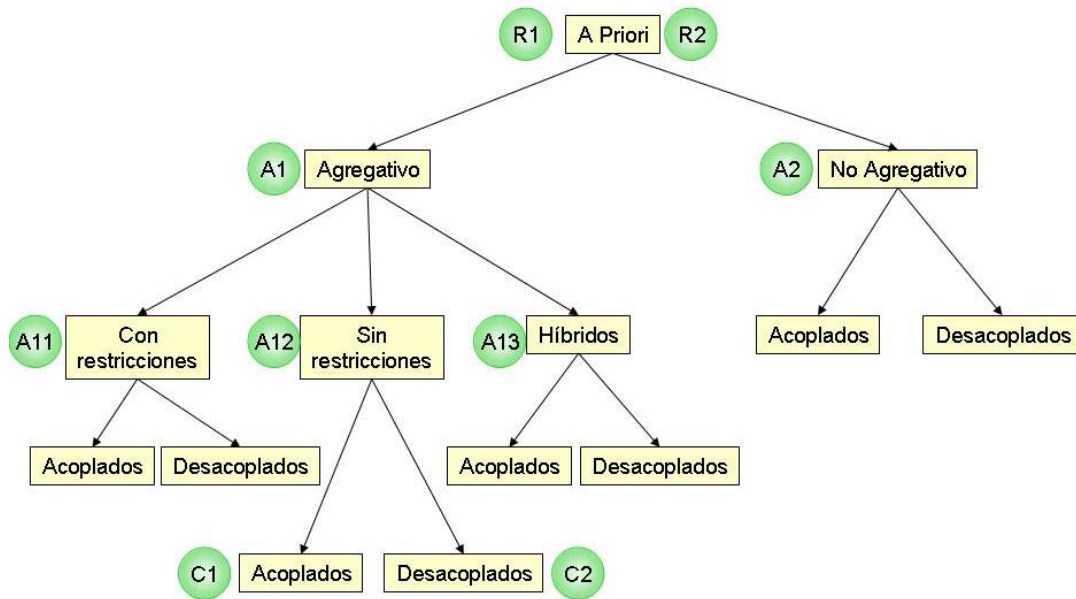
El segundo nivel de la jerarquía, Figura 4 – 2, tiene que ver con el tratamiento que se le da a la función objetivo. Si se intenta resolver ésta en forma vectorial se habla de una solución no agregativa puesto que no se desarrolló ninguna agregación de las funciones objetivos presentes en el problema inicial. Por otro lado, cuando se intenta transformar el problema multiobjetivo en uno mono-objetivo se habla de una solución agregativa.

Figura 4-2 Segundo Nivel de Clasificación Jerárquica



Las soluciones agregativas dan origen a un tercer nivel basado en la forma como se realiza dicha agregación. Si en la agregación se utilizan algunas de las funciones objetivos como restricciones se habla de una agregación con restricciones; en cambio, si se unen todas las funciones objetivos en una sola se habla agregación sin restricciones; cuando se aplican ambos tipos de agregaciones nos enfrentamos a una agregación híbrida, tal como se muestra en la Figura 4 – 3.

Figura 4-3 Jerarquía según el Tratamiento MOP



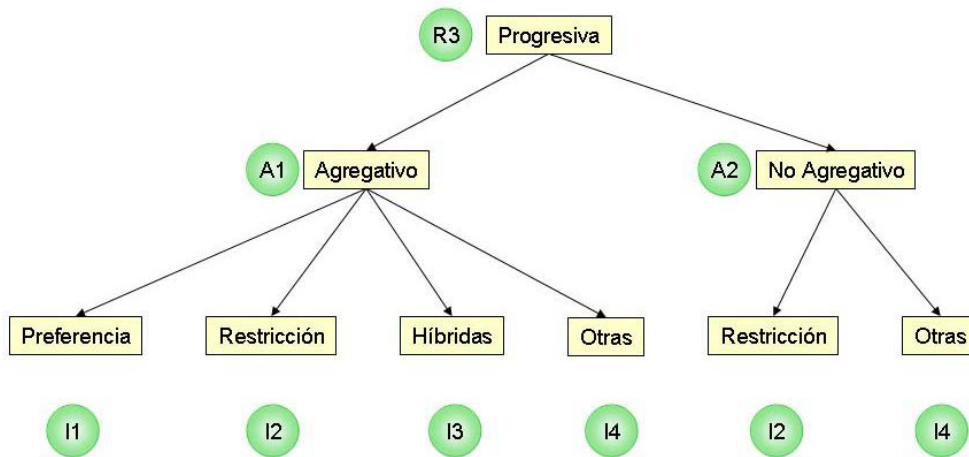
El último nivel está determinado por la correspondencia entre el método de tratamiento multiobjetivo con el método de optimización. Si se utiliza un método de

tratamiento multiobjetivo totalmente independiente del método de optimización se habla de un método desacoplado. De lo contrario se habla de uno acoplado

4.1.2 Métodos Según las Interacciones

Para los métodos de este grupo el modo de interacción es un elemento discriminante importante después de la agregación. En esencia los métodos interactivos funcionan de cuatro formas diferentes: Interacciones por preferencias, por restricciones, híbrida con respecto a las dos anteriores e interacciones de otra clase. El árbol de categorías quedaría como se muestra en la Figura 4 – 4.

Figura 4-4 Jerarquía Según las Interacciones

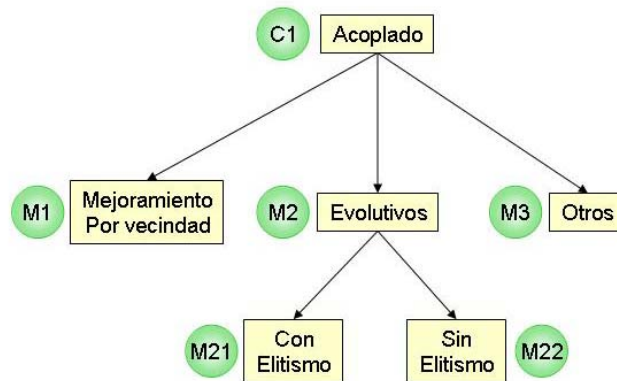


4.1.3 Clasificación Según los Métodos de Optimización

En esta clasificación se pretende profundizar en la jerarquía específica de los métodos acoplados (ver Figura 4 – 5), por lo que Collette [COL03] presenta tres familias:

- Método de mejoramiento por vecindad: Se utiliza un punto de inicio y se empieza el mejoramiento de éste a través de un análisis de todo o parte del vecindario.
- Métodos evolutivos: Consiste en la transformación de individuos de una población a fin de aproximarlos a un área óptima o un punto óptimo.
- Métodos varios: con este nombre se hace referencia a los métodos que se utilizan con menor frecuencia en el dominio de la optimización multiobjetivo por ejemplo los métodos de solución mediante la construcción de soluciones y los métodos de solución por descomposición.

Figura 4-5 Clasificación según los Métodos de Optimización



En lo que respecta a los métodos evolutivos es necesario hacer una diferencia entre métodos evolutivos con elitismo y sin elitismo. Los métodos evolutivos con elitismo se caracterizan por la utilización de un archivo en el cual se guardan los mejores individuos encontrados en una ejecución de optimización; posteriormente, estos individuos pueden ser transmitidos a la siguiente generación o pueden ser utilizados para mejorar el método.

4.1.4 ¿Cuál método escoger para solucionar un problema multiobjetivo?

La clasificación presentada en la sección anterior se convierte en una herramienta importante en la escogencia del método para la solución de un problema

multiobjetivo particular. De manera general se puede aconsejar la utilización de metaheurística cuando en el problema el óptimo es muy difícil de localizar; estos son los problemas típicos en donde, para encontrar una solución aproximada, se puede tardar horas o días debido a que están constituidos por muchos elementos estratégicos. Para esta clase de problemas sería un error escoger algunos de los métodos de interacción por el requerimiento de tiempo que demandaría del usuario que guía el método.

Por otra parte, si la estructura del espacio de búsqueda no se conoce con precisión es arriesgado utilizar métodos escalares dado que se podría obtener como solución un óptimo local o el problema podría presentar una estructura no convexa; igualmente arriesgado sería la utilización de métodos a priori dado el desconocimiento del espacio de búsqueda.

A continuación se presenta una clasificación tomada de [COL03] en donde se categorizan los métodos más comunes empleados para la solución de problemas de optimización multiobjetivos (MOP).

- **Métodos Escalares:** Con este nombre se conoce a los métodos que intentan resolver problemas de optimización multiobjetivo usando una aproximación sencilla, generalmente transforman el problema inicial en un problema de optimización mono-objetivo.

Tabla 4-1 Clasificación de Métodos Escalares

Método	Jerarquía
Weighted sum of objective functions	R1/A12/C2
Keeney-Raiffa	R1/A12/C2
Distance to an objective	R1/A12/C2
Compromise	R1/A11/C2
Hybrid	R1/A13/C2
Goal attainment	R1/A11/C2
Goal programming	R1/A11/C2
Lexicographic ordering	R1/A11/C2
Proper equality constraints	R2/A11/C2
Proper inequality constraints	R2/A11/C2

Lin-Tabak	R2/A11/C2
Lin-Giesy	R2/A11/C2

- **Métodos Interactivos:** Los métodos interactivos le permiten al usuario encontrar sólo una solución. Pertenecen a la familia de los métodos progresivos y le permiten al usuario definir sus preferencias con respecto a la negociación entre las funciones objetivos durante la ejecución del método de optimización.

Tabla 4-2 Clasificación de Métodos Interactivos

Método	Jerarquía
Surrogate worth tradeoff	R3/I2/C2
STEP	R3/I2/C2
Gandel	R3/I2/C2
Jahn	R3/I4/C2
Geoffrion	R3/I4/C2
Simplex	R3/I1/C2

- **Métodos Difusos:** Hace referencia a los métodos que utilizan la lógica difusa para resolver problemas de optimización multiobjetivos. La lógica difusa puede estar presente en los parámetros del problema, en los parámetros de las restricciones y aún en el conjunto de soluciones.

Tabla 4-3 Clasificación de Métodos Difusos

Método	Jerarquía
Sakawa	R1/A12/C2
Reardon	R1/A12/C2

- **Métodos Basados en Metaheurística:** Estos métodos de optimización están generalmente dedicados a problemas de optimización difíciles. Una metaheurística es un método general el cual necesita algunas transformaciones menores antes de ser aplicado a la solución de un problema

en particular. Las principales metaheurísticas son el recocido simulado, la búsqueda tabú y algoritmos genéticos.

Tabla 4-4 Clasificación de Métodos Interactivos

Método	Jerarquía
PASA	R _{1,2} /A12/C1/M1
MOSA	R _{1,2} /A12/C1/M1
MOGA	R2/A2/C1/M2/M21
NSGA	R2/A2/C1/M2/M21
NPGA	R2/A2/C1/M2/M21
WARGA	R2/A2/C1/M2/M21

Los métodos PASA y MOSA fueron clasificados como R_{1,2} debido a que en la práctica son bastante utilizados como métodos a posteriori (R2), sin embargo teóricamente son clasificados como métodos a priori (R1).

Aunque en esta última clasificación no aparecen los métodos SPEA, SPEA2, NSGA2 y cNSGA por ser métodos recientes, estos pueden ser clasificados de la misma forma que el NSGA por el parecido de funcionamiento salvo algunas diferencias de elitismo que se tratará en las siguientes secciones.

4.2 ALGORITMOS EVOLUTIVOS MULTI OBJETIVOS

Para la mayoría de los MOPs, el conocimiento del Frente Pareto óptimo ayuda al tomador de decisiones a seleccionar aquella solución que representa el mejor compromiso. Generar dicho frente puede ser computacionalmente costoso o incluso imposible, en especial en problemas reales de ingeniería. Entonces, lo único que se puede pretender es obtener una buena aproximación al frente Pareto óptimo verdadero. Los algoritmos evolutivos multiobjetivo son una alternativa práctica en la búsqueda de soluciones de compromiso para problemas reales donde los métodos exactos son inaplicables o ineficientes.

Durante la ejecución de un MOEA (por las siglas en inglés de Algoritmos Evolutivos Multiobjetivo) basado en dominancia Pareto, un conjunto de soluciones Pareto óptimas con respecto a la población genética actual es encontrado en cada generación.

Siguiendo la notación utilizada en [LÜC 04], a dicho conjunto se le denomina $P_{known}(t)$, donde t representa el número de generaciones transcurridas desde el inicio del procedimiento evolutivo. El frente Pareto correspondiente a $P_{known}(t)$ se denota como $PF_{known}(t)$. El conjunto de soluciones obtenidas al final de la ejecución de un MOEA basado en Pareto, esto es, el conjunto Pareto conocido, se denota con P_{known} . La notación utilizada para el frente Pareto asociado es PF_{known} .

Cuando se resuelve un MOP utilizando MOEAs, la suposición implícita es que se cumple con al menos una de las siguientes relaciones:

$PF_{known} = PF^*$, $PF_{known} \subset PF^*$, o $PF_{known} \approx PF^*$, donde PF^* representa el frente Pareto óptimo teórico real.

En relación con la clasificación presentada con anterioridad es necesario anotar que los MOEAs hacen parte de los métodos basados en metaheurística y que por consiguiente están en la jerarquía R2/A2/C1/M2/{E1, E2}

Coello [COE02a] presenta una clasificación al interior de los MOEAs en dos sentidos, en primera instancia clasifica según su funcionamiento en:

- Los algoritmos que no incorporan el concepto de óptimo de Pareto en el mecanismo de selección del algoritmo evolutivo (los que usan funciones agregativas lineales).
- Los algoritmos que jerarquizan a la población de acuerdo a si un individuo es no dominado o no (usando el concepto de óptimo de Pareto). Ejemplos: MOGA, NSGA, NPGA entre otros.

Históricamente los MOEAs se pueden clasificar en:

- **Primera Generación:** Caracterizada por el uso de jerarquización de Pareto y nichos. Algoritmos relativamente simples. También se produjeron enfoques más rudimentarios. Ejemplo: funciones agregativas lineales.
- **Segunda Generación:** Se introduce el concepto de elitismo en dos formas principales: usando selección ($\mu + \sigma$) y usando una población secundaria.

Desde finales de la década de los 90 los algoritmos evolutivos multiobjetivo que usan elitismo son vistos como el estado del arte en el área. Es el caso de los algoritmos SPEA, SPEA2, NSGA-II, cNSGA-II, entre otros. Esto se debe a que los algoritmos de segunda generación enfatizan la eficiencia computacional. Se busca vencer la complejidad de la jerarquización de Pareto ($O(kM^2)$, donde k es el número de funciones objetivo y M es el tamaño de la población) y de las técnicas tradicionales de nichos ($O(M^2)$).

Actualmente, según lo presentan Coello [COE02b] los algoritmos evolutivos de segunda generación son los más utilizados en el área de ingeniería. Específicamente Zitzler [ZIT02] destaca la superioridad de algoritmos como el SPEA, SPEA2, PESA y NSGA-II. Particularmente, en ambientes multicast Talavera [TAL04] destaca el amplio uso de los algoritmos NSGA, NSGA-II, SPEA, SPEA2 y cNSGA2, demostrando la eficiencia de SPEA2 sobre los demás.

4.3 ALGORITMOS EVOLUTIVOS MULTI OBJETIVOS EN AMBIENTES MULTICAST

La presente investigación, intitulada “Optimización Multiobjetivo sobre Redes Ópticas en Transmisión Multicast” requiere de un método confiable para la solución del problema de optimización multiobjetivo. Por la naturaleza del problema de investigación en donde se podría necesitar de al menos tres variables de decisión,

cada una de ellas estratégicas para la toma de decisiones, se tiene el antecedente en [DON03a] que este tipo de problemas son problemas difíciles de optimización y además se desconoce la cantidad de óptimos locales o la forma del espacio de búsqueda.

Por esta razón y siguiendo los lineamientos de la sección 4.1, se requiere de un método basado en metaheurística, lo que nos ubica en la jerarquía R2/A2/C1/M2 como los métodos basados en metaheurística de segunda generación tienden a ser más eficientes en tiempo computacional según lo presentado en la sección 4.2 y teniendo en cuenta que ellos trabajan utilizando elitismo esto nos ubica en la jerarquía R2/A2/C1/M2/M21; en donde se ubican algoritmos como el NSGA y todos los MOEAs de segunda generación.

A continuación se realiza una breve descripción de los algoritmos evolutivos de segunda generación más utilizados en la solución de problemas de optimización multiobjetivo en ambientes multicast a saber: NSGA2, SPEA, SPEA2 y cNSGA2.

4.3.1 NSGA2: Non dominated Sort Genetic Algorithm 2

NSGA2 es una versión revisada de su antecesor el NSGA, es más eficiente computacionalmente, no utiliza memoria externa, es elitista y no necesita de parámetros adicionales para su ejecución. El mecanismo elitista consiste en elegir los mejores individuos de la unión de las poblaciones padre e hijo. La figura 4 – 6 muestra el pseudocódigo de este método.

Figura 4-6 Algoritmo NSGA2

```
- Leer grupo multicast a enrutar.
- Inicializar población P.
- Ordenar P, considerando dominancia.
- Evaluar Individuos de P.
- Aplicar operadores genéticos a P, para tener Q
- t=0 //cantidad de generaciones
Hacer {
  - R = P U Q.
  - ordenar R, considerando dominancia y obtener frentes Fi
  - l=1
  Mientras |Pt+1| < N { // N numero de individuos en P
    - Calcular adaptabilidad de cada individuo en Fi
    - Pt+1 = Pt+1 U Fi
    l = l + 1
  }
  - Ordenar Pt+1 por dominancia.
  - Elegir los primeros N elementos de Pt+1
  - Aplicar operadores genéticos a Pt+1, para tener Qt+1
  - t = t + 1
} mientras el criterio de parada no sea alcanzado.
```

4.3.2 cNSGA2: Controlled Non dominated Sort Genetic Algorithm 2

cNSGA2 es una variación del NSGA2 cuya diferencia principal está en que a diferencia de su predecesor, que elige los primeros N elementos de la población P_{t+1} , el cNSGA2 utiliza una proporción geométrica para elegir n_i individuos de cada frente i , siendo $n_i = r * n_{i-1}$, donde r es la razón geométrica, tal como se muestra en la figura 4 – 7.

Figura 4-7 Algoritmo cNSGA2

```
- Leer grupo multicast a enrutar.  
- Inicializar población P.  
- Ordenar por no dominados P.  
- Evaluar Individuos de P.  
- Aplicar operadores genéticos a P, para tener Q  
- t=0 //cantidad de generaciones  
Hacer {  
  -  $R_t = P_t \cup Q_t$ .  
  - F = ordenar por no dominados  $R_t$   
  - l=1  
  Hasta  $|P_{t+1}| < N$  { // N numero de individuos en P  
    - Asignar la distancia  $F_i$   
    - Ordenar  $F_i$   
    -  $P_{t+1} = P_{t+1} \cup F_i[n_i:0]$  //se asignan los  $n_i$  elementos de  $F_i$   
  }  
  l = l + 1  
  }  
  - Aplicar operadores genéticos a  $P_{t+1}$ , para tener  $Q_{t+1}$   
  - t++  
} mientras el criterio de parada no sea alcanzado.
```

4.3.3 SPEA: Strength Pareto Evolutionary Algorithm

El SPEA utiliza un archivo que contiene las soluciones no dominadas encontradas (población externa de no dominados P_{nd}). En cada generación, se copian los individuos no dominados de P a P_{nd} y se borra de este las soluciones dominadas. Para cada individuo en el sistema externo, se computa un valor de fuerza (strength) proporcional al número de las soluciones a las cuales cada individuo domina. En SPEA, el fitness de cada miembro de la población actual se computa según las fuerzas de todas las soluciones no dominadas externas que la dominen.

Figura 4-8 Algoritmo SPEA

```
- Leer grupo multicast a enrutar.  
- Inicializar población P.  
Hacer {  
    - Evaluar Individuos de P.  
    - Marcar soluciones no dominadas de P.  
    - Actualizar el conjunto de soluciones no dominadas  $P_N$   
    - Calcular la adaptabilidad de los individuos de P y  $P_N$   
    - Seleccionar individuos del conjunto  $P_N$   
    - Aplicar los operadores de cruzamiento y mutación.  
} mientras el criterio de parada no sea alcanzado.
```

4.3.4 SPEA2: Strength Pareto Evolutionary Algorithm 2

Este método fue presentado por Zitzler en [ZIT02]. Se diferencia del SPEA básicamente en dos puntos a saber:

- Incorpora una estrategia fina de asignación del fitness que considera, para cada individuo, el número de los individuos que lo dominan y el número de los individuos por los cuales es dominado;
- Utiliza la técnica del “vecino más cercano” para la valoración de la densidad, dirigiendo la búsqueda en forma más eficiente.

En la figura 4 – 9 se presenta el pseudocódigo del método a fin de apreciar dichos cambios.

Figura 4-9 Algoritmo SPEA2

```
- Leer grupo multicast a enrutar.  
- Inicializar población P.  
Hacer {  
  - Evaluar Individuos de P.  
  - Marcar soluciones no dominadas de P.  
  - Actualizar el conjunto de soluciones no dominadas  $P_N$   
  - Calcular la adaptabilidad de los individuos de P y  $P_N$   
  - Seleccionar individuos del conjunto  $P \cup P_N$   
  - Aplicar los operadores de cruzamiento y mutación.  
} mientras el criterio de parada no sea alcanzado.
```

4.3.5 Escogencia del Mejor Método en Ambiente Multicast

Con base a la investigación realizada por Talavera [Tal04] y a las pruebas presentadas por Zitzler [ZIT02] al presentar el método SPEA2, se puede concluir que el método más eficiente en este tipo de ambientes es el SPEA2.

Las pruebas realizadas [TAL04] mostraron que los algoritmos NSGA2, cNSGA2, SPEA y SPEA2 poseen el mismo rendimiento cuando el grupo multicast es pequeño. No obstante, cuando el número de nodos destinos es de 19 o más se hace evidente la mejora del SPEA y el SPEA2 sobre los demás métodos. Sin embargo, cabe destacar que cNSGA2 puede ser tan bueno como el SPEA2 si se varía el parámetro R del mismo, el inconveniente es poder determinar el valor óptimo de ese parámetro.

Por su parte [ZIT02] después de realizar varias pruebas con problemas continuos y combinatorios concluye que SPEA2 es mejor que el SPEA en todas las pruebas y, al igual que Talavera, Zitzler concluye que SPEA2 es mejor que NSGA2 en problemas con espacio objetivo de altas dimensiones.

4.4 MÉTODOS BASADOS EN LÓGICA DIFUSA PARA LA SOLUCIÓN DE PROBLEMAS MULTIOBJETIVOS

Los métodos basados en lógica difusa o métodos difusos, hace referencia a los métodos que utilizan la lógica difusa para resolver problemas de optimización multiobjetivos. La lógica difusa puede estar presente en los parámetros del problema, en los parámetros de las restricciones y aún en el conjunto de soluciones. A continuación se presentan los dos métodos más utilizados y conocidos en ésta área. Ambos son métodos agregativos sin restricciones, por lo que se clasifican como R1/A12/C2.

4.4.1 Método de Reardon

El método es presentado por Reardon en [REA97a] y [REA97b], no obstante es ampliamente explicado por Coello [COE02a].

Para cada función objetivo se define una función de membresía como se presenta en la figura 4 – 10. En donde:

S_{min} y S_{max} : Factores de escala difusa.


$f_{i_{min}}$: Valor mínimo de la i-ésima función objetivo.

$f_{i_{max}}$: Valor máximo de la i-ésima función objetivo.

O_i : Valor experimental de la i-ésima función objetivo, idealmente $f_i = O_i$

E_i : Margen de error aceptable (el objetivo O_i tiene un intervalo de satisfacción de amplitud $2 * E_i$)

Figura 4-10 Función de Membresía de Reardon



Esta función de membresía permitirá informar al algoritmo que la función objetivo tiene sus valores localizados en el intervalo $[O_i - E_i, O_i + E_i]$, el cual especifica el área en donde el valor de la función de membresía es 0. Si el valor de la función objetivo se localiza fuera de este intervalo la misma es penalizada con un valor que oscila entre 0 y S_{min} o S_{max}

La Ecuación de la función de membresía es la siguiente:

- Si $f_i \leq (O_i - E_i)$ entonces, $f'(f_i) = \left[\frac{S_{max}}{f_{i_{min}} - (O_i - E_i)} \right] * (f_i - (O_i - E_i))$
- Si $(O_i - E_i) \leq f_i \leq (O_i + E_i)$ entonces, $f'(f_i) = 0$
- Si $f_i \geq (O_i + E_i)$ entonces, $f'(f_i) = \left[\frac{S_{min}}{(O_i + E_i) - f_{i_{max}}} \right] * (f_i - (O_i + E_i))$

Se debe tener en cuenta que en este método se manejan valores lógicos invertidos, es decir, el valor de la función de membresía es igual a cero cuando f_i alcanza el intervalo de valores deseado. Precisamente esta inversión de los valores de

membresía permite obtener una función objetivo más sencilla la cual se forma de la agregación de las funciones objetivos:

$$F = \frac{1}{N} * \sum_{i=1}^N f'_i(f_i)$$

Con esta función objetivo resolver el problema equivale a minimizar F . Por lo que sólo es necesario encontrar un punto tal que $f'_i(f_i)$ sea mínimo o que el nivel de membresía sea el más alto posible.

4.4.2 Método de Sakawa

Este método usa lógica difusa en todos los niveles, desde los parámetros del problema hasta en los parámetros de las restricciones e incluso en el conjunto de soluciones encontradas. Sakawa [SAK02] utiliza un nivel de membresía para las soluciones, lo cual significa que las soluciones tienen un nivel de correlación con el objetivo inicial el cual es establecido por el tomador de decisiones. Un resumen detallado del método puede ser consultado en [COE02a].

Sakawa [SAK02] establece que en algunos problemas de optimización multiobjetivo sería más apropiado considerar que los valores de los parámetros de la función objetivo y de las restricciones involucran cierta ambigüedad debido al desconocimiento del experto en cuanto al funcionamiento del sistema real durante el proceso de formulación del problema. Por lo que plantea un modelo de problema de programación no lineal multiobjetivo con números difusos (MONLP-FN) a saber:

$$\text{minimizar } f(x, \tilde{a}) = (f_1(x, \tilde{a}_1), \dots, f_k(x, \tilde{a}_k))$$

$$\begin{aligned} & g_j(x, \tilde{b}_j) \leq 0, j = 1, \dots, m_1 \\ \text{sujeto a } & h_j(x, \tilde{b}_j) = 0, j = m_1 + 1, \dots, m \\ & l_i \leq x_i \leq u_i, i = 1, \dots, n \end{aligned}$$

donde $x = (x_1, \dots, x_n)$ es un vector n-dimensional de variables de decisión; $f_i(x, \tilde{a}_i), i = 1, \dots, k$ corresponden a k funciones objetivos en conflicto; $g_j(x, \tilde{b}_j) \leq 0, j = 1, \dots, m_1$ son m_1 restricciones de desigualdad; $h_j(x, \tilde{b}_j) = 0, j = m_1 + 1, \dots, m$ corresponde a $m - m_1$ restricciones de igualdad y l_i y $u_i, i = 1, \dots, n$ corresponden a los límites inferiores y superiores de las variables de decisión. Por otra parte, $\tilde{a}_i = (\tilde{a}_{i1}, \dots, \tilde{a}_{ik_i})$ y $\tilde{b}_j = (\tilde{b}_{j1}, \dots, \tilde{b}_{jm_j})$ representan vectores de números difusos involucrados en la i -ésima función objetivo y en la j -ésima función de restricción, respectivamente. Se asume que estos números difusos se caracterizan por su función de membresía $\mu_{\tilde{a}_i}(a_i) = (\mu_{\tilde{a}_{i1}}(a_{i1}), \dots, \mu_{\tilde{a}_{ik_i}}(a_{ik_i}))$ y $\mu_{\tilde{b}_j}(b_j) = (\mu_{\tilde{b}_{j1}}(b_{j1}), \dots, \mu_{\tilde{b}_{jm_j}}(b_{jm_j}))$ respectivamente.

Dado que los MONLP-FN involucran números difusos tanto en las restricciones como en las funciones es necesario extender la noción usual de optimalidad en el sentido Pareto. Por lo que Sakawa introduce la definición de “conjunto de nivel α ” para los vectores de números difusos \tilde{a}_i y \tilde{b}_j .

Conjunto de nivel α : El conjunto de nivel α de los vectores de números difusos \tilde{a}_i y \tilde{b}_j se define como el conjunto $(\tilde{a}, \tilde{b})_\alpha$ para el cual el grado de su función de membresía excede el nivel α .

$$(\tilde{a}, \tilde{b})_\alpha = \{(a, b) / \mu_{\tilde{a}_r}(a_{ir}) \geq \alpha, \mu_{\tilde{b}_s}(b_{js}) \geq \alpha, i = 1, \dots, k, r = 1, \dots, k_i, j = 1, \dots, m, s = 1, \dots, m_j\},$$

donde $a_i = (a_{i1}, \dots, a_{ik_i}), b_j = (b_{j1}, \dots, b_{jm_j}), a = (a_1, \dots, a_k), b = (b_1, \dots, b_m)$.

Para un cierto grado α , el MONLP-FN puede ser interpretado como el siguiente problema α -MONLP no difuso.

$$\begin{aligned} & \text{minimizar } f(x, a) = (f_1(x, a_1), \dots, f_k(x, a_k)) \\ & \text{sujeto a } \begin{aligned} & g_j(x, b_j) \leq 0, j = 1, \dots, m_1 \\ & h_j(x, b_j) = 0, j = m_1 + 1, \dots, m \\ & l_i \leq x_i \leq u_i, i = 1, \dots, n \\ & (a, b) \in (\tilde{a}, \tilde{b})_\alpha \end{aligned} \end{aligned}$$

(a, b) se tratan como variables de decisión, no como constantes.

A partir de la introducción de α -MONLP Sakawa define los conceptos de optimalidad α -Pareto y optimalidad local α -Pareto donde $X(b)$ denota la región factible que satisface todas las restricciones del α -MONLP con respecto a x , como sigue a continuación.

Solución Óptima α -Pareto. Se dice que $x^* \in X(b)$ es una solución óptima α -Pareto para α -MONLP si y solamente si no existe otro $x \in X(b)$ y $(a, b) \in (\tilde{a}, \tilde{b})_\alpha$ tal que $f_i(x, a_i) \leq f_i(x^*, a_i^*), i = 1, \dots, k$ con desigualdad estricta para al menos un i , donde los correspondientes valores de los parámetros a^* y b^* son llamados parámetros óptimos de nivel α .

Solución Óptima Local α -Pareto. Se dice que $x^* \in X(b) \cap N(a^*, b^*; \delta')$ es una solución óptima α -Pareto para α -MONLP si y solamente si no existe otro $x \in X(b)$ y $(a, b) \in (\tilde{a}, \tilde{b})_\alpha$ tal que $f_i(x, a_i) \leq f_i(x^*, a_i^*), i = 1, \dots, k$ con desigualdad estricta para al menos un i , donde los correspondientes valores de los parámetros a^* y b^* son llamados parámetros óptimos de nivel α .

Cabe anotar que las soluciones óptimas α -Pareto y soluciones óptimas locales α -Pareto se pueden obtener mediante una aplicación directa de métodos escalares al tomar las variables de decisión en el α -MONLP como (x, a, b) .

Para el α -MONLP, considere la vaguedad o naturaleza difusa del juicio humano, es natural asumir que el tomador de decisiones puede tener un **objetivo difuso** para cada una de las funciones objetivos $f_i(x, a_i)$. En un problema de minimización, el objetivo difuso establecido por el tomador de decisiones puede ser interpretado como “sustancialmente menor o igual que algún valor p_i ”. Este tipo de oración puede ser cuantificada al elitizar la correspondiente función de membresía $\mu_i(f_i(x, a_i))$, esta es una función estrictamente monótona decreciente con respecto a $f_i(x, a_i)$. El problema puede ser expresado ahora como:

$$\begin{aligned} &\text{minimizar difuso} && f_i(x, a_i), i = 1, \dots, k \\ &\text{sujeto a} && x \in X(b) \\ &&& (a, b) \in (\tilde{a}, \tilde{b})_\alpha \end{aligned}$$

La noción de la solución óptima α -Pareto definida en término de las funciones objetivos no es aplicable en este tipo de problemas, por lo que se hace necesario introducir los conceptos de solución óptima M- α -Pareto y solución óptima local M- α -Pareto, los cuales se definen en términos de la función de membresía en vez de las funciones objetivos, M hace referencia a la función de membresía.

Solución Óptima M- α -Pareto: Se dice que $x^* \in X(b)$ es una solución optima M- α -Pareto para el $G\alpha$ -MONLP si y solamente si no existe otro $x \in X(b)$ y $(a, b) \in (\tilde{a}, \tilde{b})_\alpha$ tal que $\mu_i(f_i(x, a_i)) \geq \mu_i(f_i(x^*, a_i^*)), \forall i$ y

$\mu_j(f_j(x, a_j)) \neq \mu_j(f_j(x^*, a_j^*))$ para al menos un j , donde los correspondientes valores de los parámetros a^* y b^* son llamados parámetros óptimos de nivel α .

Solución Óptima Local M- α -Pareto: Se dice que $x^* \in X(b)$ es una solución óptima local M- α -Pareto para el G α -MONLP si y solamente si no existe otro $x \in X(b) \cap N(x^*, \delta) \cap N(a^*, b^*; \delta')$ y $(a, b) \in (\tilde{a}, \tilde{b})_\alpha \cap N(a^*, b^*; \delta')$ tal que $\mu_i(f_i(x, a_i)) \geq \mu_i(f_i(x^*, a_i^*)), \forall i$ y $\mu_j(f_j(x, a_j)) \neq \mu_j(f_j(x^*, a_j^*))$ para al menos un j , donde los correspondientes valores de los parámetros a^* y b^* son llamados parámetros óptimos de nivel α .

Después de determinar la función de membresía $\mu_i(f_i(x, a_i))$ para cada una de las funciones objetivos $f_i(x, a_i), i = 1, \dots, k$ tanto para α -MONLP como para G α -MONLP, se le pide al tomador de decisiones especificar el nivel de membresía en referencia para todas las funciones de membresía y el grado α . La correspondiente solución óptima (local) (M-) α -Pareto se obtiene resolviendo el problema minimax:

$$\min_{\substack{x \in X(b) \\ (a, b) \in (\tilde{a}, \tilde{b})_\alpha}} \max_{i=1, \dots, k} \{\bar{\mu}_i - \mu_i(f_i(x, a_i))\}$$

Sin embargo, Sakawa propone que se utilice el problema minimax aumentado, el cual queda especificado por:

$$\min_{\substack{x \in X(b) \\ (a, b) \in (\tilde{a}, \tilde{b})_\alpha}} \max_{i=1, \dots, k} \{\bar{\mu}_i - \mu_i(f_i(x, a_i)) + \rho \sum_{i=1}^k (\bar{\mu}_i - \mu_i(f_i(x, a_i)))\}$$

Es importante notar que el término aumentado se adopta porque al problema minimax estándar se agrega el término $\rho \sum_{i=1}^k (\bar{\mu}_i - \mu_i(f_i(x, a_i)))$, donde ρ es un escalar positivo suficientemente pequeño.

Sin embargo, Sakawa recomienda utilizar la siguiente función de fitness:

$$f(s) = 1.0 + k\rho - \max_{i=1, \dots, k} \{ \bar{\mu}_i - \mu_i(f_i(x, a_i)) + \rho \sum_{i=1}^k (\bar{\mu}_i - \mu_i(f_i(x, a_i))) \}$$

Para que el problema minimax aumentado pueda involucrar no convexidad.

5 FORMULACIÓN MATEMÁTICA DEL PROBLEMA

En concordancia con [DON03c] la red donde se realizará la optimización es modelada por un grafo $G = (N, E)$ en el cual el conjunto de nodos es denotado por la letra N y el conjunto de enlaces por la letra E . Se considera a T como el conjunto de nodos egresos, $T \subset N$. El nodo origen en la transmisión está denotado por $s \in N$ (nodo ingreso) y $t \in T$ puede ser cualquier nodo destino. El enlace existente entre el nodo i y el nodo j se denota como (i, j) , teniendo en cuenta que $(i, j) \in E$. Sea Λ el conjunto de lambdas, la variable $\lambda \in \Lambda$ indica la longitud de onda de la fibra utilizada para la transmisión en el enlace $(i, j) \in E$. La letra f representa el flujo Multicast, $f \in F$ que es el conjunto de flujos y T_f denota los nodos destinos subconjunto del flujo Multicast.

El objetivo del modelo de optimización a plantear es minimizar al mismo tiempo:

- El número de longitudes de onda utilizadas.
- La atenuación máxima en un enlace.
- El retardo. Para lo cual se tiene en cuenta el retardo total, retardo promedio, retardo máximo y la máxima variación del retardo.
- El número de saltos. En donde se debe considerar número de saltos total, promedio de número de saltos, máximo número de saltos y la máxima variación del número de saltos.
- Ancho de banda consumido.

Con este fin, se define la variable $X_{ij}^{\lambda ft}$ como una variable binaria la cual representa la presencia o no de información en el árbol multicast t del flujo f en la longitud de onda λ en el enlace (i, j) . En otras palabras:

$$X_{ij}^{wft} = \begin{cases} 1, & \text{si el flujo } f \text{ es transmitido} \\ & \text{en } w \text{ por el } (i, j) \in E \text{ con} \\ & \text{destino } t. \\ 0, & \text{en otro caso} \end{cases} \quad \text{donde } X_{ij}^{wft} \in \mathbb{Z}$$

5.1 MODELO MATEMÁTICO

5.1.1 Longitudes de Onda

A partir de la variable $X_{ij}^{\lambda ft}$ se construye la ecuación para el primer objetivo a minimizar, para esto se tiene en cuenta sólo los enlaces utilizados (aquellos para los que el valor de X es uno), razón por la cual se utiliza la función *max*. Además, el número de longitudes de onda utilizadas se calcula para todo flujo y todos los destinos del árbol multicast.

$$\sum_{\lambda} \sum_{(i,j) \in E} \max(X_{ij}^{\lambda ft})_{ft}$$

5.1.2 Atenuación

Como se describe en [MUK97], la atenuación en la fibra óptica es la reducción de la potencia de la señal a medida que ésta se propaga a lo largo de la fibra. Con el fin de conocer cuál es la distancia máxima que puede recorrer una señal para que ésta pueda ser detectada por el receptor, se debe tener en cuenta la sensibilidad de éste último, en otras palabras, conocer la mínima potencia que se requerida para el reconocimiento de la señal.

Si L es la distancia en kilómetros (km) entre dos nodos comunicados a través de fibra óptica y A la constante de atenuación (la cual depende del tipo de fibra que se esté utilizando) dada en dB/Km; entonces, la potencia requerida es:

$$P(L) = 10^{-A_{ij} * L_{ij} / 10} * P(i)$$

donde $P(i)$ es la potencia del nodo emisor de la señal.

El segundo objetivo a minimizar es la Atenuación. En este caso se desea minimizar la máxima atenuación de un flujo dado debido a que en un árbol multicast la atenuación puede variar entre enlaces. La ecuación

$$\sum_f \sum_{\lambda} \sum_{(i,j) \in E} \left[(10^{-A_{ij} * L_{ij} / 10} * P(i)) * \max(X_{ij}^{\lambda ft})_t \right]_{f, \lambda, (i,j) \in E}$$

representa la atenuación en la fibra en el enlace (i, j) hacia el destino t .

5.1.3 Retardo

En una red, el retardo es una expresión de qué tanto tiempo le toma a un paquete viajar desde un nodo origen hasta su destino.

Existen varios tipos de retardo:

- **Retardo de Colas.** Cada enrutador de una red toma un poco de tiempo para examinar el paquete que recibe y cambiar la cabecera del mismo; esto produce un poco de represamiento en el dispositivo a medida que llegan más paquetes. En la investigación, este retardo no se toma en cuenta debido a que se está evaluando el proceso de transmisión multicast en redes conmutadas, donde sólo hay dos enrutadores (entrada y salida).
- **Retardo de Conmutación.** En cada conmutador que se encuentra en una red óptica, se requiere que se convierta la información Óptico – Eléctrico, con el fin

de que se pueda establecer el puerto de reenvío de la información y una segunda conversión Eléctrico – Óptico, para el reenvío en sí.

En la investigación, se considera este tiempo despreciable, debido a que la red de estudio está conformada por conmutadores OOO (óptico – óptico – óptico), que no requieren las conversiones descritas anteriormente.

- **Retardo de Transmisión.** En una red óptica, consiste en el tiempo que se toma un paquete para viajar de un sitio a otro a la velocidad de la luz.

Este es el retardo que se tiene en cuenta en la investigación, el cual está afectado directamente por la distancia entre dos nodos.

- **Retardo Jitter – Buffer.** Es el retardo que experimentan las aplicaciones multimedia de tiempo real; que en ocasiones repercute en la entrega no continua o fluida de la información. Con el fin de evitar esto, se adiciona un buffer, en el que se almacenan los paquetes recibidos y la tasa de entrega al nivel superior se ajusta de acuerdo al rendimiento de la red.

Debido a que este tipo de retardo afecta a un determinado grupo de aplicaciones, no se tendrá en cuenta en el modelo.

Para la minimización del retardo se tiene en cuenta el retardo total, el retardo promedio, el retardo máximo y la máxima variación del retardo. La minimización de cada una de estas medidas conduce a la minimización del retardo en general, debido a que en un camino, se puede encontrar un enlace con el menor retardo y, sin embargo, el camino puede hacer parte del árbol multicast con el máximo retardo promedio o con la máxima variación del mismo, haciendo de esta solución poco deseable.

El retardo total se calcula con la ecuación:

$$\sum_f \sum_\lambda \sum_t \sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft}))$$

Donde d_{ij} representa la distancia entre el nodo i y el nodo j .

Por otra parte, el retardo promedio está dado por el retardo total dividido por la norma del conjunto de destinos de cada flujo; en otras palabras, se calcula el retardo promedio del árbol de transmisión multicast por flujo. La ecuación para el retardo promedio es la siguiente:

$$\frac{\sum_f \sum_\lambda \sum_t \sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft}))}{\sum_f |T_f|}$$

También, ha de considerarse el máximo retardo experimentado por un flujo en el árbol de transmisión multicast debido a que afecta directamente la calidad de la información que viaja por ese flujo; es por eso que se plantea la ecuación

$$\max_{\lambda, f, t} \left[\sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft})) \right]$$

Una medida adicional a minimizar en el modelo de optimización es la máxima variación del retardo, puesto que en el mismo árbol se podría encontrar tanto el mínimo como el máximo retardo. La siguiente ecuación nos permite obtener dicha medida.

$$\left(\max_{\lambda, f, t} \left[\sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft})) \right] \right) - \left(\min_{\lambda, f, t} \left[\sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft})) \right] \right)$$

5.1.4 Número de Saltos

Otro de los objetivos a minimizar es el número de saltos; al igual que en el retardo, ha de considerarse el número de saltos total, el promedio de número de saltos, el máximo número de saltos y la máxima variación del número de saltos. Siguiendo un

razonamiento similar a la obtención de las ecuaciones para la optimización del retardo, se tiene:

Número de saltos total, representa la cantidad de nodos por los que pasa un flujo, que viaja en una longitud de onda a través de en un árbol de transmisión multicast para alcanzar un destino t

$$\sum_f \sum_\lambda \sum_t \sum_{(i,j) \in E} (X_{ij}^{\lambda ft})$$

Promedio de numero de saltos, número de saltos total dividido por la norma del conjunto de destinos de cada flujo

$$\frac{\sum_f \sum_\lambda \sum_t \sum_{(i,j) \in E} (X_{ij}^{\lambda ft})}{\sum_f |T_f|}$$

Máximo numero de saltos:

$$\max \left[\sum_{(i,j) \in E} (X_{ij}^{\lambda ft}) \right]_{\lambda, f, t}$$

Máxima variación del número de saltos:

$$\left(\max \left[\sum_{(i,j) \in E} (X_{ij}^{\lambda ft}) \right]_{\lambda, f, t} \right) - \left(\min \left[\sum_{(i,j) \in E} (X_{ij}^{\lambda ft}) \right]_{\lambda, f, t} \right)$$

5.1.5 Ancho de Banda

Como última función objetivo del modelo se desea minimizar el ancho de banda consumido, el cual se representa mediante la siguiente ecuación:

$$\sum_f \sum_{\lambda} \sum_{(i,j) \in E} (b_f * \max(X_{ij}^{\lambda ft}))$$

Donde b_f representa el ancho de banda del flujo.

5.1.6 Modelo Matemático

De los ítems anteriores se obtiene un modelo con cinco objetivos a minimizar ($k = 5$), que están sujetas a $m = 5$ restricciones.

Entre las restricciones se encuentran las leyes de Kirchoff, las cuales garantizan la conservación del flujo y aseguran, adaptadas para este caso, que:

Flujo total que sale desde el nodo fuente a cualquier destino es igual a 1.

$$\sum_{(i,j)} X_{ij}^{\lambda ft} - \sum_{(j,i)} X_{ji}^{\lambda ft} = 1$$

$$\forall t \in T_f, \forall f \in F, \forall \lambda \in \Lambda, i = s$$

- Flujo total que viene de cualquier destino es igual a 1.

$$\sum_{(i,j)} X_{ij}^{wft} - \sum_{(j,i)} X_{ji}^{wft} = 1$$

$$\forall i, t \in T_f, \forall f \in F, \forall \lambda \in \Lambda$$

En los nodos intermedios el flujo de entrada es igual al flujo de salida.

$$\sum_{(i,j)} X_{ij}^{\lambda ft} - \sum_{(j,i)} X_{ji}^{\lambda ft} = 0$$

$$\forall t \in T_f, \forall f \in F, i \neq s, i \neq T_f$$

Otra restricción tiene que ver con el límite del ancho de banda consumido, el cual debe ser menor o igual a la capacidad en el enlace (i, j) . Además, la cantidad de

longitudes de onda debe ser menor o igual que el número máximo disponibles por la fibra utilizada en el enlace (i, j) . Así:

$$\sum_w \max(X_{ij}^{\lambda_{ft}})_f \leq M_{-} X_{ij}, \forall (i, j) \in E$$

Donde $M_{-} X_{ij}$ es el número máximo de longitudes de onda permitido en el enlace $(i, j) \in E$.

La variable C_{ij}^{λ} que representa la capacidad del enlace (i, j) transmitida por la longitud de onda λ ; $b\lambda_{\lambda}$ es ancho de banda utilizado en la longitud de onda λ ; $M_{-} X_{ij}$ es el número máximo de longitudes de onda permitido en el enlace $(i, j) \in E$.

El ancho de banda consumido se convierte en una restricción más del modelo.

$$\sum_f \max(X_{ij}^{\lambda_{ft}})_t * b\lambda_{\lambda} \leq C_{ij}^{\lambda}, \forall (i, j) \in E, \lambda \in \Lambda$$

La anterior ecuación, restringe la suma de los máximos anchos de banda $b\lambda_{\lambda}$ transmitido por la longitud de onda λ del enlace $(i, j) \in E$. La variable C_{ij}^{λ} que representa la capacidad del enlace (i, j) transmitida por la Lambda λ y $b\lambda_{\lambda}$ representa el ancho de banda utilizado en la Lambda λ ; El resultado de la sumatoria debe ser menor o igual a la capacidad del enlace C_{ij}^{λ} .

Luego entonces, el problema de optimización multiobjetivo en redes ópticas con transmisión multicast en el que se optimizan las variables: Retardo, Cantidad de saltos, ancho de banda utilizado, máximo retardo, máxima cantidad de saltos, retardo promedio, cantidad de saltos promedio, cantidad de lambdas, máxima variación del

retardo, máxima variación de la cantidad de saltos y máxima atenuación; puede formularse como:

Minimizar

$$f_0(x) = \sum_f \sum_\lambda \sum_t \sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft}))$$

$$f_1(x) = \sum_f \sum_\lambda \sum_t \sum_{(i,j) \in E} (X_{ij}^{\lambda ft})$$

$$f_2(x) = \sum_f \sum_\lambda \sum_{(i,j) \in E} (b_f * \max(X_{ij}^{\lambda ft})_t)$$

$$f_3(x) = \max \left[\sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft})) \right]_{\lambda, f, t}$$

$$f_4(x) = \max \left[\sum_{(i,j) \in E} (X_{ij}^{\lambda ft}) \right]_{\lambda, f, t}$$

$$f_5(x) = \frac{\sum_f \sum_\lambda \sum_t \sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft}))}{\sum_f |T_f|}$$

$$f_6(x) = \frac{\sum_f \sum_\lambda \sum_t \sum_{(i,j) \in E} (X_{ij}^{\lambda ft})}{\sum_f |T_f|}$$

$$f_7(x) = \sum_\lambda \sum_{(i,j) \in E} \max(X_{ij}^{\lambda ft})_{ft}$$

$$f_8(x) = \left(\max \left[\sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft})) \right]_{\lambda, f, t} \right) - \left(\min \left[\sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft})) \right]_{\lambda, f, t} \right)$$

$$f_9(x) = \left(\max \left[\sum_{(i,j) \in E} (X_{ij}^{\lambda ft}) \right]_{\lambda, f, t} \right) - \left(\min \left[\sum_{(i,j) \in E} (X_{ij}^{\lambda ft}) \right]_{\lambda, f, t} \right)$$

$$f_{10}(x) = \max \left[\left(10^{-A_{ij} * L_{ij} / 10} * P(i) \right) * \max (X_{ij}^{\lambda ft}) \right]_{f, \lambda, (i, j)}$$

Sujeto a

$$\sum_{(i,j)} X_{ij}^{\lambda ft} - \sum_{(j,i)} X_{ji}^{\lambda ft} = 1$$

$$\forall t \in T_f, \forall f \in F, \forall \lambda \in \Lambda, i = s$$

$$\sum_{(i,j)} X_{ij}^{wft} - \sum_{(j,i)} X_{ji}^{wft} = 1$$

$$\forall i, t \in T_f, \forall f \in F, \forall \lambda \in \Lambda$$

$$\sum_{(i,j)} X_{ij}^{\lambda ft} - \sum_{(j,i)} X_{ji}^{\lambda ft} = 0$$

$$\forall t \in T_f, \forall f \in F, i \neq s, i \neq T_f$$

$$\sum_w \max(X_{ij}^{\lambda f})_f \leq M - X_{ij}, \forall (i, j) \in E$$

$$\sum_f \max(X_{ij}^{\lambda f})_t * b \lambda_\lambda \leq C_{ij}^\lambda, \forall (i, j) \in E, \lambda \in \Lambda$$

donde

$$X_{ij}^{wft} = \begin{cases} 1, & \text{si el flujo } f \text{ es transmitido} \\ & \text{en } w \text{ por el } (i, j) \in E \text{ con} \\ & \text{destino } t. \\ 0, & \text{en otro caso} \end{cases} \quad \text{donde } X_{ij}^{wft} \in Z$$

Los problemas computacionales pueden ser de distintas categorías como son:

- P, son aquellos que pueden ser resueltos en tiempo polinomial.
- NP, son problemas para los cuales no existen algoritmos para resolverlos con una complejidad de tiempo polinomial, pero se puede aproximar a la solución con la utilización de algoritmos P.
- NP-completo, que a su vez son NP y para éste existe un algoritmo P para reducir el problema otro P.
- NP-Hard, problema de optimización en el cual se utiliza un problema NP-completo como subproceso.

Por experiencias previas en [DON03a], [DON03b] y [DON03c] se conoce que el problema presentado es de naturaleza NP-Hard, ya que la minimización de las funciones objetivos: Atenuación, Retardo y número de longitudes de onda para un grupo Multicast se conoce como el problema del árbol de Steiner (NP-completo) cuyo modelo incluye restricciones en sus variables enteras y reales.

5.2 MODELO DIFUSO

Siguiendo el método propuesto por Sakawa, en donde se considera la lógica difusa en todos los niveles, el problema de optimización multiobjetivo en redes ópticas con transmisión multicast puede formularse como un problema $G\alpha$ -MONLP:

Minimizar con Lógica Difusa

$$f_0(x, a_0) = a_0 \circ \sum_f \sum_\lambda \sum_t \sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft}))$$

$$f_1(x, a_1) = a_1 \circ \sum_f \sum_\lambda \sum_t \sum_{(i,j) \in E} (X_{ij}^{\lambda ft})$$

$$f_2(x, a_2) = a_2 \circ \sum_f \sum_\lambda \sum_{(i,j) \in E} (b_f * \max(X_{ij}^{\lambda ft})_t)$$

$$f_3(x, a_3) = a_3 \circ \max_{\lambda, f, t} \left[\sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft})) \right]$$

$$f_4(x, a_4) = a_4 \circ \max_{\lambda, f, t} \left[\sum_{(i,j) \in E} (X_{ij}^{\lambda ft}) \right]$$

$$f_5(x, a_5) = a_5 \circ \frac{\sum_f \sum_\lambda \sum_t \sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft}))}{\sum_f |T_f|}$$

$$f_6(x, a_6) = a_6 \circ \frac{\sum_f \sum_\lambda \sum_t \sum_{(i,j) \in E} (X_{ij}^{\lambda ft})}{\sum_f |T_f|}$$

$$f_7(x, a_7) = a_7 \circ \sum_\lambda \sum_{(i,j) \in E} \max(X_{ij}^{\lambda ft})_{ft}$$

$$f_8(x, a_8) = a_8 \circ \left(\max \left[\sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft})) \right]_{\lambda, f, t} \right) - \left(\min \left[\sum_{(i,j) \in E} (d_{ij} * (X_{ij}^{\lambda ft})) \right]_{\lambda, f, t} \right)$$

$$f_9(x, a_9) = a_9 \circ \left(\max \left[\sum_{(i,j) \in E} (X_{ij}^{\lambda ft}) \right]_{\lambda, f, t} \right) - \left(\min \left[\sum_{(i,j) \in E} (X_{ij}^{\lambda ft}) \right]_{\lambda, f, t} \right)$$

$$f_{10}(x, a_{10}) = a_{10} \circ \max \left[\left(10^{-A_{ij} * L_{ij} / 10} * P(i) \right) * \max(X_{ij}^{\lambda ft})_t \right]_{f, \lambda, (i, j)}$$

Sujeto a

$$\sum_{(i,j)} X_{ij}^{\lambda ft} - \sum_{(j,i)} X_{ji}^{\lambda ft} = 1$$

$$\forall t \in T_f, \forall f \in F, \forall \lambda \in \Lambda, i = s$$

$$\sum_{(i,j)} X_{ij}^{wft} - \sum_{(j,i)} X_{ji}^{wft} = 1$$

$$\forall i, t \in T_f, \forall f \in F, \forall \lambda \in \Lambda$$

$$\sum_{(i,j)} X_{ij}^{\lambda ft} - \sum_{(j,i)} X_{ji}^{\lambda ft} = 0$$

$$\forall t \in T_f, \forall f \in F, i \neq s, i \neq T_f$$

$$\sum_w \max(X_{ij}^{\lambda ft})_f \leq M \cdot X_{ij}, \forall (i, j) \in E$$

$$\sum_f \max(X_{ij}^{\lambda ft})_t * b \lambda_\lambda \leq C_{ij}^\lambda, \forall (i, j) \in E, \lambda \in \Lambda$$

$$a \in (\tilde{a})_\alpha$$

donde

$$X_{ij}^{wft} = \begin{cases} 1, & \text{si el flujo } f \text{ es transmitido} \\ & \text{en } w \text{ por el } (i, j) \in E \text{ con} \\ & \text{destino } t. \\ 0, & \text{en otro caso} \end{cases} \quad \text{donde } X_{ij}^{wft} \in Z$$

Se debe destacar que las restricciones no son afectadas por la lógica difusa debido a que las mismas son teorías físicas demostradas, las cuales no se someten a la incertidumbre.

La variable a_i no es una constante sino una variable de decisión y el operador \circ no es específicamente suma o multiplicación sino el operador de la variable a_i sobre la función original $f_i(x)$.

6 APLICACIÓN DEL ALGORITMO EVOLUTIVO SPEA2 PARA RESOLVER EL PROBLEMA

6.1 REPRESENTACIÓN DE LOS INDIVIDUOS

En esta propuesta cada individuo representa $|F|$ flujos. Por cada flujo f , existe un árbol (Árbol f) el cual es usado para transmitir la información del flujo desde su fuente s_f hacia el conjunto de destinos T_f , cada uno de estos árboles contiene un conjunto de parejas cuyos elementos corresponden, por un lado, a un camino que es un conjunto de nodos distintos que van desde la fuente s_f hacia un destino $t \in T_f$ y, por otro lado, el número de lambda (λ) que utiliza ese camino.

En la figura 6–1 se puede apreciar gráficamente como se representa un individuo dentro del algoritmo propuesto.

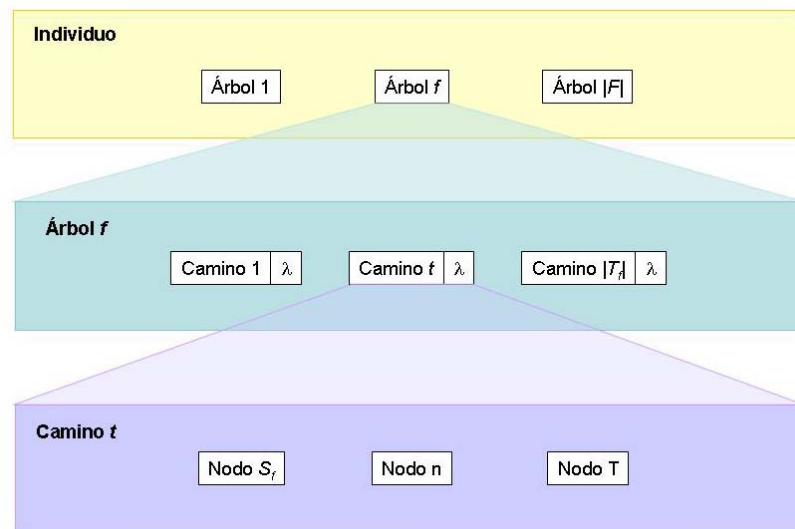
Para crear la población inicial se generan aleatoriamente caminos desde cada fuente a todos los destinos, se arma el árbol con estos caminos, y se arma el individuo con los árboles, este proceso se repite hasta tener el número de individuos necesario.

6.2 CRUZAMIENTO

Se han propuesto dos métodos diferentes que se utilizan en el operador de cruzamiento del algoritmo planteado, cruzamiento de árboles, y cruzamiento de caminos. El cruzamiento de árboles recibe dos árboles del mismo flujo de tal forma que tengan los mismos destinos y genera dos árboles hijos como resultado, esto se realiza intercambiando caminos entre los dos árboles padre, escogiendo de manera

aleatoria cuántos y cuáles intercambiar. Por ejemplo, en el caso en que se aplicara el operador al árbol $f1$ y el árbol $f2$, los cuales son del mismo flujo, donde ambos tienen como destinos los nodos 1, 2, 3 y 4, se escoge de forma aleatoria intercambiar los caminos que tienen como destino a 2 y a 3, dando como resultado del cruzamiento los árboles $f3$ y $f4$. Una representación gráfica del intercambio se ilustra en la figura 6–2.

Figura 6-1 Representación del individuo [CAR05]



El cruzamiento de caminos es un operador que recibe dos caminos que conectan el mismo origen con el mismo destino, y genera dos caminos nuevos, funciona escogiendo aleatoriamente un *nodo* i que se encuentre en los dos caminos que no sea la fuente s_f y el destino t , se forman cuatro subcaminos, dos que van de s_f a i y dos que van de i a t , uniendo los subcaminos de uno de los padres con los subcaminos del otro, se forman dos caminos nuevos que son el resultado del operador. Una representación gráfica del operador se ilustra en la figura 6 – 3.

Figura 6-2 Ejemplo de cruzamiento de dos árboles [CAR05].

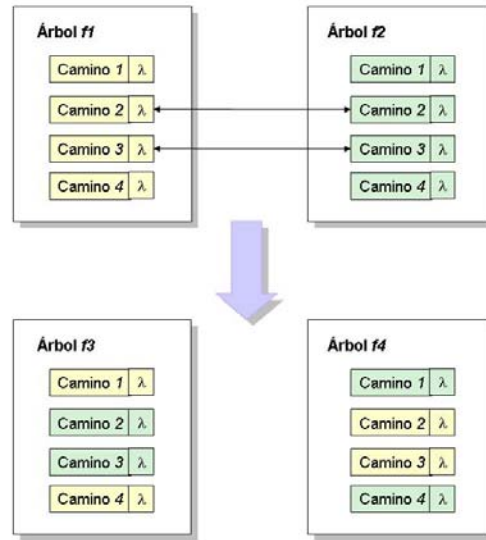



Figura 6-3 Cruzamiento de dos caminos [CAR05].



A diferencia del cruzamiento de árboles, el cual se puede realizar con cualquier par de caminos; para que sea posible realizar el cruzamiento de caminos es necesario que los caminos tengan mínimo un nodo en común y que no genere caminos con ciclos al aplicarle el método. Cabe notar que en algoritmo planteado esto esta validado.

El operador de cruzamiento del algoritmo planteado funciona de la siguiente manera, por cada flujo f que tenga el problema genera un conjunto de cuatro o dos árboles a partir de los dos árboles de f (un árbol de un padre y otro árbol del otro padre), este conjunto es generado de la siguiente manera, los dos primeros elementos son el resultado de aplicarle a los dos árboles el operador de cruzamiento de árboles

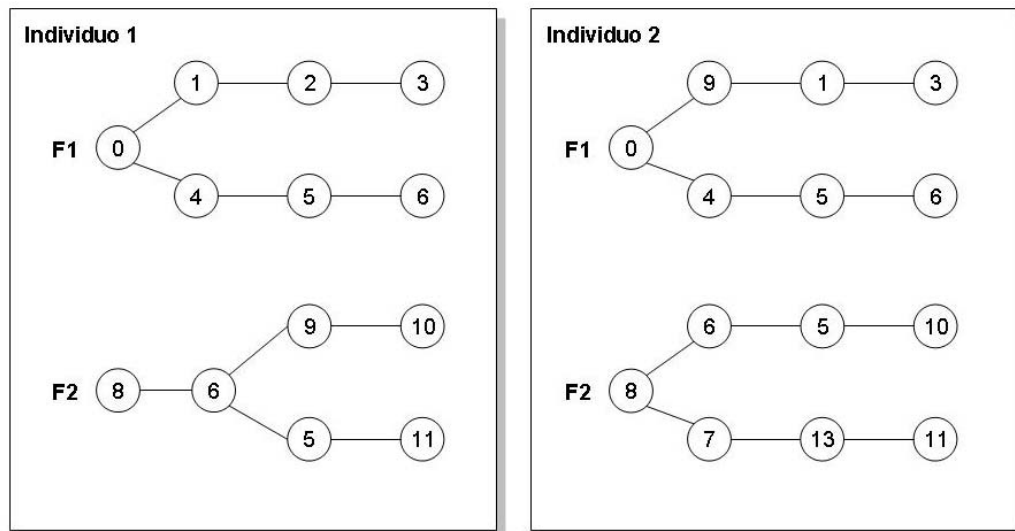
definido anteriormente, los otros dos elementos son generados al aplicarle a los árboles de los padres el método **cruza** que se definirá mas adelante, el cual puede generar dos árboles o no generar ninguno, en el primer caso el conjunto quedaría de 4 elementos y en el segundo quedaría de 2.

Cuando se hayan obtenido los conjuntos de cada flujo, se arman los individuos hijos escogiendo un árbol de cada flujo, de tal forma que cada combinación diferente dé cómo resultado un individuo diferente, se construyen como máximo 32 combinaciones posibles.

El método **cruza** recibe dos árboles, los clona, a continuación escoge aleatoriamente unos caminos de los árboles para aplicar el cruzamiento de caminos sobre estos. Si el cruzamiento de caminos fue exitoso, regresa los individuos clonados como nuevos sino no regresa hijos.

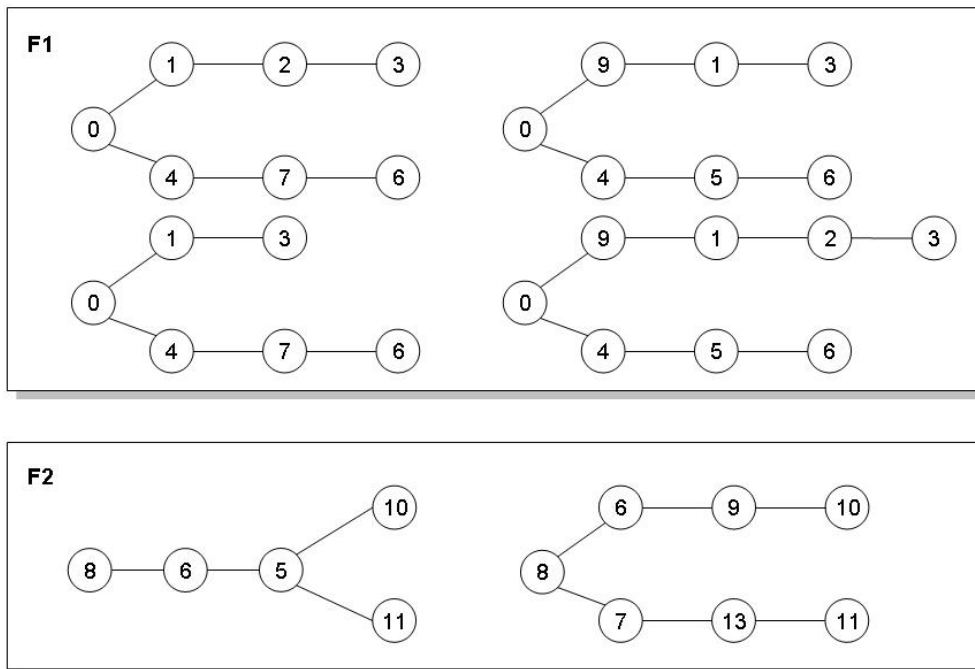
Se ilustra un ejemplo del operador de cruzamiento explicado, dados los siguientes individuos:

Figura 6-4 Individuos de ejemplo [CAR05].



Como se explicó anteriormente, se forma un conjunto por cada flujo, en este caso dos conjuntos, en la figura 6 – 5 se puede apreciar una representación gráfica de estos, los dos primeros elementos del conjunto de F1 fueron generados por el método de cruzamiento de árboles, el cual escogió aleatoriamente intercambiar los caminos que tienen como destino el nodo 6. El tercer y cuarto elemento fueron generados por el método **crusa** el cual escogió aleatoriamente el camino que va al destino 3 por lo tanto a esos dos caminos se les aplico el método de cruzamiento de caminos y el otro camino se dejo igual. Los primeros dos elementos del conjunto de F2 fueron generados por el método de cruzamiento de árboles el cual escogió aleatoriamente al camino con destino 10 para intercambiarlo. Al utilizar el método **crusa**, éste escogió aleatoriamente el camino con destino 11 pero no se encontró nodos en común, por lo tanto el método no genero árboles y es por esto que el conjunto de F2 tiene solamente 2 elementos.


Figura 6-5 Conjuntos [CAR05]



Una vez que se tengan los grupos se generan los individuos combinando árboles de cada flujo para formarlos. Se realizan a lo sumo 32 combinaciones posibles, es decir

que sólo se generarían 32 hijos como máximo para un individuo, en este caso se pueden realizar 8 combinaciones diferentes las cuales se pueden apreciar en la figura 6 – 6.

Figura 6-6 Resultados [CAR05]



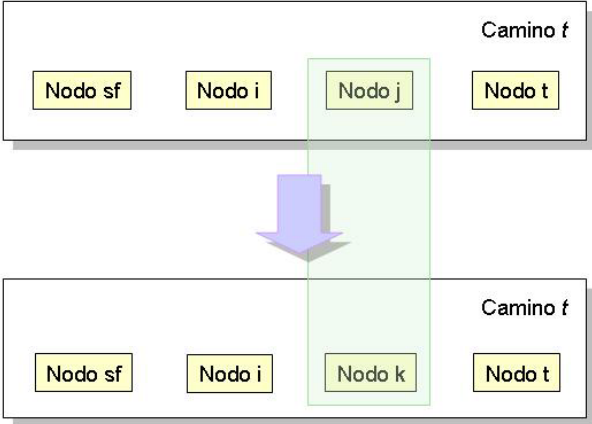
6.3 MUTACIÓN

Para realizar la mutación en el algoritmo planteado se utilizan tres métodos, el primero es la mutación de camino la cual es la base del resto de métodos, este recibe un camino y devuelve uno mutado, funciona escogiendo aleatoriamente un nodo que no sea la fuente s_f o el destino t , después busca un camino alternativo desde el nodo escogido hasta el destino y lo reemplaza creando un nuevo camino mutado. Una representación gráfica del método se puede ver en la figura 6 – 7.

El otro método es la mutación de árbol, el cual escoge aleatoriamente caminos y les aplica el método de mutación de caminos, este método como mínimo escoge un camino para mutar. El tercer método es la mutación de individuos, este método

ejecuta la mutación de árbol de todos los árboles que conforman al individuo, resultando un individuo mutado; corresponde al operador de mutación del algoritmo SPEA2.

Figura 6-7 Mutación del Camino [CAR05]



7 APLICACIÓN DEL SPEA2 DIFUSO (FSPEA2) PARA RESOLVER EL PROBLEMA

En la figura 7 – 1, se presenta el algoritmo SPEA2, en el que se encuentran resaltados los pasos en los que se ha incluido lógica difusa. A continuación, se describe la manera en que el algoritmo original fue modificado.

Figura 7-1 Algoritmo FSPEA2

- Leer grupo multicast a enrutar
- Inicializar población P.

Hacer{

- Evaluar individuos de P
- Marcar soluciones no dominadas de P
- Actualizar el conjunto de soluciones no dominadas de Pn
- Calcular la adaptabilidad de los individuos de P y Pn
- Seleccionar individuos del conjunto $P \cup Pn$

- Aplicar los operadores de cruzamiento y mutación

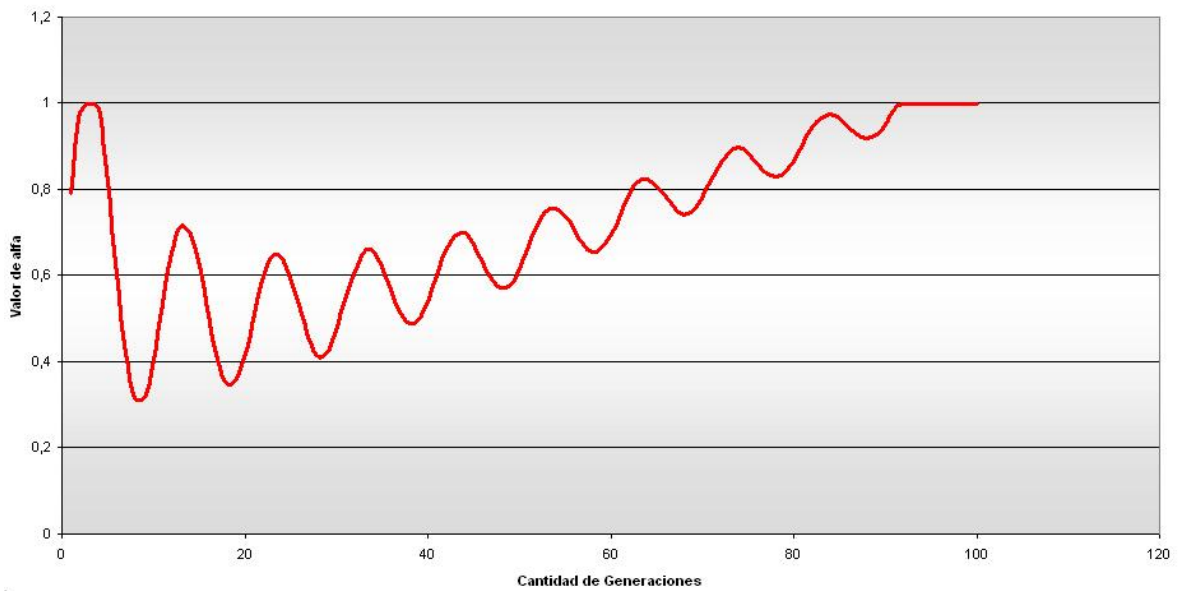
} Mientras el criterio de parada no sea alcanzado

7.1 CÁLCULO DEL VALOR DE CERTIDUMBRE MÍNIMO (α)

El valor de certidumbre mínimo del algoritmo varía a lo largo de la ejecución del mismo, entre 0.5 y 1.0; sin embargo, su nivel de convergencia, a medida que aumenta el número de generaciones calculadas, es uno (1.0).

Por otro lado, α depende de un valor de certidumbre inicial, el cual es de naturaleza aleatoria.


Figura 7-2 Comportamiento del nivel de Certidumbre (α)



7.2 FUNCIONES OBJETIVO

Luego de obtener el valor de las funciones objetivo ($f_i(x_i)$), a estos se les aplica un valor de certidumbre basado en la generación de un número triangular difuso simétrico, cuya media es $f_i(x_i)$; obteniéndose así $f_i(x_i, a)$, el valor asignado es aleatoriamente escogido, dentro del rango de certidumbre dado por a ; en otras palabras, éste valor pertenece al intervalo $[f_i(x_i)-t; f_i(x_i)+t]$ (Figura 7 – 3).

Figura 7-3 Número Triangular Difuso Simétrico $f(x_i)$



7.3 CÁLCULO DEL FITNESS

7.3.1 Función de Membresía

La función de membresía $\mu_i[f_i(x_i, a)]$ se calcula con base en los valores mínimos y máximos de cada función, teniendo en cuenta las siguientes premisas:

1. Cada generación da origen a un frente de pareto.
2. Cada nueva generación, y el frente de pareto que ésta origina, se acercarán más al frente real.

Tomando como base las premisas anteriores, para cada generación se calculan los valores máximos y mínimos de cada función, obteniéndose la membresía de cada individuo así:

$$\mu_i[f_i(x, a)] = \frac{\max_i - f_i(x, a)}{\min_i}$$

7.3.2 Cálculo de Strength y RawFitness

Estos cálculos se hacen de la misma manera en que los define el algoritmo SPEA2; sin embargo, la base de los mismos es $f_i(x_i, a)$, en lugar de $f_i(x_i)$.

7.3.3 Fitness

La función Fitness propuesta por Sakawa, utiliza la función de membresía; un valor que mide la cercanía al frente de pareto real ($\bar{\mu}_i$), el cual se ha tomado como 0.9, para obtener los valores más cercanos al frente de pareto, y dejar un nivel de incertidumbre.

$$f(s) = 1.0 + k\rho - \max_{i=1,\dots,k} \{ \bar{\mu}_i - \mu_i(f_i(x, a_i)) + \rho \sum_{i=1}^k (\bar{\mu}_i - \mu_i(f_i(x, a_i))) \}$$

Los valores obtenidos en la función de cálculo Fitness, oscilan entre cero (0) y $1+k\rho$; donde k es la cantidad de funciones objetivo a optimizar y ρ es el nivel de exactitud de los cálculos; particularizando, el intervalo es $[0, 1.011]$. Los individuos con el fitness más alto son los que deben formar parte de la población elitista.

Midiendo los valores de *strength* y *rawfitness* obtenidos por los individuos, y comparándolos con $f_i(x_i, a)$ y el fitness obtenido, se llegó a la conclusión que el valor mínimo del fitness para pasar a la población elitista es 0.5; garantizando así no caer en óptimos locales.

7.4 ANALISIS DE COMPLEJIDAD

El análisis de complejidad para el algoritmo FSPEA2 arroja el siguiente resultado con base en la figura 7-4

Figura 7-4 Análisis de Complejidad FSPEA2

- Leer grupo multicast a enrutar
- Inicializar población P.

Hacer{

- Evaluar individuos de P
- Marcar soluciones no dominadas de P
- Actualizar el conjunto de soluciones no dominadas de Pn
- Calcular la adaptabilidad de los individuos de P y Pn
- Seleccionar individuos del conjunto $P \cup Pn$
- Aplicar los operadores de cruzamiento
- Aplicar los operadores de mutación

} Mientras el criterio de parada no sea alcanzado

$$T(N_{Pob} * N_{Arb}^{N_{Pob}})$$

$$T(N_{Pob} * N_{fun})$$

$$T(N_{Pob}^3)$$

$$T(N_{ArcSiz}^4)$$

$$T(N_{MatPoolSize})$$

$$T(N_{CantArb} * N_{Ind}^{N_{Pob}})$$

$$T(N_{CantArb} * N_{MatPoolSize} * N_{Arb}^2)$$

$$T(FSPEA2) \approx N_{Gen} * \max \left(T(N_{Pob} * N_{Arb}^{N_{Pob}}) \quad T(N_{Pob} * N_{fun}) \quad T(N_{Pob}^3) \quad T(N_{ArcSiz}^4) \quad T(N_{MatPoolSize}) \right. \\ \left. T(N_{CantArb} * N_{Ind}^{N_{Pob}}) \quad T(N_{CantArb} * N_{MatPoolSize} * N_{Arb}^2) \right)$$

Luego, aplicando la complejidad $O(\)$, de conformidad a lo expuesto por [GAL93] se dice que una función $f(n)$ es de orden $O(g(n))$ sí y sólo si se cumple que existen unas constantes positivas c y n_0 , ambas independientes de n , tales que:

$$f(n) \leq c * g(n), \forall n \geq n_0$$

Aplicando las propiedades de la función Ómicron sobre las funciones de tiempo encontradas en el algoritmo se tiene que:

$$O(T(SPEA2)) \approx O(N_{Pob} * N_{CantArb} * N_{Ind}^{N_{Flujos}})$$

En donde N_{Pob} representa el tamaño de la población, $N_{CantArb}$ representa la cantidad de árboles de transmisión multicast, N_{Ind} representa la cantidad de individuos de cada generación, y N_{Flujos} representa el número de caminos/ destinos posibles.

Dado que N_{Ind} es mayor que las otras medidas y en concordancia con la definición de la función ómicron en donde se busca una cota superior se puede decir que:

$$O(T(SPEA2)) \approx O(N_{Ind}^{N_{Flujos}+2})$$

Debido a que N_{Flujos} es menor o igual que cuatro por las restricciones de las topologías modeladas, una cota superior para la función de complejidad estaría dada por N^k , donde $k > 4$. De donde se desprende que el algoritmo es de complejidad polinómica, teniendo en cuenta que entre mayor sea el valor de k peor será el comportamiento del algoritmo.

8 ANALISIS COMPARATIVO

El objetivo de éste capítulo es realizar una comparación de los dos algoritmos implementados. La comparación de estos algoritmos basados en metaheurísticas es necesaria, debido a su naturaleza estocástica. Por lo tanto, se realizó un experimento, donde se genera una serie de resultados para cada algoritmo. Estos resultados son frentes Pareto experimentales. Por convenio, para referirse a uno de estos frentes Pareto se utilizara el símbolo PF_{known} , que significa frente Pareto conocido.

8.1 DISEÑO DEL EXPERIMENTO

El diseño de un experimento es la secuencia completa de pasos tomados de antemano para asegurar que los datos apropiados se obtendrán de modo que permitan un análisis objetivo que conduzca a deducciones válidas con respecto al problema establecido.

La necesidad de un diseño de experimento surge de la necesidad de responder a preguntas como:

- ¿Cómo se va a medir el efecto? ó ¿Cuáles son las características a analizar?
- ¿Qué factores afectan las características que se van a analizar?
- ¿Cuáles son los factores que se estudiarán en esta investigación?
- ¿Cuántas veces deberá ejecutarse el experimento?
- ¿Cuál será la forma de análisis?
- ¿A partir de que valores se considera importante el efecto?

El experimento fue desarrollado siguiendo la metodología propuesta por [MON04] y [HER03]. Esta propuesta define siete pasos para el proceso de desarrollo de

investigaciones a saber: identificación y planteamiento del problema; selección de factores, niveles y rangos; selección de la variable respuesta; escogencia del diseño experimental; desarrollo del experimento; análisis estadístico de datos; y finalmente conclusiones y recomendaciones. Los mismos guardan relación directa con los aspectos concretos en la planeación de la investigación mencionados en [KUE01] a saber: Objetivos específicos del experimento; identificación de los factores que influyen en el experimento; características a medir; procedimientos particulares para realizar las pruebas o medir las características; número de repeticiones del experimento básico a realizar; recursos y materiales disponibles.

A continuación se describen cada uno de las etapas en la planeación del presente experimento:

8.1.1 Objetivo

El objetivo específico del experimento es realizar la comparación del comportamiento de los algoritmos para la optimización multiobjetivo SPEA2 y FSPEA2, para lo cual se consideraron tres escenarios: National Science Foundation (NSF), MCI y Sprint. Estas topologías se seleccionaron debido a que han sido utilizadas en varios trabajos anteriores.

8.1.2 Métricas a Analizar

- **Diferencias Normalizadas de las medias de los valores extremos (DNME).** Para calcular el DNME, se calcula por cada PF_{known} el valor mínimo encontrado para cada una de las funciones, para posteriormente calcular la media y desviación estándar de estos valores por cada PF_{known} , calculado con el mismo algoritmo y número de iteraciones. Después de tener estas medias y desviaciones

estándares, se calculan las diferencias normalizadas entre de estos valores para cada numero de iteraciones.

- **Generación de vectores no dominados (GVND).** GVND es una métrica que indica el numero de elementos no dominados generados por un algoritmo, esto es, $GVND = |PF_{true}|$.

- **Distancia Generacionales (DG).** Esta métrica indica que tan lejos esta el PF_{known} del PF_{true} . Matemáticamente se define se define así:

$$DG = \frac{\sqrt{\sum_{i=1}^{|PF_{known}|} d_i}}{|PF_{known}|}$$

Donde, d_i es la mínima distancia euclidiana entre elemento i-ésimo de PF_{known} con los elementos del frente PF_{true} .

- **Spacing (S).** Esta métrica es utilizada para medir que tan bien distribuidos están las soluciones en el espacio objetivo a través de PF_{known} . Matemáticamente se define de la siguiente manera:

$$S = \sqrt{\frac{\sum_{i=1}^{|PF_{known}|} (\bar{d} - d_i)}{|PF_{known}| - 1}}$$

Donde $d_i = \min_j \left(\sum_{k=1}^m |f_k^i(x_i) - f_k^j(x_j)| \right)$ con $i \neq j$ y $1 \leq i, j \leq |PF_{known}|$, y \bar{d} es el promedio de todos los d_i .

Para esta métrica un valor de 0 significa que todos lo elementos de PF_{known} están equidistantemente espaciados. Por lo tanto entre menor se el valor de S mejor es la distribución de los elementos del PF_{known} .

- **Tiempo Computacional.**

8.1.3 Número de Repeticiones

En cuanto al número de repeticiones, El experimento toma las tres topologías anteriormente mencionadas, y se analiza el comportamiento, cuando el tráfico multicast se dirige hacia el 20%, 30%, 40%, 50%, 60%, 70%, 80% y 90% de nodos del total de la red para cada una de las topologías. Se realizan cinco repeticiones por cada relación *Porcentaje de Destinos – Topología*, generando 40 muestras por topología para un total de 120 pruebas.

Los valores a comparar son los resultados de las medias de cada función objetivo obtenidas de las cinco ejecuciones, cada una de ellas durante 50 generaciones. Por el teorema del límite central [MEN02], se espera que cada una de las distribuciones de las funciones objetivos siga el comportamiento de una distribución normal; además, se logró demostrar (ver sección de Análisis de Correlación) que de las 11 funciones ocho son independientes, por lo que sin importar el tipo de distribución que sigan individualmente cada una de ellas, sus medias tienen un comportamiento normal; por tanto, cualquier experimentación con muestras mayores que 30 resultan suficientes.

8.1.4 Factores y Procedimientos

Mientras la cantidad de los nodos destinos varían, los parámetros de entrada para los algoritmos se mantienen fijos, de la siguiente manera:

- Población: 100
- Archive Size: 50
- Matting Pool: 50
- Generaciones: 50

Los algoritmos SPEA2 y FSPEA2 se ejecutaron cinco (5) veces en cada uno de las combinaciones Topología – Porcentaje Destinos.

Para la métrica Distancia Generacionales (DG), es necesario tener el frente Pareto real PF_{true} , por lo cual se calculó de dos maneras diferentes:

1. Asumiendo que el Frente Pareto no se conoce, éste se construye a partir de todos los PF_{known} , tomando los elementos no dominados de estos.
2. Dado que SPEA2 es un algoritmo conocido en la comunidad científica y cuyos resultados han sido validados, los valores obtenidos del SPEA2 se toman como referencia en la comparación y se asumen como el PF_{true} .

Los algoritmos reciben como datos entrada archivos descriptivos de cada uno de las topologías seleccionadas.

- Cantidad de Nodos.
- Cantidad de Flujos.
- Potencia del Láser; la cual se encuentra en dBm.
- Cantidad de Lambdas disponibles y ancho de banda de cada una.
- Nodo origen y tamaño del flujo
- Nodos destinos del flujo, los cuales se eligen en forma aleatoria, donde todos tienen la misma probabilidad de ser seleccionados.
- Matriz de la red.
 - Nodo_i.
 - Nodo_j.
 - Retardo. El cálculo del retardo se basa en la distancia entre el nodo_i y el nodo_j, teniendo en cuenta que la velocidad de la luz en una fibra es 2×10^8 m/s.
 - Distancia. La distancia euclidiana entre el nodo_i y el nodo_j en cientos de kilómetros; basados en que cada 100 km se encuentran repetidores.
 - Factor de atenuación. Se encuentra entre 0.2 y 0.5 dB.

A continuación se encuentran las tablas que describen los datos de entrada de cada topología seleccionada.

- MCI.

Figura 8-1 Topología MCI



Tabla 8-1 MCI F - Nodos Topología - Potencia del Láser

Ciudades	Nodo #	Potencia (mW)	Potencia (dBm)
Austell	0	3	4,8
Charlton	1	5	7
Dallas	2	6	7,8
Denver	3	2,4	3,8
Greensboro	4	6,4	8,1
Houston	5	7,1	8,5
Independence	6	5,8	7,6
Los Ángeles	7	3,4	5,3
New York	8	6	7,8
Pompano Beach	9	1,66	2,2
Rialto	10	2	3
Sacramento	11	3,8	5,8
San Francisco	12	3,1	4,9
Seattle	13	9	9,5
W. Springs	14	2	3
Washington	15	1,68	2,3

Tabla 8-2 MCI - Nodos Destinos

Porcentaje	Origen	Destinos				
20%	0	7	8	15		
30%	2	3	6	10	11	14
40%	3	0	4	11		
	6	1	10	13		
50%	13	5	6	9	12	
	4	0	3	7	13	
60%	5	0	1	3	10	15
	9	1	2	4	10	12
70%	12	5	6	10	15	
	7	3	6	8	14	
	15	0	8	13		
80%	8	0	2	5	6	14
	11	1	3	10	12	15
	14	3	4	7		
90%	15	1	4	7	11	12
	1	0	5	8	10	14
	5	3	9	13	14	

Tabla 8-3 MCI – Matriz de la red

Nodo_i	Nodo_j	Retardo (ms)	Distancia*	Atenuación (dB)	Distancia (Km)	Tipo
0	2	5,6725	11,35	0,3	1134,5	OC-12
0	4	2,4025	4,81	0,5	480,5	DS-3
0	8	5,9000	11,80	0,3	1180	OC-12
0	9	4,5070	9,01	0,5	901,4	DS-3
0	10	14,7600	29,52	0,3	2952	OC-12
1	8	1,7625	3,53	0,5	352,5	DS-3
2	0	5,6725	11,35	0,3	1134,5	OC-12
2	5	1,7635	3,53	0,5	352,7	DS-3
2	6	3,6350	7,27	0,5	727	DS-3
2	10	9,2750	18,55	0,3	1855	OC-12
2	14	6,2900	12,58	0,3	1258	OC-12
3	6	4,4255	8,85	0,5	885,1	DS-3
3	8	12,8585	25,72	0,3	2571,7	OC-12
3	12	7,4300	14,86	0,3	1486	OC-12
3	13	7,9585	15,92	0,5	1591,7	DS-3
3	14	7,2235	14,45	0,3	1444,7	OC-12
4	0	2,4025	4,81	0,5	480,5	DS-3
4	15	1,9530	3,91	0,5	390,6	DS-3
5	2	1,7635	3,53	0,5	352,7	DS-3
5	9	7,5565	15,11	0,5	1511,3	DS-3

6	2	3,6350	7,27	0,5	727	DS-3
6	3	4,4255	8,85	0,5	885,1	DS-3
6	14	3,1785	6,36	0,5	635,7	DS-3
7	10	0,4440	0,89	0,3	88,8	OC-12
7	12	2,7800	5,56	0,5	556	DS-3
8	0	5,9000	11,80	0,3	1180	OC-12
8	1	1,7625	3,53	0,5	352,5	DS-3
8	3	12,8585	25,72	0,3	2571,7	OC-12
8	14	4,6890	9,38	0,3	937,8	OC-12
9	0	4,5070	9,01	0,5	901,4	DS-3
9	5	7,5565	15,11	0,5	1511,3	DS-3
10	0	14,7600	29,52	0,3	2952	OC-12
10	2	9,2750	18,55	0,3	1855	OC-12
10	7	0,4440	0,89	0,3	88,8	OC-12
10	12	3,0410	6,08	0,3	608,2	OC-12
11	12	0,6035	1,21	0,5	120,7	DS-3
12	3	7,4300	14,86	0,3	1486	OC-12
12	7	2,7800	5,56	0,5	556	DS-3
12	10	3,0410	6,08	0,3	608,2	OC-12
12	11	0,6035	1,21	0,5	120,7	DS-3
12	13	5,4625	10,93	0,3	1092,5	OC-12
13	3	7,9585	15,92	0,5	1591,7	DS-3
13	12	5,4625	10,93	0,3	1092,5	OC-12
14	3	7,2235	14,45	0,3	1444,7	OC-12
14	6	3,1785	6,36	0,5	635,7	DS-3
14	8	4,6890	9,38	0,3	937,8	OC-12
15	4	1,9530	3,91	0,5	390,6	DS-3
14	2	6,2900	12,58	0,3	1258	OC-12

- National Science Foundation.

Figura 8-2 Topología NSF – 1991

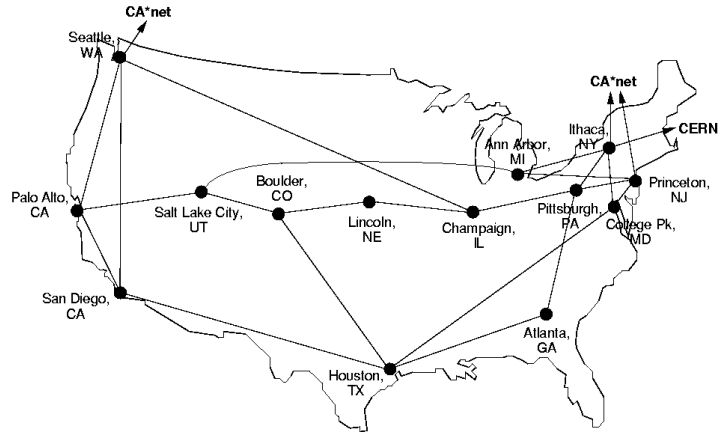


Tabla 8-4 NSF - Nodos Topología - Potencia del Láser

Ciudades	Nodo #	Potencia (mW)	Potencia (dBm)
Ann Arbor	0	2,4	3,8
Atlanta	1	6,4	8,1
Boulder	2	7,1	8,5
Champaign	3	5,8	7,6
College Pk	4	3,4	5,3
Houston	5	6	7,8
Ithaca	6	1,66	2,2
Lincoln	7	2	3
Palo Alto	8	3,8	5,8
Pittsburg	9	3,1	4,9
Princeton	10	5,8	7,6
Salt Lake City	11	3,4	5,3
San Diego	12	6	7,8
Seattle	13	1,66	2,2

Tabla 8-5 NSF - Nodos Destinos

Porcentaje	Origen	Destinos				
20%	0	5	8	9		
30%	3	5	6	11	12	
40%	4	10	11	13		
	8	2	7	11		

50%	11	0	2	3	5	
	12	6	9	10		
60%	6	7	8	10	12	
	9	0	3	6	13	
70%	10	5	8	9	11	12
	13	0	2	5	6	11
80%	2	1	6	8	13	
	4	0	1	2	9	
	5	4	9	10		
90%	7	0	2	4	8	10
	8	3	6	7	12	13
	10	1	3	11		

Tabla 8-6 NSF – Matriz de la Red

Nodo_i	Nodo_j	Retardo (ms)	Distancia*	Atenuación (dB)	Distancia(Km)
0	6	2,8905	5,78	0,2	578,1
0	10	3,8425	7,69	0,2	768,5
0	11	11,458	22,92	0,2	2291,6
1	5	5,56	11,12	0,4	1112
1	9	4,0865	8,17	0,4	817,3
2	5	7,128	14,26	0,3	1425,6
2	7	3,573	7,15	0,3	714,6
2	11	2,7525	5,51	0,3	550,5
3	7	3,525	7,05	0,4	705
3	9	3,402	6,80	0,4	680,4
3	13	13,8145	27,63	0,4	2762,9
4	5	9,8545	19,71	0,2	1970,9
4	6	1,7375	3,48	0,2	347,5
4	10	0,9195	1,84	0,2	183,9
5	1	5,56	11,12	0,4	1112
5	2	7,128	14,26	0,4	1425,6
5	4	9,8545	19,71	0,4	1970,9
5	12	10,247	20,49	0,4	2049,4
6	0	2,8905	5,78	0,3	578,1
6	4	1,7375	3,48	0,3	347,5
6	9	1,781	3,56	0,3	356,2
7	2	3,573	7,15	0,4	714,6
7	3	3,525	7,05	0,4	705
8	11	4,599	9,20	0,2	919,8
8	12	3,3	6,60	0,2	660
8	13	5,7035	11,41	0,2	1140,7
9	1	4,0865	8,17	0,4	817,3

9	3	3,402	6,80	0,4	680,4
9	6	1,781	3,56	0,4	356,2
9	10	2,158	4,32	0,4	431,6
10	0	3,8425	7,69	0,3	768,5
10	4	0,9195	1,84	0,3	183,9
10	9	2,158	4,32	0,3	431,6
11	0	11,458	22,92	0,4	2291,6
11	2	2,7525	5,51	0,4	550,5
11	8	4,599	9,20	0,4	919,8
12	5	10,247	20,49	0,4	2049,4
12	8	3,3	6,60	0,4	660
12	13	8,4785	16,96	0,2	1695,7
13	3	13,8145	27,63	0,2	2762,9
13	8	5,7035	11,41	0,2	1140,7
13	12	8,4785	16,96	0,2	1695,7

- Sprint

Figura 8-3 Topología Sprint – 2001

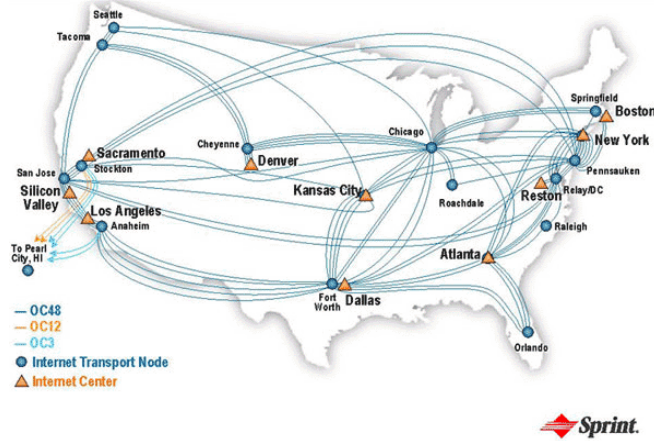


Tabla 8-7 Sprint – Nodos Topologías Potencia de Láser

Ciudades	Nodo #	Potencia (mW)	Potencia (dBm)
Anaheim	0	1,56	1,9
Atlanta	1	2,5	4
Cheyenne	2	4,8	6,8
Chicago	3	3	4,8
Fort Worth	4	8	9
Kansas City	5	1,6	2
New York	6	6,7	8,3

Orlando	7	3,4	5,3
Pennsauken	8	6	7,8
Raleigh	9	9,1	9,6
Relay	10	8	9
Roachdale	11	5,7	7,6
San José	12	3,2	5,1
Seattle	13	10	10
Springfield	14	2	3
Stockton	15	1,1	0,4
Tacoma	16	4,6	6,6

Tabla 8-8 Sprint – Nodos Destinos

Porcentaje	Origen	Destinos				
20%	0	1	11	16		
30%	1	0	2	7	15	16
40%	5	1	7	15		
	10	6	7	12	14	
50%	7	2	4	6	13	14
	11	1	2	4	10	
60%	6	5	8	13	14	15
	15	1	5	6	11	16
70%	2	6	9	12	16	
	8	0	5	9	15	
	13	1	7	11	14	
80%	7	1	2	6	8	12
	14	8	10	10	15	16
	15	2	4	6	9	
90%	1	4	7	10	12	13
	5	0	8	9	13	16
	10	1	8	12	14	15

Tabla 8-9 Sprint – Matriz de la Red

Nodo_i	Nodo_j	Retardo (ms)	Distancia*	Atenuacion (dB)	Distancia (Km)
0	4	9,4710	18,94	0,30	1894,2000
0	12	2,4175	4,84	0,30	483,5000
1	3	4,6250	9,25	0,30	925,0000
1	4	5,9130	11,83	0,30	1182,6000
1	6	5,9550	11,91	0,30	1191,0000
1	7	3,1930	6,39	0,30	638,6000
1	9	2,7830	5,57	0,30	556,6000

2	3	6,9980	14,00	0,30	1399,6000
2	16	7,5725	15,15	0,30	1514,5000
3	1	4,6250	9,25	0,30	925,0000
3	2	6,9980	14,00	0,30	1399,6000
3	4	6,4585	12,92	0,30	1291,7000
3	5	3,2455	6,49	0,30	649,1000
3	6	5,6280	11,26	0,30	1125,6000
3	11	1,9880	3,98	0,30	397,6000
3	12	14,4435	28,89	0,30	2888,7000
3	13	13,6160	27,23	0,30	2723,2000
3	14	6,0655	12,13	0,30	1213,1000
3	15	13,9960	27,99	0,30	2799,2000
4	0	9,4710	18,94	0,30	1894,2000
4	3	6,4585	12,92	0,30	1291,7000
4	5	3,6820	7,36	0,30	736,4000
4	7	7,7775	15,56	0,30	1555,5000
4	8	10,0350	20,07	0,30	2007,0000
5	3	3,2455	6,49	0,30	649,1000
5	4	3,6820	7,36	0,30	736,4000
5	8	8,0465	16,09	0,30	1609,3000
5	12	11,6300	23,26	0,30	2326,0000
5	13	11,8000	23,60	0,30	2360,0000
5	15	11,2435	22,49	0,30	2248,7000
6	1	5,9550	11,91	0,30	1191,0000
6	3	5,6280	11,26	0,30	1125,6000
6	8	1,5030	3,01	0,30	300,6000
6	10	2,3135	4,63	0,30	462,7000
6	14	0,9010	1,80	0,30	180,2000
7	1	3,1930	6,39	0,30	638,6000
7	4	7,7775	15,56	0,30	1555,5000
8	4	10,0350	20,07	0,30	2007,0000
8	5	8,0465	16,09	0,30	1609,3000
8	6	1,5030	3,01	0,30	300,6000
8	10	0,9170	1,83	0,30	183,4000
8	11	3,7475	7,50	0,30	749,5000
8	15	19,6480	39,30	0,30	3929,6000
9	1	2,7830	5,57	0,30	556,6000
9	10	1,1205	2,24	0,30	224,1000
10	6	2,3135	4,63	0,30	462,7000
10	8	0,9170	1,83	0,30	183,4000
10	9	1,1205	2,24	0,30	224,1000
10	12	18,9680	37,94	0,30	3793,6000
11	3	1,9880	3,98	0,30	397,6000
11	8	3,7475	7,50	0,30	749,5000
12	0	2,4175	4,84	0,30	483,5000

12	3	14,4435	28,89	0,30	2888,7000
12	5	11,6300	23,26	0,30	2326,0000
12	10	18,9680	37,94	0,30	3793,6000
12	15	0,4180	0,84	0,30	83,6000
12	16	5,5075	11,02	0,30	1101,5000
13	3	13,6160	27,23	0,30	2723,2000
13	5	11,8000	23,60	0,30	2360,0000
13	16	0,1950	0,39	0,30	39,0000
14	3	6,0655	12,13	0,30	1213,1000
14	6	0,9010	1,80	0,30	180,2000
15	3	13,9960	27,99	0,30	2799,2000
15	5	11,2435	22,49	0,30	2248,7000
15	8	19,6480	39,30	0,30	3929,6000
15	12	0,4180	0,84	0,30	83,6000
16	2	7,5725	15,15	0,30	1514,5000
16	12	5,5075	11,02	0,30	1101,5000
16	13	0,1950	0,39	0,30	39,0000

8.1.5 Recursos y Materiales Disponibles

El experimento se desarrolló sobre un computador con las siguientes características:

- Procesador Pentium 4 de 2.8GHz
- Memoria RAM de 512 MB
- Disco Duro de 80 GB

El software utilizado para la creación y ejecución de los algoritmos fueron:

- Windows XP.
- J2SE SDK 1.5.0.
- JCreator 3.0

Los algoritmos utilizados para la generación de resultados y su correspondiente comparación fueron:

- SPEA2.
- FSPEA2 (Propuesto).

Otros materiales utilizados fueron los documentos desarrollados por las investigaciones previas en esta misma rama dirigidas o producidas por el Ing. Yesid Donoso Meisel.

8.2 COMPARACIÓN DE RESULTADOS

Se realizó una comparación de las medias y la desviación estándar de las métricas evaluadas sobre cada uno de los frentes Pareto experimentales de cada algoritmo. Comparando directamente los resultados de cada algoritmo con el mismo número de iteraciones. Las métricas a evaluar y comparar se muestran a continuación.

8.2.1 Diferencia normalizada de las medias de los valores extremos (DNME)

Para obtener el DNME, se calcula por cada PF_{known} el valor mínimo encontrado para cada una de las funciones, posteriormente se calcula la media y desviación estándar de estos valores por cada PF_{known} obtenidos con el mismo algoritmo, número de iteraciones y cantidad de nodos destinos. Después de tener estas medias y desviaciones estándares, se calculan las diferencias normalizadas entre estos valores para cada número de iteraciones. A continuación se muestran y analizan los resultados obtenidos para cada una de las topologías seleccionadas.

- MCI.

Tabla 8-10 DNME – Grafo Topología MCI

Destinos	(FSPEA2 - SPEA2)/FSPEA2										
	F0	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10
20%	0,44275	0,40970	0,90287	0,40322	0,40819	0,44275	0,43318	0,65391	0,45046	0,48932	0,03415
30%	0,21136	0,19119	0,86867	0,40045	0,35841	0,21136	0,20141	0,41191	0,78394	0,71573	0,06511
40%	0,24545	0,25151	0,90586	0,42563	0,40975	0,24545	0,26292	0,59520	0,74259	0,69107	0,01515
50%	0,37966	0,38117	0,93700	0,38486	0,40010	0,37966	0,40134	0,58731	0,40283	0,44884	0,09287
60%	0,43598	0,41244	0,94123	0,41051	0,41848	0,43599	0,42986	0,62873	0,43796	0,50818	0,02849
70%	0,46228	0,40526	0,93691	0,43780	0,38450	0,46228	0,44907	0,73715	0,45752	0,45585	0,06592
80%	0,49653	0,43163	0,94479	0,38296	0,34418	0,49653	0,45938	0,73236	0,38720	0,38397	0,04725
90%	0,39937	0,34933	0,93783	0,31203	0,30601	0,39937	0,39377	0,63128	0,32203	0,33802	0,04038

Como se puede apreciar en la Tabla 8 – 10, al comparar los valores extremos del algoritmo FSPEA2 son superiores a los arrojados por el algoritmo original (SPEA2).

Aunque en la mayoría de las funciones de optimización la diferencia no supera el 40% en promedio, se encuentra una gran diferencia en los valores arrojados por F2, la cual corresponde a la optimización del retardo.

Por otro lado, al analizar los valores mínimos, en lugar de los promedios, se encuentra que a medida que aumenta la cantidad de nodos destinos de los flujos multicast, así mismo aumenta la diferencia entre los valores que arrojan los diferentes algoritmos.

- **NSF**

Tabla 8-11 DNME – Grafo Topología NSF

Destinos	(FSPEA2 - SPEA2)/FSPEA2										
	F0	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10
20%	0,15517	0,16835	0,86074	0,36463	0,30045	0,15517	0,17406	0,30986	0,78048	0,65599	0,12752
30%	0,26856	0,27523	0,88969	0,39058	0,35756	0,26856	0,29386	0,43747	0,66268	0,57350	0,14680
40%	0,21990	0,23824	0,91278	0,36356	0,35857	0,21991	0,25207	0,57225	0,65492	0,63120	0,16062
50%	0,32598	0,31706	0,90983	0,45581	0,41355	0,32599	0,33988	0,60994	0,64586	0,57078	0,19616
60%	0,30693	0,28624	0,92004	0,38727	0,34551	0,30694	0,30646	0,60319	0,56568	0,54055	0,17240
70%	0,32603	0,33524	0,93076	0,38798	0,34050	0,32603	0,35310	0,60873	0,54906	0,48134	0,09611
80%	0,39863	0,36218	0,91502	0,30271	0,27679	0,39864	0,38869	0,71597	0,31742	0,30206	0,18474
90%	0,21783	0,18877	0,90981	0,25645	0,22177	0,21921	0,19529	0,61218	0,41419	0,41790	0,07262

De manera general, se puede observar, que los valores extremos generados por el algoritmo FSPEA2 son superiores a los generados por el SPEA2, manteniendo los niveles de diferencia en la función F2 presentados en la topología MCI.

Adicionalmente, al comparar los resultados con los obtenidos en la topología MCI, se observa que las diferencias entre los valores de la topología MCI son superiores a los obtenidos en la topología NSF.

- **Sprint**

En la Tabla 8 – 12, se observa que los valores extremos obtenidos a través del algoritmo FSPEA2 son superiores al SPEA2, manteniéndose la diferencia marcada en

F2, exceptuando los valores extremos obtenidos en esta función, la diferencia promedio entre las soluciones arrojadas por los algoritmos es del 37%.

Tabla 8-12 DNME – Grafo Topología Sprint

Destinos	(FSPEA2 - SPEA2)/FSPEA2										
	F0	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10
20%	0,46157	0,39282	0,88979	0,55496	0,45076	0,46157	0,40793	0,46481	0,83514	0,67414	0,16632
30%	0,18981	0,21768	0,91961	0,36174	0,31340	0,18981	0,22807	0,52547	0,70997	0,61578	0,24864
40%	0,20262	0,14651	0,89820	0,36201	0,28986	0,20262	0,16000	0,60198	0,60544	0,57249	0,11802
50%	0,21411	0,19235	0,91458	0,36569	0,31490	0,21411	0,20552	0,44982	0,62145	0,60476	0,12952
60%	0,37301	0,37363	0,92632	0,42495	0,37346	0,37301	0,39497	0,71470	0,54218	0,47342	0,17015
70%	0,26879	0,23854	0,91720	0,35891	0,27937	0,26879	0,26176	0,69183	0,52333	0,43140	0,12445
80%	0,26827	0,25479	0,91152	0,29878	0,24915	0,26826	0,27047	0,61875	0,40500	0,36579	0,12590
90%	0,36523	0,32636	0,92572	0,35683	0,25920	0,36523	0,34676	0,74737	0,40859	0,29809	0,11524

8.2.2 Generación de vectores no dominados (GVND)

GVND es un indicador de la cantidad de elementos no dominados generados por un algoritmo; en otras palabras $GVND = |PF_{true}|$. A continuación se muestran los resultados obtenidos en las diferentes ejecuciones de los algoritmos.

Tabla 8-13 GVND – Cantidad Nodos destinos: 20%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	3,80	3,1145	2,80	1,0954
NSF	17,00	8,6023	40,40	3,8471
Sprint	22,40	5,6391	42,20	6,0581

En la Tabla 8–13 se muestran los resultados obtenidos cuando la cantidad de nodos destinos corresponde al 20% de la cantidad de nodos de los grafos. Para el caso de la topología MCI, el algoritmo FSPEA2 obtuvo un Frente de Pareto levemente superior al SPEA2; sin embargo, la desviación estándar del FSPEA2 es superior al SPEA2, lo cual indica que el frente de Pareto generado tiene a ser más variable. En la topología NSF el SPEA2 presenta un Frente de Pareto muy superior al FSPEA2; la desviación estándar de arrojada por ambos algoritmos muestra que los valores del FSPEA2 son más variables que los obtenidos a través del SPEA2. Por último, en la topología

Sprint se obtienen valores muy similares a los obtenidos en la topología NSF; sin embargo, la desviación estándar de los algoritmos muestra que los resultados son un poco más variables para el SPEA2.

Tabla 8-14 GVND – Cantidad Nodos destinos: 30%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	16,80	7,7910	30,80	9,0388
NSF	20,80	5,2631	39,40	1,1402
Sprint	26,20	3,1145	35,60	6,0249

Cuando la cantidad de nodos destinos de las diferentes topologías corresponde al 30%, los dos algoritmos presentan un comportamiento levemente estable, donde el SPEA2, para todos los casos, arrojó un Frente de Pareto aproximadamente 40% superior al obtenido con el FSPEA2. Por otro lado, la diferencia entre la desviación estándar no supera, en promedio, el 1%; donde el comportamiento más estable se presenta en las topologías NSF y Sprint, para el caso del SPEA2 y FSPEA2 respectivamente.

Los valores desplegados en la Tabla 8 – 14 con los de la Tabla 8 – 15, los algoritmos presentaron un comportamiento estable, con respecto a todas las topologías. La excepción fue para el algoritmo SPEA2, en la que la cantidad de elementos no dominados disminuyó en un 40% con respecto a los anteriores; sin embargo, la desviación estándar muestra que este valor es variable.

Tabla 8-15 GVND – Cantidad Nodos destinos: 40%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	15,60	6,5038	19,80	10,3537
NSF	20,00	4,7434	39,80	6,9426
Sprint	23,60	5,0299	44,20	5,5408

En la Tabla 8 – 16 se muestran la cantidad de individuos no dominados obtenidos con ambos algoritmos en todas las topologías, siendo evidente que los valores se

mantienen estables, al igual que mantienen su nivel de variación, debido a que la desviación estándar también se muestra estabilizada. Sin embargo, observando la topología MCI, el algoritmo FSPEA2 arrojó un Frente de Pareto 31% superior al SPEA2; evidenciando poca variación de los datos, debido a los valores de las desviaciones estándar, las que a su vez son aproximadamente equivalentes.

Tabla 8-16 GVND – Cantidad Nodos destinos: 50%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	13,80	2,5884	9,00	2,5495
NSF	17,00	5,1478	40,60	3,0496
Sprint	19,60	4,2778	44,20	5,7619

Para una cantidad de nodos destinos correspondiente al 60%, en la topología MCI el FSPEA2 permite obtener un Frente de Pareto superior al SPEA2, donde esta diferencia alcanza, en promedio, un 68%; y la variación de estos valores es relativamente estable y equivalente. Por otro lado, en las topologías restantes, el SPEA2 obtiene valores superiores al FSPEA2, continuando con la tendencia mostrada anteriormente, sin embargo, la desviación estándar muestra la gran variación que estos valores pueden tener; mientras que el FSPEA2 muestra un comportamiento más estable.

Tabla 8-17 GVND – Cantidad Nodos destinos: 60%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	18,80	3,1145	6,00	3,0822
NSF	20,00	4,1833	28,60	15,5820
Sprint	23,80	7,2250	33,80	13,3304

En la Tabla 8 – 18 se muestran los resultados cuando 70% de los nodos de los grafos son destinos de flujos de datos en transmisión Multicast; en ella, se muestra un comportamiento estable en las topologías NSF y Sprint, mostrando una variación más estable en el SPEA2. En la topología MCI, el FSPEA2 obtuvo un Frente de Pareto

levemente superior al SPEA2, aunque la variación de este último es inferior a la del FSPEA2.

Tabla 8-18 GVND – Cantidad Nodos destinos: 70%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	12,20	6,3008	10,80	1,0954
NSF	19,80	5,0695	23,40	5,5946
Sprint	19,40	6,7676	45,60	6,9857

En la Tabla 8 – 19, se muestra que los Frente de Pareto generados por ambos algoritmos ha disminuido, aunque el nivel de variación en el FSPEA2 es inferior al mostrado en el SPEA2, adicionalmente, este último muestra una alta variación en la topología de Sprint. Por otro lado, para MCI, FSPEA2 obtuvo valores un 55% superiores que el SPEA2, donde éste último presenta un menor nivel de variación. Sin embargo, en las dos topologías restantes, SPEA2 obtuvo valores superiores, con respecto a la cantidad de individuos no dominados, aunque la variación que estos valores presentan es más estable en el FSPEA2

Tabla 8-19 GVND – Cantidad Nodos destinos: 80%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	9,40	4,4497	4,20	2,4900
NSF	16,20	4,0249	22,00	7,3485
Sprint	22,60	4,3359	39,80	13,0652

Finalmente, cuando la cantidad de nodos destinos corresponde al 90% de los nodos de los grafos correspondientes a las topologías seleccionadas, se observa que el algoritmo SPEA2 presenta la menor variación (topología MCI) y a su vez la más alta en la topología NSF; sin embargo, con el algoritmo en mención, se obtienen más miembros del Frente de Pareto en las topologías NSF y Sprint.

Tabla 8-20 GVND – Cantidad Nodos destinos: 90%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	10,00	3,3912	6,80	1,7889
NSF	19,00	3,3912	38,40	13,0307
Sprint	22,80	10,6395	44,20	9,1761

8.2.3 Distancia Generacionales (DG)

En la Tabla 8 – 21, se observa la distancia generacional para una cantidad de nodos destinos del 20%, apreciándose que para las tres topologías el algoritmo SPEA2 se encuentra más cerca al Frente de Pareto real que los obtenidos por el algoritmo FSPEA2, obteniéndose además una poca variación de los datos.

Tabla 8-21 DG – Cantidad Nodos destinos: 20%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	4,6260	0,6644	0,7702	0,1001
NSF	5,3667	0,4992	1,4173	0,3527
Sprint	6,1421	0,2445	1,7613	0,1011

Cuando la cantidad de nodos destinos equivale a un 30%, el algoritmo SPEA2 obtuvo una menor distancia con el Frente de Pareto Real; además, el valor de la desviación estándar muestra que se mantiene la poca variación de los datos.

Tabla 8-22 DG – Cantidad Nodos destinos: 30%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	5,6616	0,7311	1,7461	0,1345
NSF	5,9822	0,3637	1,9101	0,8457
Sprint	7,9092	0,4697	2,3990	0,1874

En la Tabla 8 – 23, muestra nuevamente que el algoritmo SPEA2 es más cercano al Frente de Pareto real, manteniendo los promedios de las desviaciones estándar; sin embargo es importante anotar, que a medida que se ha ido aumentando la cantidad de destinos, la distancia ha ido aumentando moderadamente.

Tabla 8-23 DG – Cantidad Nodos destinos: 40%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	6,3220	0,6813	1,8089	0,1298
NSF	7,2519	0,4698	2,4318	0,0915
Sprint	7,4104	0,2508	2,7888	0,3031

En las Tablas 8 – 24, 8 – 25 y 8 – 26, las cuales corresponden a un porcentaje de nodos destinos de 50%, 60% y 70% respectivamente; se observa que el FSPEA2 está más alejado del Frente de Pareto Real, frente a los resultados arrojado por el algoritmo SPEA2; siguiendo la tendencia de aumentar moderadamente la distancia entre los datos obtenidos y el Frente de Pareto Real a medida que aumenta la cantidad de destinos.

Tabla 8-24 DG – Cantidad Nodos destinos: 50%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	6,5421	0,2919	1,5547	0,1165
NSF	7,1801	0,4941	2,2905	0,1212
Sprint	8,7976	0,4770	2,6995	0,4773

Tabla 8-25 DG – Cantidad Nodos destinos: 60%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	7,4392	0,4491	1,9169	0,1239
NSF	7,7243	0,3077	2,5746	0,0758
Sprint	9,2079	0,2815	2,7463	0,1750

Tabla 8-26 DG – Cantidad Nodos destinos: 70%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	6,9336	0,1451	1,8275	0,0840
NSF	7,8755	0,5016	2,4516	0,1584
Sprint	8,5020	0,8323	3,1354	0,1882

Cuando la cantidad de nodos destinos corresponde al 80% y 90% de la totalidad de los nodos de las topologías seleccionadas, el resultado obtenido una menor distancia

entre los datos arrojados por el algoritmo SPEA2, frente a los arrojados por el FSPEA2.

Tabla 8-27 DG – Cantidad Nodos destinos: 80%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	7,6020	0,3745	2,1072	0,1410
NSF	8,1044	0,7477	3,0034	0,1088
Sprint	8,7876	0,5391	3,5372	0,2624

Tabla 8-28 DG – Cantidad Nodos destinos: 90%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	7,3736	0,2821	2,2567	0,0660
NSF	8,2653	0,7983	3,1317	0,0584
Sprint	9,4545	0,3373	3,2346	0,1243

En las tablas 8 – 29, 8 – 30 y 8 – 31 se presenta la distancia generacional entre los resultados obtenidos por el algoritmo FSPEA2 y el SPEA2, tomando éste último como el PF_{true} . En las tres topologías estudiadas, la distancia promedio entre las soluciones aumenta a medida que se incrementan la cantidad de nodos destinos; sin embargo, las desviaciones estándar se mantienen más estables.

Tabla 8-29 DG – Topología MCI PF_{true} SPEA2

Destinos	Promedio	Desv. Estándar
20%	10,5900	1,5550
30%	12,7490	2,2879
40%	16,7437	3,0154
50%	18,5933	0,8467
60%	22,7116	2,7307
70%	20,0972	1,5648
80%	21,1964	1,7292
90%	20,4959	1,6805

Tabla 8-30 DG – Topología NSF PF_{true} SPEA2

Destinos	Promedio	Desv. Estándar
20%	10,6033	1,0105
30%	12,3331	1,7370
40%	18,9641	1,9418
50%	19,0704	1,0357
60%	21,7082	1,4824
70%	24,6032	2,7265
80%	19,0175	1,6406
90%	23,7957	2,1398

Tabla 8-31 DG – Topología NSF PF_{true} SPEA2

Destinos	Promedio	Desv. Estándar
20%	11,9626	1,1552
30%	20,6629	2,0654
40%	18,9429	2,6230
50%	25,4522	3,2736
60%	25,2354	2,4759
70%	25,5237	1,8930
80%	24,5149	1,8572
90%	24,9161	0,5494

8.2.4 Spacing (S)

En la Tabla 8 – 32 se aprecian los resultados obtenidos por los algoritmos cuando la cantidad de nodos destinos corresponde al 20% de los nodos de la topología; en este caso, el algoritmo SPEA2 muestra estar distribuido más uniformemente, con una desviación estándar inferior para todas las topologías. Esta tendencia también es apreciable en las tablas 8 – 33, 8 – 34 y 8 – 35; las cuales despliegan los resultados obtenidos para una cantidad de destinos igual a 30%, 40% y 50% del total de nodos de cada una de las topologías seleccionadas.

Tabla 8-32 Spacing – Cantidad Nodos destinos: 20%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	3,6677	1,0721	0,7741	0,1006
NSF	3,7561	0,7787	1,4120	0,3944
Sprint	4,6015	0,6216	1,3709	0,1998

Tabla 8-33 Spacing – Cantidad Nodos destinos: 30%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	4,1419	1,3358	1,5620	0,1913
NSF	3,9501	1,6408	1,9101	0,8457
Sprint	6,1315	0,4641	1,9883	0,3974

Tabla 8-34 Spacing – Cantidad Nodos destinos: 40%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	5,2050	0,7725	1,5048	0,2838
NSF	5,9792	0,4729	1,7743	0,1443
Sprint	5,5548	0,0697	1,9588	0,2280

Tabla 8-35 Spacing – Cantidad Nodos destinos: 50%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	5,5747	0,5757	1,1797	0,0648
NSF	6,0571	0,9169	1,6841	0,1927
Sprint	7,2356	0,6556	1,8388	0,4022

Cuando la cantidad de nodos destinos corresponde al 60%, el algoritmo SPEA2 muestra una distribución más uniforme frente al algoritmo FSPEA2; sin embargo, hay un leve aumento en la variación de los datos arrojados en las topologías NSF y Sprint, mientras que en el FSPEA2 se siguen teniendo los mismos niveles de variación de los datos.

Tabla 8-36 Spacing – Cantidad Nodos destinos: 60%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	6,3752	0,8827	1,4947	0,1171
NSF	6,0635	0,9476	2,4653	1,2655
Sprint	7,8668	0,5858	2,7470	1,5236

En las Tablas 8 – 37, 8 – 38 y 8 – 39, se muestran los resultados obtenidos por ambos algoritmos cuando la cantidad de nodos destinos corresponde al 70%, 80% y 90% respectivamente; evidenciando la tendencia mostrada en los anteriores resultados, habiendo leves variaciones en las desviaciones estándar en cada uno de los algoritmos.

Tabla 8-37 Spacing – Cantidad Nodos destinos: 70%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	5,9275	0,2204	1,3840	0,3279
NSF	6,8578	0,7062	1,7580	0,4886
Sprint	7,0939	1,2738	2,1445	0,1930

Tabla 8-38 Spacing – Cantidad Nodos destinos: 80%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	6,1037	0,6332	1,4535	0,1350
NSF	6,9069	1,5144	2,4545	1,2341
Sprint	7,0712	0,8776	2,4425	0,3916

Tabla 8-39 Spacing – Cantidad Nodos destinos: 90%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	6,3358	0,3950	1,4776	0,1336
NSF	6,9188	1,1000	1,9578	0,2334
Sprint	7,5456	0,8483	2,2911	0,3891

Es importante resaltar que tanto para el FSPEA2 como para el SPEA2, a medida que aumenta la cantidad de nodos destinos, disminuye levemente la uniformidad de con la que se distribuyen los datos obtenidos en cada uno de los algoritmos.

8.2.5 Tiempo Computacional

En forma general, el algoritmo FSPEA2 consumió mucho más tiempo de ejecución que el SPEA2, alcanzando diferencias hasta por 16010.8%; esta evidencia se presenta en las Tablas 8 – 40 a la 8 – 47.

Tabla 8-40 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 20%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	55.540,80	17.140,70	7.487,80	241,27
NSF	212.922,00	28.933,69	9.053,20	355,03
Sprint	292.440,60	30.561,44	9.806,20	288,50

Tabla 8-41 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 30%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	202.134,40	80.752,96	12.193,80	608,87
NSF	178.312,60	47.886,01	8.700,00	263,69
Sprint	141.372,00	37.799,03	12.875,00	513,71

Tabla 8-42 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 40%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	2.351.409,60	930.071,30	35.434,40	6.531,64
NSF	1.366.103,60	864.307,00	29.465,60	3.423,94
Sprint	1.513.866,00	512.943,88	41.890,60	6.337,58

Tabla 8-43 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 50%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	1.335.028,20	361.850,24	38.997,00	1.899,93
NSF	1.353.537,60	575.151,26	35.606,40	1.438,37

Sprint	1.670.271,80	695.594,77	60.925,00	7.844,72
--------	--------------	------------	-----------	----------

Tabla 8-44 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 60%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	1.856.849,80	571.379,66	46.534,20	1.175,17
NSF	1.231.812,40	495.667,03	42.868,60	8.167,16
Sprint	1.613.678,00	599.677,30	44.846,80	2.268,30

Tabla 8-45 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 70%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	9.763.003,00	4.799.578,72	82.069,00	9.042,58
NSF	1.706.684,20	420.443,98	43.759,40	2.327,49
Sprint	16.332.765,60	8.509.832,28	134.553,40	8.821,63

Tabla 8-46 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 80%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	15.169.456,40	6.427.384,43	101.778,20	6.328,49
NSF	13.264.187,80	5.150.063,70	92.143,60	2.271,30
Sprint	20.532.325,20	5.236.726,05	128.240,80	5.337,24

Tabla 8-47 Tiempo de Ejecución (ms) – Cantidad Nodos destinos: 90%

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
MCI	7.745.819,00	2.775.833,72	96.684,40	4.308,15
NSF	11.851.103,20	1.334.610,23	111.343,80	4.708,76
Sprint	20.212.243,60	5.911.571,86	129.793,60	6.649,40

8.2.6 Análisis de Correlación

Con el fin de comprender la relación entre el comportamiento de cada una de las funciones objetivo, se analiza el coeficiente de correlación, para lo cual se debe tener en cuenta que:

- El coeficiente tiene valores adimensionales entre -1 y 1.
- El coeficiente tomará un valor de 1 cuando la relación entre las variables es perfecta y directamente proporcional.
- El coeficiente tomará un valor de -1 cuando la relación entre las variables a analizar es perfecta e inversamente proporcional.

Para realizar el análisis de correlación se tomó la topología MCI con la cantidad de nodos destinos correspondientes al 20, 50 y 90%; los coeficientes de correlación obtenidos se encuentran consignados en las tablas 8 – 45, 8 – 46 y 8 – 47; en las cuales se observa una estrecha relación entre varias funciones objetivos; sin embargo las relaciones que prevalecen son las siguientes:

- **Retardo (F0).** Esta función muestra una relación directa con dos objetivos. El primero de ellos es la Cantidad de saltos (F1), con un coeficiente promedio de 0.8645; el segundo es el Retardo Promedio (F5), donde se evidencia una relación perfecta y directa, ya que para todos los casos el coeficiente tomó el valor de uno (1).
- **Cantidad de Saltos (F1).** Los valores desplegados en las topologías seleccionadas evidencian que la relación que existe entre esta función y el Retardo (F0) – Retardo Promedio (F5) es la misma, mostrando un comportamiento promedio de 0.8645. Adicionalmente, muestra una estrecha relación con el objetivo Cantidad de Saltos Promedio (F6), sin llegar a ser una relación perfecta.
- **Máximo Retardo (F3).** El coeficiente de correlación que existe entre esta función y la Máxima Variación del Retardo (F8) es perfecta y directa, debido a que siempre se obtuvo un coeficiente de 1.
- **Máxima Cantidad de Saltos (F4).** Aunque en la topología MCI con 20% de nodos destinos no presenta una relación perfecta, ésta toma un valor considerablemente alto (0.98) con respecto al objetivo Máxima Variación de

la Cantidad de Saltos (F9); adicionalmente en las topologías siguientes se muestra una relación perfecta de 1.

Tabla 8-48 Coeficientes de Correlación de Funciones Objetivo – Topología MCI, destinos 20%

CORRELACION											
	F0	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10
F0		0,8527	0,1793	0,8632	0,6447	1,0000	0,8087	0,4497	0,8632	0,5775	0,2145
F1			0,1852	0,7320	0,8390	0,8527	0,9669	0,5105	0,7319	0,7877	0,4210
F2				0,1836	0,1454	0,1793	0,1654	0,4029	0,1837	0,1337	0,1158
F3					0,7222	0,8632	0,6957	0,4029	1,0000	0,6856	0,2586
F4						0,6447	0,8051	0,4624	0,7221	0,9890	0,4545
F5							0,8087	0,4498	0,8632	0,5775	0,2146
F6								0,4730	0,6956	0,7569	0,4337
F7									0,4029	0,4435	0,3842
F8										0,6855	0,2584
F9											0,4560
F10											

Tabla 8-49 Coeficientes de Correlación de Funciones Objetivo – Topología MCI, destinos 50%

CORRELACION											
	F0	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10
F0		0,8492	-0,1164	0,5897	0,3788	1,0000	0,7500	-0,0077	0,5898	0,3788	0,0976
F1			-0,1205	0,3935	0,5043	0,8492	0,9022	-0,0167	0,3935	0,5043	0,2266
F2				-0,0456	-0,0351	-0,1164	-0,1220	0,5980	-0,0456	-0,0351	0,0708
F3					0,4774	0,5897	0,3191	0,0334	1,0000	0,4774	0,0232
F4						0,3787	0,4653	0,0722	0,4774	1,0000	0,2019
F5							0,7499	-0,0077	0,5898	0,3787	0,0976
F6								0,0246	0,3191	0,4653	0,2341
F7									0,0335	0,0722	0,2158
F8										0,4774	0,0232
F9											0,2019
F10											

Tabla 8-50 Coeficientes de Correlación de Funciones Objetivo – Topología MCI, destinos 90%

CORRELACION											
	F0	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10
F0		0,8915	-0,0772	0,4701	0,4533	1,0000	0,7747	0,1651	0,4701	0,4533	0,0035
F1			-0,1145	0,3420	0,5663	0,8915	0,8871	0,1604	0,3420	0,5663	0,0440
F2				-0,0749	-0,0522	-0,0773	-0,0713	0,6209	-0,0749	-0,0522	0,0269
F3					0,2842	0,4700	0,3618	0,0023	1,0000	0,2842	-0,0811
F4						0,4533	0,5268	0,0334	0,2843	1,0000	0,0376
F5							0,7747	0,1651	0,4701	0,4533	0,0034
F6								0,1637	0,3617	0,5268	0,0352
F7									0,0023	0,0334	0,0557
F8										0,2843	-0,0811
F9											0,0376
F10											

8.2.7 Intervalo de Confianza

Este estimado busca encontrar el intervalo en el que varía un valor de una población, a partir del promedio, desviación estándar del mismo. Con el fin de analizar este estimado, se tomó la topología MCI, y en las tablas 8 – 51 a 8 – 58 se consignan los intervalos de los promedios de cada una de las funciones objetivo, tanto para SPEA2 y FSPEA2, con una confianza del 95%; evidenciando los porcentajes de diferencia desplegados en las Diferencias Normalizadas entre los algoritmos (Tabla 8 – 10).

Tabla 8-51 Intervalos de Confianza – Topología MCI, destinos 20%

Funciones	Intervalo FSPEA2		Intervalo SPEA2	
F0	70,0849	79,5485	38,9874	44,3962
F1	13,4229	15,1322	7,9697	8,8863
F2	114,6866	210,1460	14,9758	16,5762
F3	39,0440	44,0060	23,0144	26,5482
F4	6,7822	7,7158	3,9853	4,5947
F5	23,3618	26,5163	12,9960	14,7987
F6	4,1022	4,6978	2,3112	2,6768
F7	20,3387	25,2450	7,4879	8,2881
F8	34,6890	39,6507	18,6596	22,1930
F9	4,8682	5,7685	2,3822	3,0498
F10	5,3528	5,4908	5,1879	5,2853

Tabla 8-52 Intervalos de Confianza – Topología MCI, destinos 30%

Funciones	Intervalo FSPEA2		Intervalo SPEA2	
F0	149,1345	166,9700	117,2202	132,0732
F1	25,1226	27,9876	20,3326	22,6234
F2	153,6308	307,9692	28,4013	32,2227
F3	45,8938	49,9289	27,4867	29,9637
F4	7,5177	8,2619	4,8467	5,2773
F5	29,8270	33,3942	23,4441	26,4147
F6	4,6031	5,2091	3,6712	4,1648
F7	23,1389	28,4039	14,2007	16,1113
F8	31,6232	36,8945	6,2708	8,5329
F9	4,9387	5,9103	1,2944	1,7896
F10	4,8736	5,0771	4,5331	4,7698

Tabla 8-53 Intervalos de Confianza – Topología MCI, destinos 40%

Funciones	Intervalo FSPEA2		Intervalo SPEA2	
F0	184,4771	199,7725	131,0486	158,8885
F1	32,9536	35,6750	23,5975	27,7705
F2	223,0470	460,2836	29,4839	34,8481
F3	47,6634	51,7241	26,4789	30,6059
F4	8,4937	9,3022	4,8953	5,6087
F5	30,7461	33,2955	21,8413	26,4813
F6	5,0643	5,5235	3,5554	4,2486
F7	47,5338	58,9479	19,8153	23,2887
F8	32,3365	37,5094	7,6337	10,3450
F9	5,4922	6,4589	1,6271	2,0649
F10	5,2277	5,3261	5,1888	5,2051

Tabla 8-54 Intervalos de Confianza – Topología MCI, destinos 50%

Funciones	Intervalo FSPEA2		Intervalo SPEA2	
F0	236,3460	251,8866	148,0806	154,7890
F1	41,7331	44,3649	26,0866	27,1934
F2	291,5211	562,3891	26,1109	27,6851
F3	51,9116	55,7892	32,0223	34,2288
F4	8,9023	9,5140	5,3363	5,7117
F5	29,5433	31,4861	18,5100	19,3486
F6	4,7713	5,1308	2,8968	3,0312
F7	39,1436	46,7421	17,2005	18,2435
F8	49,5092	53,3869	29,6205	31,8264
F9	7,9023	8,5140	4,3363	4,7117
F10	5,3959	5,5487	4,8892	5,0390

Tabla 8-55 Intervalos de Confianza – Topología MCI, destinos 60%

Funciones	Intervalo FSPEA2		Intervalo SPEA2	
F0	313,7877	339,1871	173,6390	194,6488
F1	56,8122	61,0653	33,2914	35,9686
F2	368,0914	764,4637	31,9874	34,5766
F3	54,4947	57,4406	30,3130	35,6715
F4	9,6308	10,2549	5,3592	6,2048
F5	31,3789	33,9189	17,3637	19,4646
F6	5,2331	5,6976	2,9728	3,2592
F7	54,4899	64,8734	21,2739	23,0421
F8	44,0443	47,5105	22,9702	28,4871
F9	7,3155	8,0396	3,3518	4,2002
F10	5,6613	5,6613	5,4385	5,5615

Tabla 8-56 Intervalos de Confianza – Topología MCI, destinos 70%

Funciones	Intervalo FSPEA2		Intervalo SPEA2	
F0	350,8704	374,8334	190,7626	199,4658
F1	64,1144	67,6815	38,5088	39,8752
F2	283,9164	631,6182	28,0818	29,6822
F3	53,6263	56,9677	30,0290	32,1467
F4	9,1937	9,8022	5,6440	6,0480
F5	31,8976	34,0760	17,3420	18,1333
F6	5,3628	5,7311	2,9922	3,1198
F7	83,3214	106,8827	24,3534	25,6426
F8	49,5865	52,8637	26,7168	28,8602
F9	7,2938	7,9225	3,8893	4,3907
F10	5,4912	5,6033	5,1676	5,1956

Tabla 8-57 Intervalos de Confianza – Topología MCI, destinos 80%

Funciones	Intervalo FSPEA2		Intervalo SPEA2	
F0	378,3042	407,3298	191,6316	203,9122
F1	69,3029	73,7094	39,7453	41,5387
F2	350,5435	706,6320	28,3002	30,0698
F3	53,5943	56,8918	32,1854	35,9889
F4	9,3954	9,9025	6,0407	6,6153
F5	29,1004	31,3330	14,7409	15,6857
F6	4,8742	5,2400	2,6114	2,8566
F7	91,6177	113,6721	26,7501	28,1939
F8	52,9912	56,2891	31,5816	35,3849
F9	8,3954	8,9025	5,0407	5,6153
F10	5,4697	5,5865	5,2202	5,3136

Tabla 8-58 Intervalos de Confianza – Topología MCI, destinos 90%

Funciones	Intervalo FSPEA2		Intervalo SPEA2	
F0	412,2050	438,1712	247,4495	263,3139
F1	80,0412	84,1466	52,2635	54,5685
F2	338,7265	693,0612	30,9130	33,2350
F3	55,3396	58,2009	37,2649	40,8471
F4	10,2652	10,8532	7,0271	7,6289
F5	29,4431	31,2979	17,6749	18,8080
F6	5,2497	5,5911	3,1606	3,4114
F7	73,1142	85,3021	28,3796	30,0324
F8	53,5773	56,4387	35,5024	39,0847
F9	9,2652	9,8532	6,0271	6,6289
F10	5,6371	5,6703	5,3607	5,4901

8.3 CASOS DE PRUEBA

Los resultados obtenidos en el ítem 8.2 hacen necesaria la verificación de la cantidad de generaciones calculadas y la variación del nivel de certidumbre, con la esperanza de encontrar mejores resultados, originando dos (2) experimentos adicionales; para los cuales se tomó la topología NSF, con una cantidad de nodos destinos correspondientes al 20, 50 y 90 por ciento.

8.3.1 Aumento en Cantidad de Generaciones

Al verificar la cantidad de generaciones, se tomaron las topologías seleccionadas y se calcularon 150 generaciones (tres más que en el experimento original) en cinco (5) ocasiones con el algoritmo FSPEA2. A continuación se encuentra el contraste entre los resultados obtenidos y los arrojados en el primer experimento por el SPEA2.

8.3.1.1 Diferencia normalizada de las medias de los valores extremos (DNME)

En la tabla 8 – 59 se muestran los resultados obtenidos, los cuales al ser comparados con los consignados en la tabla 8 – 11, no muestran mayor variación en cuanto a la diferencia porcentual entre las soluciones obtenidas por el FSPEA2 y el SPEA2.

Tabla 8-59 DNME – Grafo Topología NSF – 150 Generaciones

Destinos	(FSPEA2 - SPEA2)/FSPEA2										
	F0	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10
20%	0,22375	0,22840	0,84727	0,39452	0,35031	0,22375	0,23364	0,41336	0,77234	0,67089	0,14136
50%	0,35680	0,35337	0,93246	0,45905	0,41066	0,35680	0,37843	0,59456	0,63240	0,54388	0,21980
90%	0,21547	0,18247	0,93043	0,25539	0,21194	0,21686	0,19150	0,60470	0,40925	0,39945	0,07267

8.3.1.2 Generación de vectores no dominados (GVND)

En la tabla 8 – 60 se encuentran los valores promedios de los individuos no dominados obtenidos en cada algoritmo. Al comparar los resultados con los consignados en las tablas 8 – 13, 8 – 16 y 8 – 20, se observa un ligero aumento en la cantidad de individuos no dominados obtenidos por el algoritmo FSPEA2 en los dos experimentos.

Tabla 8-60 GVND – Topología NSF – 150 Generaciones

Destinos	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
20%	18,4	2,0736	40,4	3,8471
50%	21	6,5192	40,6	3,0496
90%	11,4	4,8270	38,4	13,0307

8.3.1.3 Distancia Generacionales (DG)

Al comparar los resultados consignados en la tabla 8 – 61 con los obtenidos en el experimento inicial (tablas 8 – 21, 8 – 24 y 8 – 28) se observa que en el algoritmo FSPEA2 hay un leve incremento en la distancia de los Frente de Pareto conocidos con el Frente Pareto real; sin embargo, mantiene la misma diferencia promedio con los obtenidos a través del algoritmo SPEA2.

Tabla 8-61 DG – Topología NSF – 150 Generaciones

Destinos	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
20%	5,2058	0,5833	1,4173	0,3527
50%	9,4149	2,0861	2,2905	0,1212
90%	11,3330	2,1698	3,1317	0,0584

En la tabla 8 – 62, se presenta la distancia generacional de los resultados obtenidos en el presente experimento y el SPEA2; en ella se puede observar que, al igual que en el experimento inicial, los valores promedios de las distancias aumentan a medida que se incrementan la cantidad de nodos destinos; sin embargo, las desviaciones estándar presentan una alta variación, en lugar de permanecer estables. Lo anterior evidencia

que para una cantidad de destinos correspondientes al 20% de los nodos de la topología, los individuos solución guardan aproximadamente la misma distancia con respecto al PF_{true} ; mientras que, cuando la cantidad de nodos destinos aumenta (50% y 90%) los individuos tienden a estar a distancias muy variables con respecto al PF_{true} .

Tabla 8-62 DG – Topología NSF – 150 Generaciones PF_{true} SPEA2

Destinos	Promedio	Desv. Estándar
20%	10,088	0,080
50%	22,204	6,729
90%	30,040	4,724

8.3.1.4 Spacing (S)

En la tabla 8 – 63 se encuentran los resultados obtenidos por el algoritmo FSPEA2, contrastados con los obtenidos por el algoritmo SPEA2 en el experimento inicial. Analizando los valores arrojados por el FSPEA2, estos tuvieron un incremento promedio del 60% frente a los consignados en las tablas 8 – 32, 8 – 35 y 8 – 39.

Tabla 8-63 Spacing – Topología NSF – 150 Generaciones

Destinos	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
20%	3,6571	0,8433	1,4120	0,3944
50%	9,8539	3,6475	1,6841	0,1927
90%	13,2882	2,7071	1,9578	0,2334

8.3.1.5 Tiempo Computacional

Los tiempos computacionales de este nuevo experimento son visiblemente mayores, lo cual no es más que una consecuencia directa del aumento en la cantidad de generaciones a calcular (Tabla 8 – 64).

Tabla 8-64 Tiempo Computacional (ms) – Topología NSF – 150 Generaciones

Destinos	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
20%	777673,8	29074,99	9053,2	355,03
50%	16177634,2	1659534,43	35606,4	1438,37
90%	117994441,2	18557826,19	111343,8	4708,76

8.3.2 Nivel de Certidumbre

Con el fin de medir el efecto de la variación del nivel de certidumbre en los resultados se decidió generar una experimento en donde el valor de certidumbre se mantenga constante, siguiendo la recomendación dada por Reardon en [REA97a] y [REA97b], en la que se sugiere que este valor debe ser 0.9, y se calcularon 50 generaciones con las topologías seleccionadas en cinco (5) ocasiones, obteniéndose los resultados analizados a continuación.

8.3.2.1 Diferencia normalizada de las medias de los valores extremos (DNME)

En la tabla 8 – 65 se presentan los resultados obtenidos, los cuales al ser comparados con los consignados en la tabla 8 – 11, muestran una disminución en la diferencia de los valores obtenidos por el FSPEA2 con respecto al algoritmo SPEA2.

Tabla 8-65 DNME – Grafo Topología NSF – 150 Generaciones

Destinos	(FSPEA2 - SPEA2)/FSPEA2										
	F0	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10
20%	0,18356	0,16746	0,85970	0,39276	0,29720	0,18239	0,19461	0,34873	0,78944	0,64215	0,13659
50%	0,32751	0,30856	0,92647	0,45491	0,37733	0,32871	0,34769	0,60423	0,64291	0,52569	0,20519
90%	0,20480	0,17381	0,90169	0,25169	0,19354	0,20528	0,18997	0,61172	0,42293	0,38140	0,08017

8.3.2.2 Generación de vectores no dominados (GVND)

En la tabla 8 – 66 se encuentran los valores promedios de los individuos no dominados obtenidos en cada algoritmo. Al comparar los resultados con los consignados en las tablas 8 – 13, 8 – 16 y 8 – 20, se observa un aumento en la cantidad de individuos no dominados obtenidos por el algoritmo FSPEA2 en los dos experimentos anteriores, ya que pasó de obtener 17.67 individuos a 28 individuos no dominados. Igualmente, al comparar los resultados obtenidos en la topología NSF – 150 Generaciones (tabla 8 – 60), es notorio el incremento en la cantidad de individuos. Sin embargo, no alcanza a igualar o superar la cantidad de individuos no dominados del algoritmo SPEA2.

Tabla 8-66 GVND – Topología NSF – Certidumbre 0.9

Destinos	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
20%	22	9,2736	40,4	3,8471
50%	28,8	6,0992	40,6	3,0496
90%	33	7,2457	38,4	13,0307

8.3.2.3 Distancia Generacionales (DG)

Al comparar los resultados consignados en la tabla 8 – 67 con los obtenidos en el experimento inicial (tablas 8 – 21, 8 – 24 y 8 – 28) se observa que el algoritmo FSPEA2 mantiene la distancia generacional reportada en el experimento inicial. Al mismo tiempo, al comparar los valores de las tablas 8 – 61 y 8 – 67, los presentados en esta última son levemente inferiores.

Tabla 8-67 DG – Topología NSF – Certidumbre 0.9

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
20%	5,5560	0,6061	1,4173	0,3527
50%	7,7100	0,1326	2,2905	0,1212
90%	8,2506	0,4670	3,1317	0,0584

Cuando se calculan las distancias de las soluciones obtenidas con el nivel de certidumbre constante y el arrojado por SPEA2, se puede observar que al aumentar la cantidad de nodos destinos se incrementa la distancia; sin embargo, la desviación estándar se mantiene estable; indicando que los valores tienden a estar equidistantes con respecto al PF_{true} .

Tabla 8-68 DG – Topología NSF – Certidumbre 0.9 PF_{true} SPEA2

Destinos	Promedio	Desv. Estándar
20%	10,7662	0,3870
50%	16,1263	0,3663
90%	20,6408	1,8526

8.3.2.4 Spacing (S)

En la tabla 8 – 69 se encuentran los resultados obtenidos por el algoritmo FSPEA2, contrastados con los obtenidos por el algoritmo SPEA2 en el experimento inicial. Analizando los valores arrojados por el FSPEA2, estos mantuvieron los niveles reportados en el experimento inicial, consignados en las tablas 8 – 32, 8 – 35 y 8 – 39; por lo que no se presenta ninguna mejora.

Tabla 8-69 Spacing – Topología NSF – Certidumbre 0.9

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
20%	3,9700	0,8458	1,4120	0,3944
50%	6,2428	0,3941	1,6841	0,1927
90%	6,6917	0,7638	1,9578	0,2334

8.3.2.5 Tiempo Computacional

En la tabla 8 – 70 se encuentran los tiempos computacionales promedios obtenidos en las cinco (5) ejecuciones del algoritmo. Al comparar los valores con los mostrados en las tablas 8 – 40, 8 – 43 y 8 – 47, es notoria una disminución en el tiempo de ejecución, consecuencia directa de la no variación del nivel de certidumbre.

Tabla 8-70 Tiempo Computacional (ms) – Topología NSF – Certidumbre 0.9

Topología	FSPEA2		SPEA2	
	Promedio	Desv. Estándar	Promedio	Desv. Estándar
20%	257234,4	22078,59	9053,2	355,03
50%	857181,2	1073319,66	35606,4	1438,37
90%	39256	3627,28	111343,8	4708,76

9 CONCLUSIÓN Y TRABAJOS FUTUROS

9.1 CONCLUSIÓN

En la presente investigación se trata la transmisión multicast en árboles origen–destino estáticos, sobre redes GMPLS, en las que se desean optimizar once (11) funciones objetivo y cuya solución se alcanza a través de metaheurísticas, presentando dos algoritmos SPEA2 y FSPEA2. Éste último es una propuesta que integra la lógica difusa sobre el algoritmo SPEA2.

De acuerdo con los resultados discutidos en el ítem 8.2, en los que se muestra el comportamiento de los algoritmos en las topologías MCI, NSF y Sprint, se puede concluir:

- Cuando el valor de certidumbre varía ampliamente, el algoritmo FSPEA2 no obtiene soluciones satisfactorias en comparación con el SPEA2. Aún cuando se aumenta la cantidad de generaciones calculadas, se mantienen los valores de las diferentes métricas multiobjetivo evaluadas en la presente investigación (diferencia normalizada, cantidad de individuos no dominados, distancia con el frente de pareto real y la distancia entre los individuos solución) Lo anterior se debe a que la cantidad de generaciones calculadas con un nivel de certidumbre superior a 0.9 no logran ser suficientes para igualar o superar el nivel del SPEA2.
- Manteniendo el valor de certidumbre fijo en 0.9, el algoritmo FSPEA2 logra mejorar los resultados obtenidos, permitiendo aumentar la cantidad de

individuos no dominados de la solución; sin embargo, no logra alcanzar el nivel de solución logrado por el algoritmo SPEA2.

- Al correlacionar las métricas multiobjetivo Distancia Generacional y Spacing, se concluye que los resultados arrojados por el algoritmo FSPEA2 se concentran en una zona del frente de Pareto real.
- Los valores mínimos obtenidos por el SPEA2 y el FSPEA2 son los mismos en la topología MCI con una cantidad de nodos destinos correspondiente al 20%. Lo cual es consecuencia directa de que algunos individuos encontrados por el SPEA2 hallan sido encontrados también por el FSPEA2. Confirmando la legitimidad del método propuesto.
- Basados en el análisis de correlación el modelo puede reducirse a siete (7) funciones objetivos. Eliminando las funciones Retardo (F0), Cantidad de Saltos (F1), Máximo Retardo (F3) y Máxima Cantidad de Saltos (F4); dejando para el estudio el comportamiento del Retardo Promedio (F5), Cantidad de Saltos Promedio (F6), Máxima Variación del Retardo (F8) y Máxima Variación de la Cantidad de Saltos (F9) respectivamente; debido a que éstas últimas arrojan valores más significativos y equicomparables.
- Las condiciones bajo las que se concibió el modelo matemático a solucionar, tienen por naturaleza, un nivel de certidumbre muy alto, por lo que la amplia variación de éste arrojó soluciones medianamente alejadas a las encontradas con un nivel de certidumbre de uno (1), como las obtenidas por el SPEA2.

9.2 TRABAJOS FUTUROS

La presente investigación propone un algoritmo que mezcla la lógica difusa con algoritmos evolutivos, más específicamente con el SPEA2; sin embargo existen

condiciones experimentales necesarias para medir el comportamiento del algoritmo propuesto, las más significativas son:

- Implementar un algoritmo predictivo, basado en inteligencia artificial, enfocado al cálculo de la mejor variación del nivel de certidumbre.
- Proponer un modelo que permita solucionar MOPs en transmisión Multicast dinámica.
- Estudiar el comportamiento del algoritmo FSPEA2 en problemas multi objetivo en redes con transmisión multicast que optimicen variables con incertidumbre, tales como: pérdida de paquetes, calidad y confiabilidad del enlace, así como también diferentes tipos de retardo.

BIBLIOGRAFÍA

- [ASS03] ASSI, Chadi. *Optical networking and real-time provisioning: An integrated vision for a next generation survivable optical Internet.* (No publicado). The City University of New York. Junio 2003. En: Digital Dissertations.
- [AWD01] AWDUCHE, Daniel; REKHTER, Yakov. *MPλS (Multiprotocol Lambda Switching): Combinando el Control de la Ingeniería de Tráfico de MPLS con los Conmutadores Ópticos.* Trad. Antonio Salavert. IEEE Communications Magazine, Marzo 2001.
- [BAE00] BAEZA, Daniel Michael. *Studies on modern telecommunications planning: Technoeconomical considerations and environmental issue.* (No publicado). Florida Atlantic University. Diciembre 2000. En: Digital Dissertations.
- [BAN01] BANERJEE, Ayan; et. Al. *Generalized Multiprotocol Label Switching: Una Visión de las Mejoras de Encaminamiento y Gestión.* Trad. Antonio Salavert. IEEE Communications Magazine, Enero 2001.
- [BLA02] BLACK, UYless. *MPLS & Label Switching Networks.* USA, Prentice Hall. 314 páginas. 2002.

- [CAR05] CARO PÉREZ, Luis Fernando; y ROSADO GUTIERREZ, Pierre. *Optimización Multi-Objetivo En Transmisiones Multicast Sobre Redes Ópticas Usando Algoritmos Evolutivos, Meméticos Y Ant-Colony*. Barranquilla. Junio 2005.
- [COE 02a] COELLO, Carlos. *Introducción a la Optimización Multiobjetivo*. México D.F. Septiembre 2002. En: <http://neo.lcc.uma.es/pdf-charlas/MOEA.pdf>
- [COE02b] COELLO, Carlos. *Aplicaciones de los Algoritmos Evolutivos Multiobjetivo*. México D.F. Septiembre 2002. En: <http://neo.lcc.uma.es/pdf-charlas/apli-MOEA.pdf>
- [COL03] COLLETTE, Yann y SIARRY, Patrick. *MultiObjective Optimization Principles and Case Studies*. 1st Edition. Germany, Springer-Verlong. 2003. 293 Páginas.
- [DEB01] DEB, Kalyanmoy. *Multi-Objective Optimization Using Evolutionary Algorithms*. USA, Willey and Son. 2001. 497 Páginas.
- [DON03a] DONOSO MEISEL, Yezid; FABREGAT, Ramon y MARZO, José. *Multi-Objective Optimization Algorithm for Multicast Routing with Traffic Engineering*. IEEE 2003.
- [DON03b] DONOSO MEISEL, Yezid; FABREGAT, Ramon y MARZO, José. *Multicast Routing With Traffic Engineering: A Multi-Objective Optimization Scheme And A Polynomial Shortest Path Tree Algorithm With Load Balancing*. IEEE 2003.
- [DON03c] DONOSO MEISEL, Yezid; FABREGAT, Ramon y MARZO, José. *Multi-Objective Scheme over Multi-Tree Routing in Multicast MPLS Networks*. In: *Latin American Networking Conference (LANC'03)*. (2003 : La Paz).

- [DUA 01] DUARTE, Susana y BARÁN, Benjamín. *Multiobjective Network Design Optimization using Parallel Evolutionary Algorithms [online]*. En XXVII Conferencia Latinoamericana de Estudios Informáticos. (27°:2001:Mérida).En:
<http://www.cnc.una.py/invest/publicaciones.html>
- [GAL93] GALVE, Javier et al. *Algoritmica. Diseño y Análisis de Algoritmos Funcionales e Imperativos*. USA, Addison – Wesley Iberoamericana. 502 páginas. 1993.
- [GEN00] GEN, Mitsuo y RUNWEI, Cheng. *Genetic Algorithms & Engineering Optimization*. USA, Willey- Interscience. 2000. 494 Páginas.
- [HAN03] HAN, Yutao. *An efficient unicast-based multicast tree construction and maintenance for multimedia transmission*. (No publicado). Utah State University. Diciembre 2003. En: Digital Dissertations.
- [HER03] HERNANDEZ, R; FERNANDEZ, C; BAPTISTA, P. *Metodología de la investigación*. Mc Graw Hill. 3a edición. 2003.
- [JER01] JERRAM, Neil; y FARREL, Adrian. *MPLS en las Redes Ópticas*. Trad. Antonio Salavert. Data Connection Limited. Octubre 2001.
<http://people.ac.upc.es/asalaver/jerram1.pdf>
- [KUE01] KUEHL, Robert O. *Diseño de Experimentos: Principios estadísticos para el diseño y análisis de investigaciones*. Trad.: María González Osuna. México, Thomson Learning. 2001. 666 páginas.
- [LI04] LI, Yihan. *Design and analysis of scheduling for high speed input queued switches*. (No publicado). Polytechnic University of Brooklyn, NY. Enero 2004. En: Digital Dissertations.

- [LIA03] LIANG, Song Sam. *Unifying the transport layer of a packet-switched internetwork*. (No publicado). Stanford University. Marzo 2003. En: Digital Dissertations.
- [LÜC 04] LÜCKEN, Christian Von et al. *Algoritmos Evolutivos para Optimización Multiobjetivo: un Estudio Comparativo en un Ambiente Paralelo Asíncrono*. Universidad Nacional de Asunción. Paraguay. 2004. En: <http://www.cnc.una.py/invest/publicaciones.html>
- [MEN02] MENDENHALL, William III. WACKERLY, Dennis D; y SCHEAFFER, Richard L. *Estadística matemática con aplicaciones*. Trad. Jorge Yescas Milanés. México, Thomson. 2002. 853 páginas.
- [MON04] MONTGOMERY, D. *Diseño y Análisis de Experimentos*. Limusa Wiley. 2a edición. 2004.
- [MUK97] MUKHERJEE, Biswanath. *Optical Communications Networks*. USA, McGraw – Hill. 1997. 576 páginas.
- [RAJ03] RAJAGOPALAN, Bala; LUCIANI, James; AWDUCHE, Daniel. *IP sobre Redes Ópticas: un Marco*. Trad. Antonio Salavert. Internet Draft Octubre 2003. <http://people.ac.upc.es/asalaver/ipoptical1.pdf>
- [REA97a] Reardon, B. J. *Fuzzy Logic vs Niche Pareto Multi-Objective Genetic Algorithm Optimization: Part I: Schaffer's F2 Problem*. Technical report LA-UR-97-3675, Los Alamos National Laboratory, 1997.
- [REA97b] Reardon, B. J. *Fuzzy Logic vs Niche Pareto Multi-Objective Genetic Algorithm Optimization: Part II: a Simplified Born-Mayer Problem*. Technical report LA-UR-97-3676, Los Alamos National Laboratory, 1997.

- [SAK02] SAKAWA, Masatoshi. *Genetic Algorithms and Fuzzy Multi-Objective Optimization*. USA, Kluber Academic Publisher. 2002. 288 Páginas.
- [SEM00] SEMERIA, Chuck. *Multiprotocol Label Switching. Enhancing Routing in the New Public Network*. Juniper Networks, Inc. 2000. http://www.juniper.net/solutions/literature/white_papers/200001.pdf
- [SHA03] SHAMI, Abdallah. *Traffic engineering in hybrid, IP-centric DWDM-based optical networks*. (No publicado). The City University of New York. Febrero 2003. En: Digital Dissertations.
- [TAL 04] TALAVERA, Francisco et al. *Comparación de Algoritmos Evolutivos Multiobjetivos en un Ambiente Multicast*. Universidad Nacional de Asunción. Paraguay. 2004. En: <http://www.cnc.una.py/invest/publicaciones.html>
- [UNI04] UNIVIRTUAL. *Diseño Experimental*. Departamento de Estadística, Universidad Nacional de Colombia. Septiembre 6 de 2004. <http://www.virtual.unal.edu.co/cursos/ciencias/2000352/index.html>. (Julio 1 de 2006).
- [VAL01] VALCARENGHI, Luca. *Survivable IP-over-WDM networks*. (No publicado). The University of Texas at Dallas. Diciembre 2001. En: Digital Dissertations.
- [WAJ02] WANG, Jian. *Design and analysis of optical WDM metropolitan and wide-area networks*. (No publicado). University of California DAVIS. 2002. En: Digital Dissertations.
- [WAK03] WANG, Kang Bin. *Multicasting in MPLS networks*. (No publicado). Concordia University (Canada). Junio 2003. En: Digital Dissertations.

- [WIL00] WILLIAMSON, Beau. *Developing IP Multicast Networks*. Vol 1. USA, CISCO Press, 2000. 568 páginas.
- [WON01] WONG, Vincent Chi Chiu. *Lightpath routing and resource reservation: An integrated solution for IP over DWDM networks*. (No publicado). University of Toronto (Canada). 2001. En: Digital Dissertations.
- [WU03] WU, Wenji. *Modeling and analysis of GMPLS-based automatically switched optical network*. (No publicado). University of Arizona. Agosto 2003. En: Digital Dissertations.
- [XIN02] XIN, Chunseng. *Optical network control, engineering and switching*. (No publicado). State University of New York at Buffalo. Julio 2002. En: Digital Dissertations.
- [YE00] YE, Yinghua. *Multiwavelength optical networks capabilities for next generation Internet*. (No publicado). The City University of New York. Mayo 2000. En: Digital Dissertations.
- [ZIT 02] ZITZLER, Eckart et al. *SPEA2: Improving the Strength Pareto Evolutionary Algorithm for Multiobjective Optimization*. Computer Engineering and Network Laboratory. Barcelona, España. 2002. En: <http://sci2s.ugr.es/docencia/doctobio/SPEII.pdf>
- [RFC3031] RFC 3031. *MPLS – Multiprotocol Label Switching Architecture*. Enero de 2001. <http://people.ac.upc.es/asalaver/rfc3031-es.pdf>.
- [RFC3032] RFC 3032. *Codificación de la pila de Etiquetas MPLS*. Trad. Antonio Salavert. Enero de 2001. <http://people.ac.upc.es/asalaver/rfc3032-es.pdf>.

- [RFC3353] RFC 3353. *Overview of IP Multicast in a Multi-Protocol Label Switching (MPLS) Environment*. Agosto de 2002. www.ietf.org.
- [RFC3443] RFC 3443. *Procesamiento del tiempo de vida (TTL) en Redes MPLS (Multi-Protocol Label Switching)*. Trad. Antonio Salavert. Enero de 2003. <http://people.ac.upc.es/asalaver/rfc3443-es.pdf>.
- [RFC3471] RFC 3471. *Generalized Multi-Protocol Label Switching (GMPLS) Descripción Funcional de la Señalización*. Trad. Antonio Salavert. Enero de 2003. <http://people.ac.upc.es/asalaver/rfc3471-es.pdf>.
- [RFC3474] RFC 3474. *Documentación de las asignaciones de IANA para el GMPLS (Generalized Multiprotocol Label Switching), RSVP-TE (Resource Reservation Protocol – Traffic Engineering, Utilización y Extensiones para ASON (Automatically Switched Optical Network))*. Trad. Antonio Salavert. Marzo de 2003. <http://people.ac.upc.es/asalaver/rfc3474-es.pdf>.