



UNIVERSIDAD DEL BÍO-BÍO

FACULTAD DE CIENCIAS EMPRESARIALES

GENERACIÓN AUTOMÁTICA DE PATRONES DE ENTRELAZAMIENTO DE IMÁGENES PARA COMUNICACIÓN ROBUSTA UTILIZANDO ALGORITMOS GENÉTICOS

TESIS PRESENTADA POR KATHERINE BETSABÉ ZAPATA QUIÑONES
PARA OBTENER EL GRADO DE MAGÍSTER EN CIENCIAS DE LA COMPUTACIÓN

Gilberto Gutiérrez, Cristian Durán Faúndez

2017

Departamento de Ciencias de la Computación y Tecnologías de Información

Agradecimientos

Este trabajo no habría sido posible sin la ayuda de Dios primeramente, ni sin el apoyo y el estímulo de mis profesores, Doctores Gilberto Gutierrez Retamal y Cristian Duran-Fundez, bajo cuya supervisión he desarrollado el proyecto de Tesis.

También me gustaría agradecer a la profesora María Angélica Pinninghoff Junemann, a Eric Orellana-Romero y Christopher Arredondo Flores por apoyar el desarrollo de esta Tesis.

No puedo terminar sin agradecer a mi familia, cuyo estímulo constante y amor me han acompañado en mis años de estudio. Agradezco a mi Esposo Hugo Jara por su apoyo y colaboración, a mi hijo Maximiliano Jara por estar a mi lado en este proceso y a mi Madre Delia Quiñones por sus enseñanzas que me han ayudado a finalizar cada uno de los desafíos que me he embarcado. Es a ellos a quien dedico este trabajo.

Índice general

Agradecimientos	2
1 Introducción	19
1.1 Hipótesis y objetivos	21
1.2 Alcances de la tesis	23
1.3 Organización del documento	23
2 Métodos de Entrelazamiento	24
2.1 Método de mezclado de <i>Turner y Peterson</i>	25
2.2 Entrelazado Dual Stream JPEG-Adaptation Layer	25
2.3 Entrelazado horizontal de <i>DeBrunner et al.</i>	26
2.4 Método de entrelazamiento Automorfismos Torales	27
2.5 Método de Rombaut	27
2.6 Conclusión del capítulo	28
3 Introducción a los Algoritmos Genéticos	30
3.1 Principios de optimización	30
3.1.1 Formalización de un problema de optimización	30
3.1.2 Optimización combinatoria	32
3.1.3 Clasificación de los algoritmos de optimización	32
3.2 Algoritmos Genéticos	34
3.2.1 Definición	34
3.2.2 Características	36
3.2.3 Vocabulario general	37
3.2.4 Aspectos básicos de un AG	37
3.2.5 Cruzamiento	39
3.2.6 Mutación	41
3.2.7 Siguiete generación (Reemplazo)	43
3.2.8 Criterio de detención	43

4	Propuesta	44
4.1	Componentes del AG propuesto	45
4.1.1	Esquema de codificación	45
4.1.2	Población inicial	45
4.1.3	Función de evaluación	46
4.1.4	Selección	48
4.1.5	Cruzamiento	48
4.1.6	Mutación	48
4.2	Análisis para selección de parámetros	48
4.2.1	Esquemas de prueba	48
4.2.2	Resultados	50
4.2.3	Conclusión pruebas	52
5	Resultados experimentales	66
5.1	Evaluación del AG y comparación con otros métodos	67
5.1.1	Evaluación de patrones mediante simulaciones	80
5.1.2	Conclusión de las evaluaciones	94
6	Conclusiones	96
6.1	Trabajo Futuro	98
	Bibliografía	99
	Anexos	104
A	Análisis para selección de parámetros	105
A.1	Resultados pruebas tamaño de población.	105
A.1.1	Valores de aptitud y tiempo de ejecución promedio Tp.	105
A.1.2	Distancia Ecludianan: Valores de aptitud y tiempo de ejecución promedio Tp.	105
A.2	Resultados pruebas probabilidad de cruce.	106
A.2.1	Valores de aptitud y tiempo de ejecución promedio Pc.	106
A.3	Resultados pruebas probabilidad de mutación.	106
A.3.1	Valores de aptitud y tiempo de ejecución promedio Pm.	106
A.4	Resultados pruebas porcentaje de supervivencia.	106
A.4.1	Valores de aptitud y tiempo de ejecución promedio PS.	106
A.5	Resultados pruebas número de generaciones.	106
A.5.1	Valores de aptitud y tiempo de ejecución promedio NG.	106

B	Resultados evaluación de patrones mediante simulaciones	108
B.1	Resultados por Imagen	108
B.1.1	PSNR promedio patrón SE	108
B.1.2	PSNR promedio, patrón AG	108
B.1.3	PSNR promedio, patrón AR	109
B.1.4	PSNR promedio, patrón AT	109
B.1.5	PSNR menor, patrón SE	109
B.1.6	PSNR menor, patrón AG	110
B.1.7	PSNR menor, patrón AR	110
B.1.8	PSNR menor, patrón AT	110
B.1.9	PSNR mayor, patrón SE	111
B.1.10	PSNR mayor, patrón AG	111
B.1.11	PSNR mayor, patrón AR	111
B.1.12	PSNR mayor, patrón AT	112
B.2	Resultados por patrón	112
B.2.1	PSNR promedio imagen B	112
B.2.2	PSNR promedio imagen BR	113
B.2.3	PSNR promedio imagen C	113
B.2.4	PSNR promedio imagen F	113
B.2.5	PSNR promedio imagen G	114
B.2.6	PSNR promedio imagen L	114
B.2.7	PSNR promedio imagen P	115
B.2.8	PSNR promedio imagen S	115
B.2.9	PSNR menor y mayor imagen B	115
B.2.10	PSNR menor y mayor imagen BR	116
B.2.11	PSNR menor y mayor imagen C	116
B.2.12	PSNR menor y mayor imagen F	116
B.2.13	PSNR menor y mayor imagen G	117
B.2.14	PSNR menor y mayor imagen L	117
B.2.15	PSNR menor y mayor imagen P	117
B.2.16	PSNR menor y mayor imagen S	118
B.2.17	Desviación estandar imagen B	118
B.2.18	Desviación estandar imagen BR	118
B.2.19	Desviación estandar imagen C	119
B.2.20	Desviación estandar imagen F	119
B.2.21	Desviación estandar imagen G	120

B.2.22	Desviación estandar imagen L	120
B.2.23	Desviación estandar imagen P	120
B.2.24	Desviación estandar imagen S	121
B.3	Resultados VFCD v/s PSNR.	121
B.3.1	VFCD escenario 1.	121
B.3.2	PSNR escenario 1.	122
B.3.3	VFCD escenario 5.	122
B.3.4	PSNR escenario 5.	122

Índice de figuras

1.1	Transmisión secuencial de imágenes [gentileza de Eric Orellana-Romero]. . .	20
1.2	Transmisión de imágenes utilizando entrelazamiento [gentileza de Eric Orellana-Romero].	21
2.1	Esquema de entrelazamiento utilizando una configuración de paquetización básica [gentileza de Eric Orellana-Romero].	24
2.2	Esquema de una secuencia de transmisión usando método Turner y Peterson, obtenido de [45].	25
2.3	Esquema de entrelazado horizontal de píxeles	26
2.4	Ejemplo de máscara de paquetización	28
3.1	Familia de los Algoritmos Evolutivos [48].	35
3.2	Ciclo básico de los Algoritmos Evolutivos [48].	35
3.3	Representación binaria de un cromosoma, obtenido de [39].	38
3.4	Representación de una selección por ruleta con las probabilidades de los cuatro elementos que componen la población.	39
3.5	Representación de cruce en un punto [39].	40
3.6	Representación de Partially-mapped crossover (PMX) obtenido de [27]. . .	40
3.7	Ejemplo de cruzamiento OX1. En (a), la representación de los padres (P1 y P2). (b) muestra la realización de cortes en cada uno de los padres. (c) muestra los hijos que en una primera instancia poseen los elementos entre los cortes (ejemplo: H1 posee elementos entre los cortes de P1). Finalmente, (d) muestra la nueva posición de los elementos del padre (Ejemplo: H1 posee los elementos de P2 que aún no están contenidos en H1).	41
3.8	Representación de Position based crossover (POS)[27].	41
3.9	Representación de mutación.	42
3.10	Representación de Displacement mutation (DM), obtenido de [27].	42
3.11	Representación de Insertion mutation (ISM), obtenido de [27].	43
3.12	Representación de Inversion mutation (IVM), obtenido de [27].	43

4.1	Ejemplo de esquema de codificación utilizado para representar el cromosoma.	45
4.2	Ejemplo de generación de individuos.	45
4.3	Valores de aptitud alcanzados para Tp 50, 100 y 150 en cada ejecución. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16,(c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25	53
4.4	Valores de aptitud y tiempo de ejecución promedio para Tp 50, 100 y 150. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16,(c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25	54
4.5	Valores de aptitud alcanzados para Pc 0.6, 0.8 y 1 en cada ejecución. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16,(c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25	55
4.6	Valores de aptitud y tiempo de ejecución promedio para Pc 0.6, 0.8 y 1. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16,(c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25	56
4.7	Valores de aptitud alcanzados para Pm 0.01, 0.03 y 0.05 en cada ejecución. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16,(c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25	57
4.8	Valores de aptitud y tiempo de ejecución promedio para Pm 0.01, 0.03 y 0.05. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16,(c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25.	58

4.9	Valores de aptitud alcanzados para PS 0, 0.1 y 0.2 en cada ejecución. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16,(c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25	59
4.10	Valores de aptitud y tiempo de ejecución promedio para PS 0, 0.1 y 0.2. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16,(c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25	60
4.11	Valores de aptitud alcanzados para NG 500, 1000 y 1500 en cada ejecución. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16,(c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25	61
4.12	Valores de aptitud y tiempo de ejecución promedio para NG 500, 1000 y 1500. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16,(c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25.	62
4.13	Valor de aptitud promedio por generación. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16,(c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25	63
4.14	Resultados pruebas adicionales para Máscara 16x16 y Particiones 27 (a) Gráfico número de generación versus aptitud para NG 5000. (b) Gráfico Tiempo de ejecución versus número de generación para NG 5000.	64
4.15	Resultados pruebas adicionales para Máscara 16x16 y Particiones 27 (a) Gráfico número de generación versus aptitud para Tp 1000. (b) Gráfico Tiempo de ejecución versus número de generación para Tp 1000.	65
5.1	VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 1 (máscara 8x8, particiones 6).	71
5.2	VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 2 (máscara 8x8, particiones 25).	71
5.3	VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 3 (máscara 16x16, particiones 6).	72

5.4	VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 4 (máscara 16x16, particiones 25).	72
5.5	VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 5 (máscara 16x16, particiones 27).	73
5.6	VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 6 (máscara 16x16, particiones 100).	73
5.7	VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 7 (máscara 32x32, particiones 6).	74
5.8	VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 8 (máscara 32x32, particiones 25).	75
5.9	resultados considerando 5000 iteraciones, escenario 5 (máscara 8x8, particiones 6). (a) VPFCR de AG y AR por iteración. (b) tiempo de ejecución por iteración	76
5.10	resultados considerando elementos sujetos a evaluación igual a 1000, escenario 5 (máscara 8x8, particiones 6). (a) VPFCR de AG y AR por iteración. (b) tiempo de ejecución por iteración	77
5.11	Gráfica de tiempos de ejecución por AG, AR y AG en alcanzar un valor aproximado bajo la evaluación de FCR.	78
5.12	Imágenes utilizadas en simulaciones	81
5.13	Promedio, mayor y menor PSNR alcanzado en el escenario 1 dependiendo del patrón e imagen.	84
5.14	Imágenes obtenidas mejor PSNR alcanzado después de simulaciones, aplicando el 50 % de Loss Rate, escenario 5	90
5.15	Imágenes obtenidas mejor PSNR alcanzado después de simulaciones, por patrón SE, AG, AR y AT, escenario 5	91
5.16	(a) Gráfico mejores VFCR alcanzados en evaluación del AG basado en otros métodos por SE, AG, AR Y AT, aplicando el 20 % de Loss Rate, escenario 1 . (b) Gráfico mejores PSNR alcanzados en evaluación de patrones mediante simulaciones por patrón SE, AG, AR y AT, imagen Baboon, aplicando el 20 % de Loss Rate, escenario 1	92
5.17	(a) Gráfico mejores VFCR alcanzados en evaluación del AG basado en otros métodos por SE, AG, AR Y AT, aplicando el 20 % de Loss Rate, escenario 5 . (b) Gráfico mejores PSNR alcanzados en evaluación de patrones mediante simulaciones por patrón SE, AG, AR y AT, imagen Baboon, aplicando el 20 % de Loss Rate, escenario 5	92

Índice de tablas

2.1	Resumen de Métodos de entrelazamiento presentados	28
3.1	Nomenclatura Algoritmos Genéticos.	38
4.1	Abreviaciones parámetros del AG	44
4.2	Escenarios	49
4.3	Esquema de Pruebas Tp	49
4.4	Esquema de Pruebas Pc	50
4.5	Esquema de Pruebas Pm	50
4.6	Esquema de Pruebas PS	50
4.7	Esquema de Pruebas NG	50
5.1	Escenarios	69
5.2	Parámetros AG	69
5.3	Parámetros AR	69
5.4	Mejores parámetros AT por escenario	69
5.5	Resultados FCR por escenario.	70
5.6	Escenarios	81
5.7	Desviación estandar de acuerdo a los resultados por imagen utilizando el patrón SE, escenario 1	83
5.8	Desviación estandar de acuerdo a los resultados por imagen utilizando el patrón AG, escenario 1	84
5.11	PSNR promedio y mínimo y máximo alcanzados en el escenario 1 por patrón e imagen.	86
5.9	Desviación estandar de acuerdo a los resultados por imagen utilizando el patrón AR, escenario 1	87
5.10	Desviación estandar de acuerdo a los resultados por imagen utilizando el patrón AT, escenario 1	87

5.12	Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen B, escenario 1 .	87
5.13	Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen BR, escenario 1 .	87
5.14	Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen C, escenario 1 .	88
5.15	Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen F, escenario 1 .	88
5.16	Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen G, escenario 1 .	88
5.17	Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen L, escenario 1 .	89
5.18	Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen P, escenario 1 .	89
5.19	Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen S, escenario 1 .	89
A.1	Aptitud y tiempo de ejecución promedio para Tp 50, 100 y 150.	105
A.2	Distancia Euclidiana: Aptitud y tiempo de ejecución promedio para Tp 50, 100 y 150.	105
A.3	Aptitud y tiempo de ejecución promedio para Pc 0.6, 0.8 y 1.	106
A.4	Aptitud y tiempo de ejecución promedio para Pc 0.01, 0.03 y 0.05.	106
A.5	Aptitud y tiempo de ejecución promedio para PS 0, 0.1 y 0.2.	106
A.6	Aptitud y tiempo de ejecución promedio para NG 500, 1000 y 1500.	107
B.1	PSNR Promedio patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1	108
B.2	PSNR Promedio patrón AG de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1	109
B.3	PSNR Promedio patrón AR de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1	109
B.4	PSNR Promedio patrón AT de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1	109
B.5	PSNR menor patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1	110
B.6	PSNR menor patrón AG de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1	110

B.7 PSNR menor patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1	110
B.8 PSNR menor patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1	111
B.9 PSNR mayor patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1	111
B.10 PSNR mayor patrón AG de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1	111
B.11 PSNR mayor patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1	112
B.12 PSNR mayor patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1	112
B.13 PSNR promedio imagen B de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	112
B.14 PSNR promedio imagen BR de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	113
B.15 PSNR promedio imagen C de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	113
B.16 PSNR promedio imagen F de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	114
B.17 PSNR promedio imagen G de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	114
B.18 PSNR promedio imagen L de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	114
B.19 PSNR promedio imagen P de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	115
B.20 PSNR promedio imagen S de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	115
B.21 PSNR menor y mayor imagen B de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	116
B.22 PSNR menor y mayor imagen BR de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	116
B.23 PSNR menor y mayor imagen C de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	116
B.24 PSNR menor y mayor imagen F de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	117

B.25 PSNR menor y mayor imagen G de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	117
B.26 PSNR menor y mayor imagen L de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	117
B.27 PSNR menor y mayor imagen P de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	118
B.28 PSNR menor y mayor imagen S de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	118
B.29 Desviación estandar PSNR de las 200 distribuciones imagen B de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	118
B.30 Desviación estandar PSNR de las 200 distribuciones imagen BR de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	119
B.31 Desviación estandar PSNR de las 200 distribuciones imagen C de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	119
B.32 Desviación estandar PSNR de las 200 distribuciones imagen F de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	119
B.33 Desviación estandar PSNR de las 200 distribuciones imagen G de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	120
B.34 Desviación estandar PSNR de las 200 distribuciones imagen L de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	120
B.35 Desviación estandar PSNR de las 200 distribuciones imagen P de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	121
B.36 Desviación estandar PSNR de las 200 distribuciones imagen S de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1	121
B.37 Mejores VFCR alcanzados en evaluaciones del AG basados en otros méto- dos por SE, AG, AR y AT, aplicando el 20 % de Loss Rate, escenario 1.	121
B.38 Mejores PSNR alcanzados en evaluación de patrones mediante simulaciones por patrón SE, AG, AR y AT, imagen Baboon, aplicando el 20 % de Loss Rate, escenario 1.	122
B.39 Mejores VFCR alcanzados en evaluaciones del AG basados en otros méto- dos por SE, AG, AR y AT, aplicando el 20 % de Loss Rate, escenario 5.	122
B.40 Mejores PSNR alcanzados en evaluación de patrones mediante simulaciones por patrón SE, AG, AR y AT, imagen Baboon, aplicando el 20 % de Loss Rate, escenario 5.	122

Resumen

Los métodos de entrelazamiento, en el proceso de la transmisión de datos con contenido multimedia, permiten mantener gradualmente la robustez de una imagen post-transmisión, pero los métodos existentes en su mayoría no consideran la diversidad de combinaciones posibles para entrelazar los píxeles o bloques. El presente trabajo utiliza la técnica estocástica, de búsqueda y optimización, conocido como Algoritmos Genéticos, para realizar la búsqueda de un patrón óptimo de paquetización, considerando la combinatoria sujeta al problema de optimización de paquetización. Mediante una serie de experimentos se comparó nuestro Algoritmo Genético con los propuestos por Rombaut et al. en [41], Duran-Faundez y Lecuire en [17] con sus mejores parámetros y la configuración sin entrelazar. El estudio se realizó bajo la evaluación de los resultados mediante la función de costo objetivo para evaluar la paquetización, propuesta por Rombaut et al. en [41] y el indicador de calidad de la imagen recibida PSNR (Peak Signal-to-Noise Ratio), al someter los mejores patrones de paquetización alcanzados a simulación exhaustivas a través de la herramienta Sim-LIT 2.0. Los resultados experimentales mostraron que el Algoritmo Genético resultó ser competitivo con los métodos de la literatura anteriormente señalados.

Abstract

Interleaving methods, in the process of data transmission with multimedia content, allow to gradually maintain the robustness of a post-transmission image, but the existing methods mostly do not consider the diversity of possible combinations to interleave the pixels or blocks. The present work uses the stochastic technique of search and optimization, known as Genetic Algorithms, to perform the search for an optimal pattern of packetization, considering the combinatorial subject to the problem of optimization of packetization. Through a series of experiments we compared our Genetic Algorithm with those proposed by Rombaut et al. in [41], Duran-Faundez and Lecuire in [17] with its best parameters and configuration without interlacing. The study was performed under the evaluation of the results using the objective cost function to evaluate the packetization proposed by Rombaut et al. in [41] and the quality indicator of the image received PSNR (Peak Signal-to-Noise Ratio), by subjecting the best packetization patterns achieved to simulation exhaustive through the Sim-LIT 2.0 tool. The experimental results showed that the Genetic Algorithm turned out to be competitive with the previously mentioned methods of the literature.

Capítulo 1

Introducción

Es bien sabido que la transmisión de datos multimedia puede consumir parte importante del ancho de banda disponible en una red de comunicación. Dicho consumo se ve incrementado por la necesidad de transmitir información o paquetes de datos adicionales, desde y hacia el nodo origen, para asegurar niveles mínimos de calidad perceptual del lado del receptor, dado el problema de la potencial pérdida de paquetes.

La pérdida de paquetes según [32], puede ocurrir por distintos factores incluyendo errores en el canal, colisiones y congestión. Cualquiera sea el nivel de pérdida, será causal de imágenes o audio mayor o menormente degradados, generando un potencial problema. En una red de comunicaciones, este tipo de problema se enfrenta, tradicionalmente, mediante la inclusión de códigos correctores de error o, principalmente, mediante la adopción de protocolos basados en ARQ (del inglés Automatic Repeat-reQuest) [43]. Dichos métodos son llamados en [41], métodos de *ocultación de errores activos*. Sin embargo, para ciertas aplicaciones en las cuales el ancho de banda, los requerimientos de tiempo de respuesta y/o la disponibilidad de recursos es muy limitada, la retransmisión de paquetes y la adición de información adicional pueden no ser adecuadas pues inherentemente generan retardos y uso adicional de recursos. Los problemas se incrementan en sistemas compuestos por grandes cantidades de nodos. Ejemplos donde los métodos tradicionales son considerados poco adecuados según [32, 36, 40] pueden ser la transmisión de video en tiempo real (debido a la necesidad de asegurar tiempos de respuesta rápidos), las redes de sensores inalámbricos ¹ (debido al incremento en el uso de recursos de los nodos), o en la radiodifusión (debido a la inexistencia de canales de retorno). En esos casos, el uso

¹Las redes de sensores inalámbricos, según [2, 3, 7, 17] son redes de gran escala formada por pequeños dispositivos interconectados sin cables con capacidad de detectar los fenómenos ambientales a través de un conjunto de transductores y un transceptor de radio con fuente de alimentación autónoma, las cuales están limitadas en términos de batería, memoria, capacidad de procesamiento, y tasa de datos obtenibles, por lo cual persiguen la eficiencia energética y la transmisión robusta.

de métodos de ocultamiento error pasivo es más apropiado. En [6, 40, 41] indican que los métodos de ocultación de error pasivo permiten reparar una imagen deteriorada (por ejemplo, por la pérdida de datos producto de pérdidas de paquetes), utilizando, típicamente, información obtenida de píxeles (o bloques de píxeles) vecinos recibidos correctamente, para estimar las intensidades de los píxeles perdidos. Esto requiere de antemano contar con una configuración de paquetización que permita distribuir los píxeles o bloques vecinos en los diferentes paquetes asegurando ciertos criterios. Una de las técnicas que aborda este enfoque es la ofrecida por los *métodos de entrelazamiento*.

La Figura 1.1 muestra el efecto de la pérdida de paquetes de una imagen transmitida de forma secuencial² y su reconstrucción utilizando método de ocultamiento de error pasivo.




Figura 1.1: Transmisión secuencial de imágenes [gentileza de Eric Orellana-Romero].

Los métodos de entrelazamiento de acuerdo a [14, 31], son algoritmos que codifican una imagen reuniendo (potencialmente) bloques de píxeles (bloques) adyacentes en diferentes paquetes de datos antes o durante la transmisión, con el fin de reducir el impacto de los errores de red. Se espera, entre otras cosas, contar con paquetes en los que no se encuentre almacenado ningún bloque vecino, de manera que en caso que se pierda un paquete, al reordenar los bloques recepcionados, los faltantes estén separados entre sí y el bloque individual perdido pueda ser recuperado utilizando un método de ocultación error pasivo. La calidad de la imagen reconstruida dependerá tanto del comportamiento de la red durante la transmisión como de la configuración de paquetización. La Figura 1.2 ilustra la mejora perceptual obtenida en la imagen resultante, aplicando una técnica de entrelazamiento de píxeles, para el mismo escenario (i.e., imagen, patrón de pérdidas de paquetes, etc.) de la Figura 1.1.

Los métodos de entrelazamiento son métodos simples muy efectivos para reducir el impacto de las pérdidas en la red. Funcionan bajo un principio que dice que, si se pierden paquetes, se mejora sustancialmente la probabilidad de recuperación de suficiente

²Se entiende por transmisión secuencial a una transmisión de bloques de píxeles organizada línea por línea.

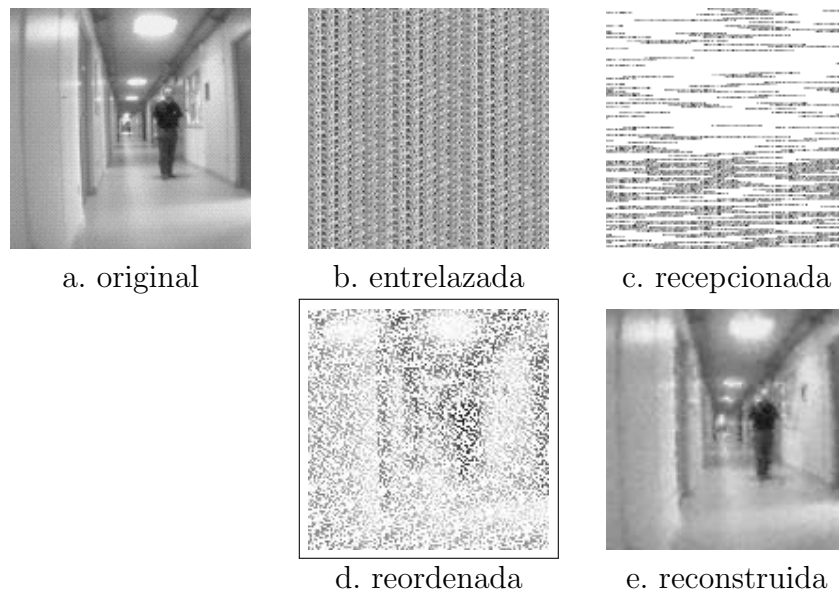


Figura 1.2: Transmisión de imágenes utilizando entrelazamiento [gentileza de Eric Orellana-Romero].

información para obtener una aproximación de las intensidades originales perdidas, lo cual se puede aplicar a redes que prioricen economías en el uso de recursos (Ej: redes de sensores inalámbricos) u otras mencionadas. En dichos escenarios, técnicas que agregan datos redundantes en los paquetes como Forward Error Correction (FEC) o que reenvían automáticamente los paquetes perdidos (ARQ) no son adecuadas de acuerdo a [2, 3, 7, 32, 36, 40], por requerir energía, tiempo y ancho de banda adicional. Ahora bien, la mayor parte de los métodos de entrelazamiento están basados en funciones matemáticas o estrategias procedurales sencillas que codifican la imagen basándose en algún criterio simple, típicamente, intentar asegurar una distancia entre los píxeles vecinos en la cadena de paquetización. Sin embargo, estos modos no consideran el problema de la combinatoria sujeta a la cantidad de bloques a transportar por paquete y otros parámetros, lo que motiva la hipótesis y objetivos propuestos para este trabajo.

1.1 Hipótesis y objetivos

Con la información rescatada preliminarmente al desarrollo de este proyecto y considerando la hipótesis del proyecto Fondecyt número 11121657 “Optimal packetization of still images in wireless vision sensor networks”, que tiene directa relación con el presente trabajo, las hipótesis son:

1. Es posible utilizando técnicas de computación evolutiva, como algoritmos genéti-

cos, establecer una configuración óptima de paquetización tal que sea mejor o igual, en términos de los resultados arrojados por los métodos de entrelazamiento considerados en esta investigación con sus mejores parámetros encontrados a través de simulaciones exhaustivas al ser evaluados por la función objetivo.

2. *La aplicación de la configuración óptima encontrada a través del algoritmo genético, en simulaciones trabajando con imágenes y tasas de pérdida distintas, revalidará la función objetivo encontrada en el desarrollo del Proyecto Fondecyt número 11121657 “Optimal packetization of still images in wireless vision sensor networks”.*

En concordancia con lo expuesto, el objetivo general de este trabajo de investigación es: *Mediante la aplicación de algoritmos genéticos, generar configuraciones de paquetización de imágenes que, en términos de la función objetivo seleccionada, superen o igualen a los resultados obtenidos por los métodos de entrelazamiento encontrados en la literatura, validándose además mediante simulación*³.

Los objetivos específicos de este trabajo son:

1. *Estudiar algoritmos genéticos aplicados en la optimización.*
2. *Determinar los algoritmos genéticos de optimización posibles de utilizar para resolver el problema de generar una configuración óptima de entrelazamiento de imagen.*
3. *Diseñar un algoritmo genético que se ajuste al problema, tomando como base los trabajos reportados en la literatura.*
 - *Determinar representación de los individuos*
 - *Determinar valores de Aptitud*⁴ *para los individuos de la población.*
 - *Determinar objetivo para maximizar o minimizar a través del algoritmo genético.*
4. *Implementar y evaluar el algoritmo genético.*
5. *Evaluar resultados del algoritmo.*
6. *Analizar y comparar los resultados obtenidos.*

³Simulación exhaustiva a través de la herramienta de simulación que apoya el estudio de las técnicas de entrelazamiento Sim-LIT

⁴Valor real que indica la calidad de un individuo como una solución para el problema

1.2 Alcances de la tesis

Este trabajo se focaliza en el problema de la comunicación de imágenes estáticas (fotografía) en redes de sensores inalámbricos. Estas redes se caracterizan por transmitir imágenes de baja resolución. Más aún, por simplicidad (y como es tradicional en el trabajo con este tipo de sistemas), se considerará exclusivamente el trabajo con imágenes en escala de grises.

La investigación se centrará en el estudio de un algoritmo genético secuencial por ser capaz de:

- Crear soluciones para problemas de optimización, presentes en el mundo real [9, 38],
- Aplicarse exitosamente a numerosos problemas en el área de negocios, ingeniería y ciencias [12, 21],
- Incrementar la eficiencia de procesamiento en tiempo de ejecución y
- Responder ante la necesidad de cómputo requerida por problema de extrema complejidad [9].

Los alcances establecidos persiguen dar una solución eficiente al problema de paquetización a través de algoritmos genéticos secuenciales, dejando fuera de este trabajo la generación de un algoritmo genético paralelo y otras técnicas de aceleración de búsqueda en términos de tiempo de ejecución.

1.3 Organización del documento

El resto de este documento se organiza de la siguiente manera:

En el Capítulo 2 se describen los métodos de entrelazamiento a considerar en la investigación.

En el Capítulo 3 se realiza una introducción las temáticas de optimización con metaheurísticas, describiendo particularmente a los algoritmos genéticos.

En el Capítulo 4 se presenta el algoritmo genético propuesto, para la obtención de una configuración de paquetizado de bloques para comunicación robusta de imágenes.

En el Capítulo 5 se presentan los parámetros de simulación y resultados obtenidos.

Finalmente, el Capítulo 6 concluye y comenta algunos trabajos futuros.

Capítulo 2

Métodos de Entrelazamiento

Los métodos de entrelazamiento son técnicas de codificación de imágenes utilizadas para (entre otras aplicaciones) reducir el impacto de la pérdida de paquetes en la red a través del uso de funciones matemáticas o estrategias procedurales para generar configuraciones de paquetización que (típicamente) reúnan bloques de píxeles adyacentes en diferentes paquetes antes de o durante la transmisión. La idea de usar los métodos de entrelazamiento según [14, 31] es que los bloques contiguos de la imagen original no viajen en el mismo paquete con el objetivo de aumentar la probabilidad de reconstruir una imagen post-transmisión a través de un método de ocultación error pasivo, como lo descrito en el Capítulo 1.

Para comprender lo antes señalado, la Figura 2.1 muestra un esquema de entrelazamiento utilizando una configuración de paquetización básica de dimensiones $M \times N$, donde $M \times N$ correspondiente a la cantidad de bloques de píxeles a transmitir, paquetizando lo bloques en diferentes paquetes.




Figura 2.1: Esquema de entrelazamiento utilizando una configuración de paquetización básica [gentileza de Eric Orellana-Romero].

A continuación, se presentan algunos de los métodos existentes en la literatura:

2.1 Método de mezclado de *Turner y Peterson*

En [45], Turner y Peterson propusieron un método de entrelazado a nivel de píxeles en el dominio espacial, donde los píxeles dentro de un paquete se agrupan de acuerdo a un desplazamiento denotado por **ByteOffset**, que especifica la distancia entre dos píxeles en el mismo paquete. Esto asegura que no hay dos píxeles, dentro del mismo paquete que sean adyacentes en el espacio de la imagen. Para atender a las pérdidas de paquetes en ráfagas, **PacketOffset** especifica el número de bytes entre los píxeles de partida de paquetes adyacentes. Este parámetro controla la distancia temporal de los paquetes adyacentes en el espacio imagen. Este método puede ser aplicado en diferentes plataformas con anchos de banda variados.

La Figura 2.2, muestra un paquete construido utilizando ByteOffset como $(\text{rowLength} + 2)$, rowLength representa el ancho de la imagen en píxeles, y PacketOffset como el PacketLength, que es el tamaño del paquete en bytes.




Figura 2.2: Esquema de una secuencia de transmisión usando método Turner y Peterson, obtenido de [45].

2.2 Entrelazado Dual Stream JPEG-Adaptation Layer

Dual Stream JPEG-Adaptation Layer, propuesto en [35], es un método de compresión de flujos de video basado en el algoritmo JPEG, que incorpora una técnica de entrelazado con el fin de minimizar los efectos de las pérdidas en ráfagas¹ de bloques adyacentes.

¹Se entiende por pérdidas en ráfaga a un proceso en el que, por diversos motivos, se pierden varios paquetes de datos secuenciales durante un cierto período. En la comunicación secuencial de imágenes,

La técnica define un parámetro escalar, denominado STEP, que determina la distancia del siguiente bloque a ser empaquetado de una imagen que contiene $NCOL \times NROW$ bloques, determinando la secuencia de transmisión. Específicamente, a partir del bloque situado en $(1, 1)$, la secuencia de transmisión se puede definir de la siguiente manera : Si (x_i, y_i) denota el bloque más reciente incluido en la secuencia de transmisión, entonces el bloque siguiente (denotado por (x_{i+1}, y_{i+1})) de la secuencia está dada por (2.2):

$$x_{i+1} = (x_i + STEP) \text{ mód } NCOL \quad (2.1)$$

$$y_{i+1} = \left(y_i + \left\lfloor \frac{x_i + STEP}{NCOL} \right\rfloor \right) \quad (2.2)$$

Si el resultado de y_{i+1} excede $NROW$, la siguiente posición a considerar es la primera (línea por línea) que no haya sido aún considerada.

2.3 Entrelazado horizontal de *DeBrunner et al.*

El método de entrelazado horizontal de píxel, de acuerdo a lo expuesto en [14], ensambla píxeles de filas pares e impares en paquetes diferentes. Mientras el paquete con los píxeles fila par y el paquete con píxeles adyacentes de filas impares no son al mismo tiempo perdido, los perdidos incluso píxeles fila puede ser recuperado por su fila impar adyacente píxeles y viceversa.

o	o	o	o	o	o	o	o
x	x	x	x	x	x	x	x
o	o	o	o	o	o	o	o
x	x	x	x	x	x	x	x
o	o	o	o	o	o	o	o
x	x	x	x	x	x	x	x
o	o	o	o	o	o	o	o
x	x	x	x	x	x	x	x

Figura 2.3: Esquema de entrelazado horizontal de píxeles

Además de este método, en [14] se da a conocer: el *Entrelazado Vertical*, el cual sigue la misma estructura del horizontal pero en vez de considerar las filas, considera las columnas, esto se traduce como varias líneas perdidas, lo que podría visualizarse como “cortes” importantes en una imagen.

el *Entrelazado Horizontal-Vertical* que es una mezcla de ambos y el *Entrelazado de píxel dinámico* que considera el borde o textura predominante (horizontal o vertical) para determinar de que forma se codificará el píxel.

2.4 Método de entrelazamiento Automorfismos Torales

Automorfismos Torales, abreviado como AT, son sistemas fuertemente caóticos que pueden ser adaptados como una transformada de permutación en dos dimensiones, de acuerdo a [47]. En [17] se realizó una adaptación para un sensor-camara, el cual se aplicó como una técnica de entrelazado de bloques aplicando los conocidos Cat Map de Arnold, detallado en [5]. Dentro de las cualidades que destacan son el caracter caótico de los resultados, asegurando un entrelazado semi-aleatorio, además de no incurrir en gasto energéticos excesivos por la simplicidad en su ejecución. Con este método se puede calcular el cambio de posición del píxel mediante (2.3).

$$\begin{pmatrix} x' \\ y' \end{pmatrix} = \begin{pmatrix} 1 & 1 \\ k & k+1 \end{pmatrix}^n \begin{pmatrix} x \\ y \end{pmatrix} \pmod{N} \quad (2.3)$$

donde (x', y') denotan la nueva coordenada para un elemento en una coordenada (x, y) , considerando que la imagen contiene $N \times N$ elementos². k y n son parámetros seleccionables por el usuario.

2.5 Método de Rombaut

En [41], Rombaut et al. presentan un método de paquetización robusto para la transmisión de imágenes, que se desarrolló a partir de una función de costo objetivo definida para evaluar la paquetización. Este método está basado en el concepto de máscaras de paquetización y utiliza optimización estocástica basada en un algoritmo de recocido simulado para calcular la máscara de paquetización óptima. Este método es original en este sentido; a diferencia de los anteriores, que se basan en procedimientos o ecuaciones deterministas, el método propuesto por Rombaut considera una solución emergente basada en una metaheurística (y, por tanto, base comparativa para el trabajo a realizar en esta tesis).

En la Figura 2.4, se muestra un ejemplo de máscara de paquetización obtenida de [41], en donde cada número representa el paquete en el cual se transportará el elemento

²En la comunidad de procesamiento de imágenes, es normal trabajar con imágenes cuadradas. El paso de una técnica a una imagen no cuadrada es trivial.

(bloque de píxeles) en la coordenada respectiva.

8	13	14	15	16	5	6	7	8	13
12	1	2	3	4	9	10	11	12	1
16	5	6	7	8	13	14	15	16	5
4	9	10	11	12	1	2	3	4	9
8	13	14	15	16	5	6	7	8	13
12	1	2	3	4	9	10	11	12	1
16	5	6	7	8	13	14	15	16	5
4	9	10	11	12	1	2	3	4	9
8	13	14	15	16	5	6	7	8	13
12	1	2	3	4	9	10	11	12	1

Figura 2.4: Ejemplo de máscara de paquetización

2.6 Conclusión del capítulo

Como se puede apreciar, existen distintos métodos de entrelazamiento que aplicados en la modificación del proceso de paquetización. Estos proveen una solución para mejorar la robustez en el sistema de transmisión de imágenes, a través del uso de funciones matemáticas o estrategias para codificar la imagen. Las estrategias utilizadas por los métodos principalmente son del tipo deterministas (ver Tabla 2.1) a excepción del método Rombaut et al. propuesto en [41] que utiliza un enfoque metaheurístico. Este último ha sido el único método encontrado en la literatura que utiliza este enfoque y que considera el factor de la combinatoria ligada al problema, lo cual ha despertado el interés tanto por el

Tabla 2.1: Resumen de Métodos de entrelazamiento presentados

MÉTODO	AUTOR	AÑO	TIPO DE ESTRATEGIA
Turner y Peterson	C. J. Turner and L. L. Peterson	1992	Determinista
Dual Stream JPEG-Adaptation Layer	E. J. Posnak, S. P. Gallindo, A. P. Stephens, and H. M. Vin	1994	Determinista
Horizontal de DeBrunner et al.	V. DeBrunner, L. DeBrunner y Longji Wang	1999	Determinista
Automorfismos Torales	Cristian Duran-Faundez y Vincent Lecuire	2008	Determinista semialeatorio
Rombaut	Joost Rombaut, Aleksandra Pizurica y Wilfried Philips	2008	Probabilístico

enfoque probabilístico como el factor de la combinatoria en la búsqueda de optimizar la paquetización, y será considerado para validar los resultados arrojados por la propuesta presentada en este trabajo.

Capítulo 3

Introducción a los Algoritmos Genéticos

3.1 Principios de optimización

La optimización de acuerdo a [25], es la ciencia encargada de determinar las (posibles) mejores soluciones a problemas a través de la búsqueda y comparación de soluciones factibles que responden a uno o más objetivos. Las soluciones responden a valores extremos que dependen directamente del o los objetivos que se desean alcanzar, es decir, mínimos o máximos. El proceso de la optimización, explicado a grandes rasgos por [22, 48], ajusta las entradas a las características de un dispositivo, proceso matemático o el experimento para encontrar el mínimo o máximo de salida como resultado. La entrada consiste en las variables, el proceso o función se conoce como función de costo, función objetivo, función de aptitud, o función de evaluación, y la salida es el costo.

3.1.1 Formalización de un problema de optimización

En términos formales, un problema de optimización según [33, 48], se describe como un par (X, f) , donde $X \neq \emptyset$ es un conjunto que representa al espacio de soluciones posibles del problema y f es un criterio de calidad conocido como función objetivo, que se define como:

$$f : X \longrightarrow \mathbb{R} \quad (3.1)$$

El problema es encontrar un $x' \in X$ que satisfaga la siguiente desigualdad en caso de minimización:

$$f(x') \leq f(x) \quad \forall x \in X \quad (3.2)$$

tal que un punto x' corresponde a una solución óptima global a la instancia para el caso dado, o, cuando no pueda surgir ninguna confusión, simplemente una solución óptima .

En función de lo expuesto, se definen los siguientes conceptos fundamentales:

- **Solución candidata:** este término hace referencia a todas y cada una de las soluciones posibles al problema.
- **Espacio de soluciones o de búsqueda:** se define como espacio de soluciones S al conjunto no vacío de todas las soluciones aceptables al problema.
- **Adyacentes o próximos:** Se dice que dos puntos p y p' , pertenecientes a un espacio de búsqueda de una función, son adyacentes si pertenecen al mismo vecindario.
- **Vecindad:** La vecindad corresponde al entorno acotado del espacio de búsqueda alrededor del punto que se está evaluando donde todos los puntos son adyacentes.
- **Máximo local:** un máximo local corresponde a $x' \in X$ de una función $f : X \rightarrow \Re$ es un elemento tal que, $f(x') \geq f(x)$ para cualquier otro elemento x que pertenezca al vecindario. Dicho de otra forma, si $X \subseteq R$ se puede decir: (3.3).

$$x' : \forall x' \exists \epsilon > 0 : f(x') \geq f(x) \forall x \in X, |x - x'| < \epsilon \quad (3.3)$$

- **Mínimo local:** Se define que el mínimo local $x' \in X$ de una función $f : X \rightarrow \Re$ es un elemento tal que, $f(x') \leq f(x)$ para todo elemento x que pertenezca al vecindario de x' . Dicho de otra forma, si $X \subseteq R$ se puede decir: (3.4).

$$x' : \exists \epsilon > 0 : f(x') \leq f(x) \forall x \in X, |x - x'| < \epsilon \quad (3.4)$$

- **Óptimo local:** Se define el óptimo local $x_l^* \in X$ de una función $f : X \rightarrow \Re$ como aquel elemento que es máximo o mínimo local de la función.
- **Máximo global:** Se define el máximo global $x' \in X$ de una función $f : X \rightarrow \Re$ como aquel elemento que para cualquier $x \in X$ se cumple que $f(x') \geq f(x)$.
- **Mínimo global:** Un mínimo global $x' \in X$ de una función $f : X \rightarrow \Re$ como aquel elemento que para cualquier $x \in X$ se cumple que $f(x') \leq f(x)$.
- **Óptimo global:** Se define el óptimo global $x^* \in X$ de una función $f : X \rightarrow \Re$ como aquel elemento que es máximo o mínimo global de la función.

La optimización puede ser distinguida por la naturaleza de sus variables, las cuales pueden ser discretas o continuas. Las variables discretas por su parte poseen un número finito de valores posibles, mientras que las variables continuas tienen un número infinito de valores posibles. Cuando nos enfrentamos a decidir en que orden se deben realizar una serie de tareas de una lista, la optimización de variables discretas, es la empleada. Sin embargo, si se busca encontrar el valor mínimo de $f(x)$ en una recta numérica, es más apropiado ver el problema como continuo.

3.1.2 Optimización combinatoria

La optimización de variables discretas, más conocida como optimización combinatoria, corresponde según [22, 33] a la rama de la matemática que busca determinar la mejor combinación de variables de un conjunto finito de posibles soluciones, sujetas a restricciones. Esta es una de las más jóvenes y más activas áreas de las matemáticas discretas, cuyo origen está en la combinatoria, investigación de operaciones y las ciencias de la computación teórica de acuerdo a [24].

La mayoría de los problemas de optimización combinatoria se pueden formular de forma natural en términos de gráficos y como programas lineales. En [24] se describe como una secuencia ordenada.

3.1.3 Clasificación de los algoritmos de optimización

En la literatura, es posible encontrar una infinidad de técnicas algorítmicas para resolver problemas de optimización, generalmente divididos en dos grupos, según el método de operación: algoritmos deterministas y algoritmos probabilísticos. Los algoritmos deterministas son a menudo usados si existe una clara relación entre las características de las posibles soluciones y su utilidad para un determinado problema. Este tipo de algoritmo no contiene instrucciones que utilice números aleatorios con el que se decida qué hacer o en la modificación de datos (siempre producirá los mismos resultados cuando se administra las mismas entradas) y garantiza encontrar una solución óptima al problema para todas las instancias de tamaño finito. Sin embargo, por lo general, si se trata de instancias grandes de problemas complejos, el espacio de búsqueda a menudo no puede ser dividido adecuadamente, necesitando tiempos exponenciales de computación, lo cual no puede ser abordado de forma realista (o al menos eficiente). Por otro lado, se encuentran las técnicas probabilísticas que de acuerdo a [16, 48] sacrifican la garantía de encontrar el óptimo global con el fin de encontrar buenas soluciones en un tiempo más razonable en comparación con las técnicas deterministas, incorporando componentes aleatorios.

El término heurística en la optimización global, consiste en funciones que ayudan a decidir cual solución del conjunto de posibles soluciones será examinada. Este enfoque según [48] puede ser utilizado tanto por los algoritmos deterministas como por los probabilísticos. Las metaheurísticas de acuerdo a [16, 48], son una combinación de técnicas heurísticas básicas en entornos de más alto nivel para la solución de una clase muy general de problemas, explorando un espacio de búsqueda de gran dimensión y complejidad entrínseca de forma eficiente y efectiva, planificando de manera estructurada la aplicación de varias operaciones .

En la literatura, las metaheurísticas son clasificadas bajo diferentes criterios. En [19] se encuentran divididas en dos categorías: *metaheurísticas de solución única*, donde se considera una solución y trayectoria de búsqueda a la vez, y *metaheurísticas de población*, donde multiples soluciones son obseadas simultáneamente. Dentro de las metaheurísticas de solución única encontramos al Recocido Simulado o (en inglés) *Simulated Annealing* (SA). Este corresponde a un método basado en una analogía de un proceso termodinámico consistente con el enfriamiento y proceso de temple en metales, propuesto como enfoque para resolver problemas de optimización en 1983 por Kirkpatrick et al. en [46], y en 1985 por Cerny en [10]. El proceso termodinámico, explicado superficialmente, consiste en fundir un material para luego enfriarlo progresivamente, logrando la recuperación de un estado solido de menor energía (material sea menos frágil), lo que es logrado si la temperatura se mantiene el tiempo suficiente en cada nivel para alcanzar un equilibrio. En [19] se explica la asociación del proceso termodinámico con SA, como: “Una solución corresponde a un estado del sistema físico y el costo de la solución a la energía del sistema. En cada iteración la solución actual es modificada por selección aleatoria de un movimiento de una clase particular de transformación, que define un entorno de soluciones. Si la nueva solución proporciona una mejora, se acepta de forma automática y se convierte en la nueva solución. De lo contrario, la nueva solución es aceptada de acuerdo con el criterio Metropolis, donde la probabilidad de aceptación está relacionada con la magnitud del aumento del costo y la temperatura. Básicamente, un movimiento es más probable que sea aceptado si la temperatura es alta y el aumento del costo es bajo. El parámetro de temperatura es rebajado progresivamente, de acuerdo con algún esquema de enfriamiento predefinido, y un cierto número de iteraciones por cada nivel de temperatura. Cuando la temperatura es suficientemente baja, sólo mejores movimientos son aceptados y el método se detiene en un óptimo local”.

En las Metaheurísticas de población se trabaja con múltiples soluciones, que se combinan para crear nuevas soluciones. Dentro de estas, se encuentran los Algoritmos Evolutivos (AE) basados en los procesos de selección natural, siendo los Algoritmos Genéticos los

más conocidos. Estos algoritmos fueron inspirados en la teoría de la evolución de Charles Darwin, quien postula que, a lo largo de las generaciones, las poblaciones evolucionan en la naturaleza acorde a los principios de selección natural y supervivencia, de acuerdo a lo expuesto en [12].

Con la llegada de los computadores con mayores capacidades de cómputo y plataformas paralelas, las metaheurísticas se han aplicado con éxito a los problemas en tiempo-real, con los requisitos de tiempo de respuesta requeridos. Ahora, el desafío consiste en adaptar una metaheurística a un problema en particular o clase de problema, lo que requiere, por lo general, mucho menos trabajo que el desarrollo de una heurística especializada desde cero. Por otra parte según [19], una buena implementación metaheurística es probable que proporcione soluciones casi óptimas, en tiempos de cálculo razonables .

3.2 Algoritmos Genéticos

En 1959, Charles Darwing promulgó por primera vez los principio de la selección natural y la supervivencia de los más aptos como fuerza impulsora detrás de la evolución biológica. A partir de ellos, los Algoritmos Evolutivos (AE) surgen e introducen un cambio de semántica, por estar orientados a objetivos, con el fin de encontrar soluciones para problemas complejos.

Los Algoritmos Genético (AG), introducidos por Holland en 1975, son un subconjunto de los AE (ver Figura 3.1, extraída de [37]), que comparten el ciclo básico de AE (ver Figura 3.2) compuesto por una población inicial de soluciones candidatas que entran en un ciclo, el cual considera cuatro fases. En la primera se evalúa la población, en la segunda se asigna un valor de aptitud a los individuos, en la tercera se seleccionan los individuos más aptos lo que finalmente se reproducen en la fase cuatro. Los elementos del ciclo serán profundizados en la Sección 3.2.4.

3.2.1 Definición

En los AG el espacio de búsqueda de un problema es representado según [39], como una colección de *individuos* (Población de individuos) $P(t)$, la cual evoluciona a través de acciones aleatorias semejantes a las que actúa en la evolución biológica (cruzamiento y mutación), así como también a una selección de acuerdo con algún criterio, que permite decidir cuales son los individuos más o menos aptos. Esto tiene como propósito de encontrar al individuo del espacio de búsqueda con el mejor material genético de acuerdo a [27]. En otras palabras, los AG consisten en generar aleatoriamente una población inicial de individuos, asociar un valor de *aptitud* a cada individuo, representando su calidad con

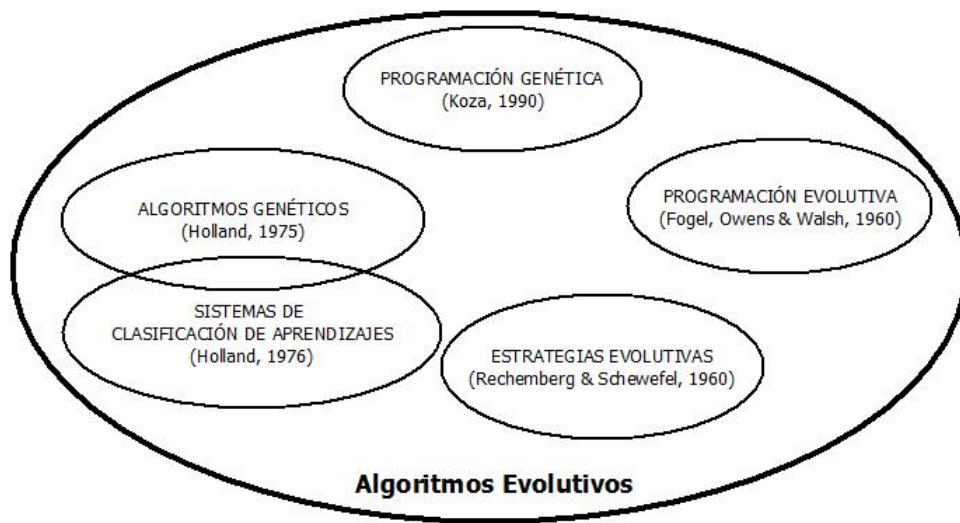


Figura 3.1: Familia de los Algoritmos Evolutivos [48].

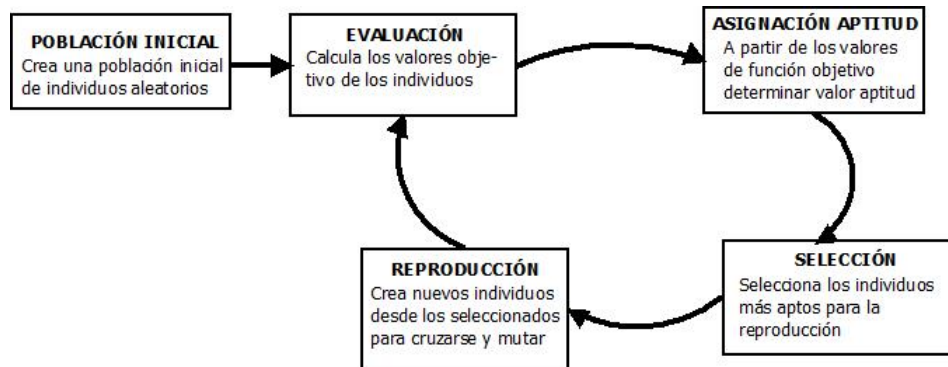


Figura 3.2: Ciclo básico de los Algoritmos Evolutivos [48].

respecto a los demás, y posteriormente aplicar operadores estocásticos como la selección, cruzamiento y mutación sobre la población, con el objetivo de generar una completa generación de nuevos individuos. El proceso se repite en sucesivas iteraciones (generaciones) y el algoritmo termina si se cumple un criterio de detención, el cual, usualmente, consiste en alcanzar un número de iteraciones preestablecido y/o encontrar un individuo con una aptitud equivalente al óptimo, o una aproximación a ésta, si es conocida de antemano.

Bajo la explicación antes expuesta subyace un proceso probabilístico que puede llegar a ser complejo, pero que puede reducirse al Algoritmo 1, el que representa la versión más sencilla utilizada por los AG de acuerdo a [18].

Algoritmo 1 Pseudocódigo AG.

```
1:  $t = 0$ 
2: Inicializar  $P(t)$ 
3: Evaluar  $P(t)$ 
4: mientras no sea condición de término hacer
5:    $t = t + 1$ 
6:   Seleccionar  $P(t)$  a partir de  $P(t - 1)$ 
7:   Aplicar Cruzamiento y Mutación sobre  $P(t)$  formando  $P'(t)$ 
8:   Evaluar  $P'(t)$ 
9:   Reemplazar  $P(t)$  desde  $P'(t)$  y  $P(t - 1)$ 
10: fin mientras
```

3.2.2 Características

Los AG según [16], son utilizado para resolver problemas de búsqueda y de optimización, típicamente en problemas considerados NP (Non-Deterministic Polynomial-time), es decir, problemas que no pueden ser resueltos eficientemente con técnicas tradicionales. De este tipo de problemas, de acuerdo [44], se conoce bastante poco, y su solución se restringe, típicamente, al uso de metaheurísticas. También, los AG son aplicados en problemas en los que es necesario manipular muchos parámetros simultáneamente según [39].

En [29] se mencionan algunas de las características que presentan los AG, en comparación con otras técnicas de solución de problemas:

Ventajas

1. No se requieren conocimientos específicos sobre el problema que intentan resolver.
2. Operan en forma simultánea con varias soluciones, en vez de trabajar secuencialmente como las técnicas tradicionales.
3. Cuando se usan para problemas de optimización, resultan menos afectados por los mínimos locales que cuando se emplean técnicas más tradicionales.
4. Resultan fáciles de ejecutar en arquitecturas modernas con paralelismo masivo [42].
5. Usan operadores probabilísticos en vez de los típicos operadores determinísticos de otras técnicas.

Desventajas

1. Pueden tardar mucho en alcanzar la convergencia, o no llegar a converger en absoluto, dependiendo en cierta medida de los parámetros que se utilicen, el tamaño de

la población, el número de generaciones, y otros factores.

2. Pueden llegar a una convergencia prematura debido a un conjunto de problemas de diversa índole, como la mala elección de los operadores genéticos, o los porcentajes probables de cruzamiento y/o mutación, entre otros.

Consideraciones del tipo de problema

Además de lo mencionado, es recomendable que el problema a tratar presente las siguientes características:

1. Su espacio de búsqueda (es decir sus posibles soluciones) debe estar definido dentro de un cierto rango acotado.
2. Debe ser posible definir una función de aptitud que entregue una indicación sobre qué tan buena o mala es una cierta solución.
3. Las soluciones deben codificarse de una manera que resulte fácil de implementar en un computador.

3.2.3 Vocabulario general

Dado que en los AG se aplican operaciones extraídas de la naturaleza, la nomenclatura utilizada en este campo es estrechamente en relación con los términos que se encuentran en la biología. La Tabla 3.1 resume estos términos de acuerdo a [4, 44].

3.2.4 Aspectos básicos de un AG

En esta sección se presentarán los aspectos básicos del AG, explicados de forma general, que deben ser considerados al momento de implementarlos.

Codificación

Codificación o Esquema de codificación corresponde al proceso que transforma los elementos que representan el problema real en los parámetros del espacio (genes) que componen al cromosoma. En los inicios de los AG, el alfabeto elegido en la codificación fue el binario, representando a los cromosomas como una secuencia de bits (ver Figura 3.3). En la actualidad es posible encontrar distintos esquemas de codificación, como lo son: Cadena de letras, reales (Números enteros), matrices, permutaciones por mencionar algunas. En la elección de la codificación hay que tener presente tanto el problema como las restricciones del mismo.

Tabla 3.1: Nomenclatura Algoritmos Genéticos.

Término	Descripción
Genotipo	El código, ideado para representar los parámetros del problema en la forma de una cadena.
Cromosoma	Una cadena codificada de parámetros (números punto flotante, binarios, etc ..).
Individuo	Uno o más cromosomas con un valor de <i>aptitud</i> asociado.
Gen	La versión codificada de un parámetro del problema a resolver.
Alelo	Valor que un gen puede suponer (binario, entero, estructuras de datos reales, o incluso complejos).
Lugar	La posición que el gen ocupa en el cromosoma.
Fenotipo	Versión Problema del genotipo (versión algoritmo), adecuado para ser evaluado.
Aptitud	Valor real que indica la calidad de un individuo como una solución para el problema.
Medio ambiente	El problema. Esto se representa como una función que indica la idoneidad de fenotipos.
Población	Un conjunto de individuos con sus estadísticas asociadas (promedio de <i>aptitud</i> , distancia Hamming, ...).
Selección	Políticas para la selección de un individuo de la población (la selección de los más aptos, ...).
Cruzamiento	Operación que combina los genotipos de dos padres seleccionados para producir dos nuevos hijos.
Mutación	Operación que cambia de forma espontánea uno o más alelos del genotipo.



Figura 3.3: Representación binaria de un cromosoma, obtenido de [39].

Población inicial

En cada generación los AG manipulan un conjunto de soluciones denominada población, la cual reviste gran importancia ya que, considerando que el cromosoma con mejor rendimiento sobrevive en cada generación, la construcción de la población inicial impacta en la calidad de los cromosomas y en la convergencia del AG.

La población inicial de soluciones candidatas (individuos) según [44] puede ser generada a partir de alguna técnica previa de optimización local con el objetivo que el AG las mejore, pero, más a menudo, es de generación aleatoria desde el espacio de búsqueda. Este aspecto está sujeto a la previa definición del tamaño de la población (T_p), típicamente, entre 50 y 1000 de acuerdo a [30].

Evaluación de Aptitud

Después de codificar y generar la población inicial, las soluciones candidatas son valorizadas, a través de un valor de aptitud, que es determinado mediante la función objetivo, función que establece qué tan bien el individuo resuelve el problema.

Selección

Después de la evaluación de la Aptitud, se seleccionan los individuos adecuados para la próxima generación, es decir, este operador selecciona con mayor probabilidad a aquellas soluciones con el mejor valor de aptitud y, de este modo, se impone el mecanismo de la sobrevivencia del más apto sobre las soluciones candidatas. Los individuos seleccionados son utilizados para reproducirse.

Los operadores de selección más conocidos y utilizados en la práctica son:

1. **Selección por torneo:** La selección por torneo consiste en escoger al azar un número determinado de individuos (en general 2) y los hacer competir entre sí para decidir cuál es el que se convertirá en uno de los progenitores de la nueva generación. El método selecciona el individuo con mejor valor de aptitud [8].
2. **Selección por ruleta:** La selección por ruleta consiste en simular una ruleta donde cada individuo x tiene asignado una sección de tamaño $P(x)$ que representa la probabilidad que tiene ese elemento de ser escogido [20] (Ver Figura 3.4).




Figura 3.4: Representación de una selección por ruleta con las probabilidades de los cuatro elementos que componen la población.

3.2.5 Cruzamiento

Para explotar el potencial de la reserva genética se usa el cruzamiento con el objetivo de generar un nuevo cromosoma. El cruzamiento combina partes de dos o más soluciones

emparejadas para crear nuevas y posibles mejores soluciones. Cruzamiento es el operador que da a los AG su fuerza; permite diferentes soluciones para compartir información entre sí. El operador tiene una probabilidad de cruzamiento asociada (P_c), que determina si un par de individuos se cruza o no. Tipicamente, este valor esta en el rango de 0.5 a 1.0 según [42]. La Figura 3.5 muestra un ejemplo de cruzamiento clásico.




Figura 3.5: Representación de cruce en un punto [39].

Dentro de los operadores de cruzamiento existe una categoria utilizada para problemas donde es necesario mantener consistentes los elementos de una secuencia (permutaciones). Por ejemplo, en el problema del vendedor viajero, donde cada cromosoma representa a una combinación de determinadas ciudades.

Algunos operadores de cruzamiento utilizado para este tipo de problema según [27] son:

1. **Partially-mapped crossover (PMX):** Este operador fue propuesto por Goldberg y Lingle en 1985, el cual genera hijos ($H1$ y $H2$) a partir de los padres ($P1$ y $P2$), donde $H1$ hereda una fracción del $P2$ y el resto de los elementos es incorporado a $H1$ a través del mapeo de los elementos de la fracción a heredar de $P2$ en $P1$ para completar la secuencia (ver ejemplo de la Figura 3.6).




Figura 3.6: Representación de Partially-mapped crossover (PMX) obtenido de [27].

2. **Order crossover (OX1):** Este operador fue propuesto por Davis en 1985, y genera hijos ($H1$ y $H2$) a partir de los padres ($P1$ y $P2$) donde $H1$ hereda una fracción del $P2$ y el resto de los elementos es incorporado a $H1$ según el orden de los elementos en

$P1$ para completar la secuencia, comenzando por cubrir los espacios a continuación de la fracción heredada (ver ejemplo en Figura 3.7).




Figura 3.7: Ejemplo de cruzamiento OX1. En (a), la representación de los padres ($P1$ y $P2$). (b) muestra la realización de cortes en cada uno de los padres. (c) muestra los hijos que en una primera instancia poseen los elementos entre los cortes (ejemplo: $H1$ posee elementos entre los cortes de $P1$). Finalmente, (d) muestra la nueva posición de los elementos del padre (Ejemplo: $H1$ posee los elementos de $P2$ que aún no están contenidos en $H1$).

3. Position based crossover (POS): Este operador fue propuesto por Syswerda en 1991, el cual genera hijos ($H1$ y $H2$) a partir de los padres ($P1$ y $P2$) donde $H1$ hereda elementos en la misma posición que están en $P2$ y el resto de los elementos es incorporado a $H1$ según el orden de los elementos en $P1$ en $H1$, en las posiciones disponibles y, así, completar la secuencia (ver Figura 3.8).




Figura 3.8: Representación de Position based crossover (POS)[27].

3.2.6 Mutación

El cruzamiento opera con dos o más cromosomas emparejados, a diferencia de la mutación, la que, comúnmente, involucra uno o más cambios sobre un individuo en particular. Un operador de mutación se utiliza para generar nuevos cromosomas. La forma más común de aplicación de mutación es cambiar una pequeña parte o sustituirla por un nuevo valor. El operador tiene una probabilidad de mutación asociado (Pm), que determina si un individuo generado por el cruzamiento (hijo) muta o no. Típicamente, este valor está en el rango de 0.005 a 0.05 según [42]. De Jong en [13] sugiere que Pm sea inversa a la longitud del cromosoma. La Figura 3.9 muestra un ejemplo de mutación clásica.

El papel de la mutación en el AG es restaurar el material genético perdido o inexplorado en la población, con el fin de prevenir la convergencia prematura del AG a soluciones




Figura 3.9: Representación de mutación.

subóptimas. El operador de mutación selecciona al azar una posición en el cromosoma y realiza el cambio de alelo modificando así la información. La necesidad de cambio viene del hecho de que los miembros menos aptos de las generaciones sucesivas se descartan ocasionando que algunos aspectos de material genético puedan perderse para siempre. La realización de un intercambio aleatorio en los cromosomas proporciona que las nuevas piezas permitan alcanzar un espacio de búsqueda que la reproducción y el cruzamiento por sí solos no puede garantizar plenamente. A continuación se presentan algunos operadores de mutación encontrados en la literatura:

1. **Displacement mutation (DM)** : Este operador fue propuesto por Michalewicz en 1992 y consiste en remover una sección del cromosoma y desplazarla a una nueva ubicación (ver Figura 3.10), tanto la nueva posición que es insertada como la misma sección es determinada aleatoriamente.




Figura 3.10: Representación de Displacement mutation (DM), obtenido de [27].

2. **Insertion mutation (ISM)**: Este operador fue propuesto por Fogel 1988 y Michalewicz en 1992 y consiste en remover un elemento del cromosoma para posteriormente insertarlo en una nueva posición (ver Figura 3.11), este operador corresponde al caso DM con largo de sección uno.
3. **Inversion mutation (IVM)**: Este operador fue propuesto por Fogel en 1990-1993 y es similar a DM, con la diferencia que la sección removida es insertada inversamente (ver Figura 3.12).




Figura 3.11: Representación de Insertion mutation (ISM), obtenido de [27].




Figura 3.12: Representación de Inversion mutation (IVM), obtenido de [27].

3.2.7 Siguiente generación (Reemplazo)

Este aspecto está relacionado con la generación de la población para la próxima iteración. La nueva población puede estar conformada totalmente con individuos resultantes de las operaciones de cruce y mutación o con una fracción de sobrevivientes de la actual población (Porcentaje de sobrevivencia PS). Este porcentaje también es conocida como Generation Gap en [11] y en [22] señala que va de 0 a 1.

3.2.8 Criterio de detención

El criterio de detención consiste en definir bajo que condiciones dejará de iterar el AG. Usualmente, este criterio de detención consiste en alcanzar un número de iteraciones preestablecido que hacen alusión al número de generaciones (NG) y/o encontrar un individuo con un valor de aptitud equivalente al óptimo, o una aproximación a éste, si es conocido de antemano. Generalmente según [30], el AG itera desde 50 a 500 o más generaciones. Otro método es considerar la convergencia genética de la población, cuando se comienza a perder la diversidad en la población [13].

Capítulo 4

Propuesta

Ya descritos los principios en los que se basan los AG, el presente Capítulo detalla los componentes del algoritmo propuesto, el que busca dar solución al problema de la optimización de paquetización descrita. La elección de los operadores está basada, principalmente, con el buen desempeño en estudios previos reportados en la literatura, como los realizados por Larrañaga et al. en [27] y por Deep et al. en [26]. Los parámetros del AG, como el tamaño de la población (Tp), probabilidad de cruzamiento (Pc), probabilidad de mutación (Pm), número de generaciones (NG) y porcentaje de sobrevivientes (PS) para la siguiente generación, son evaluados con el objetivo de conocer su impacto en el resultado final y, de esta forma, definir sus diferentes valores para el AG a implementar.

El AG implementado se ajusta al modelo del algoritmo genético simple expuesto en el Capítulo 3. A continuación, en la Sección 4.1 se definen los operadores elegidos, y en la Sección 4.2 se presenta el esquema de pruebas para la selección de parámetros y sus resultados. Adicionalmente una vez concluido el proceso investigativo se determino la aplicación de pruebas complementarias para NG 5000 y Tp 1000, los resultados son presentados en la subsección 4.2.2. Para mayor comodidad del lector, en la tabla 4.1 se presenta las abreviaciones en conjunto, antes mencionadas.

Tabla 4.1: Abreviaciones parámetros del AG

Abreviación	Término
Tp	Tamaño población
Pc	Probabilidad de cruzamiento
Pm	Probabilidad de mutación
PS	Porcentaje de sobrevivencia
NG	Número de generaciones

4.1 Componentes del AG propuesto

4.1.1 Esquema de codificación

El esquema de codificación utilizado para representar un cromosoma es un flujo de números enteros diferentes que simbolizan los bloques de la imagen a paquetizar (vea Figura 4.2). En [27] éste tipo de esquema de codificación es considerado como una representación natural en problemas que requieren simbolizar una secuencia. Por lo tanto, un individuo I es un vector de $N \times M$ números enteros diferentes, donde N y M representan la cantidad de filas y columnas de la matriz de bloques a paquetizar, respectivamente.

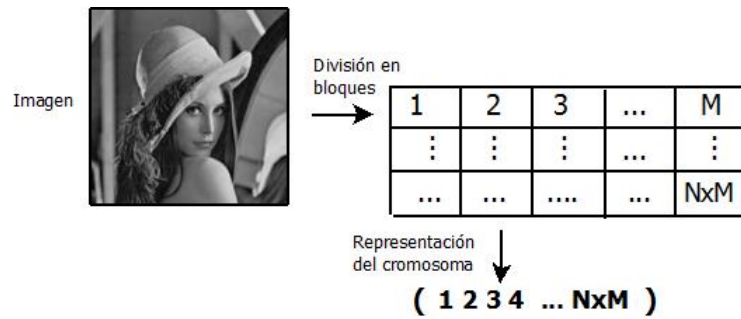


Figura 4.1: Ejemplo de esquema de codificación utilizado para representar el cromosoma.

4.1.2 Población inicial

La población inicial de t_p soluciones candidatas es generada aleatoriamente desde el espacio de búsqueda, a través de permutaciones aleatorias vector de tamaño $N \times M$.




Figura 4.2: Ejemplo de generación de individuos.

4.1.3 Función de evaluación

Los valores de aptitud de las soluciones candidatas son evaluadas a través de la función de evaluación. En este caso particular, se utilizó la función de costo que evalúa la máscara de interpolación utilizada para la paquetización (entrelazado), propuesta por Rombaut et al. en [41], revisada y publicada por la IEEE, la cual está basada en propiedades que mejoran la calidad de paquetización. La función de evaluación busca minimizar el costo, por lo cual se considera que entre más cerca el valor de aptitud esté de cero, mejor es la solución.

En la notación aplicada en [41] por Rombaut et al., se define una imagen como una señal f definida en el dominio discreto D . De acuerdo a lo anterior, se define como Máscara de Interpolación a la matriz $f = \{f_{1,1}, f_{1,2}, \dots, f_{N,M}\}$ donde $f_{s,t}$ contiene el número de secuencia del paquete de datos en el que se transportará el bloque de coordenadas (s, t) .

La función de evaluación esta dada por la combinación de tres términos (Ec. (4.1)):

$$Q(\mathfrak{B}) = \alpha Q_1(\mathfrak{B}) + \beta Q_2(\mathfrak{B}) + \Upsilon Q_3(\mathfrak{B}) \quad (4.1)$$

Donde \mathfrak{B} representa la maximización de la distancia intra-partición mínima global y $Q_i(\mathfrak{B}), i = 1, 2, 3$, corresponden, respectivamente, a las propiedades para una buena paquetización (penalización), definida por Rombaut et al. como:

1. Distancia entre paquetes lo suficientemente grande,
2. Máximo esparcimiento del conjunto de elementos necesarios para reconstruir un elemento j a través de los paquetes, y
3. Máximo esparcimiento de los elementos necesarios para reconstruir todos los elementos de un paquete sobre todos los otros paquetes.

Los factores α , β y Υ reflejan la importancia ligada a las diferentes propiedades deseadas, los cuales están basados en un modelo de los paquetes perdidos. El factor α representa el número estimado de paquetes perdidos basados en una probabilidad (Ec. (4.2)).

$$\alpha = \sum_{u=0}^P i \text{Prob}(N_{lost} = i) \quad (4.2)$$

donde P es el número total de paquetes, N_{lost} es el número de paquetes perdidos y $\text{Prob}(N_{lost} = i)$ es la probabilidad que el paquete i se pierda.

El factor β representa el número estimado de parejas ordenadas de paquetes perdidos (Ec. (4.3)).

$$\beta = \sum_{i=0}^P i(i-1) \text{Prob}(N_{lost} = i) \quad (4.3)$$

El factor Υ representa el número estimado de parejas ordenadas de paquetes perdidos considerando TODAS LAS PAREJAS DE PAQUETES (Ec. (4.4)).

$$\Upsilon = \sum_{i=0}^P i(i-1) \text{Prob}(N_{lost} = i) \quad (4.4)$$

Finalmente, Q_1 , Q_2 y Q_3 se calculan, respectivamente, como indican las Ecuaciones (4.5), (4.6) y (4.7):

$$Q_1(\mathfrak{B}) = \frac{1}{P} \sum_{i=0}^{P-1} \sum_{k=0}^{\#S_i^{\mathfrak{B}}-1} \sum_{\substack{l=0 \\ l \neq k}}^{\#S_i^{\mathfrak{B}}-1} C(d(s_{i,k}^{\mathfrak{B}}, s_{i,l}^{\mathfrak{B}})) \quad (4.5)$$

$$Q_2(\mathfrak{B}) = \frac{1}{P(P-1)} \sum_{i=0}^{P-1} \sum_{\substack{j=0 \\ i \neq j}}^{P-1} \sum_{k=0}^{\#S_i^{\mathfrak{B}}-1} \left[\sum_{l=0}^{\#S_j^{\mathfrak{B}}-1} C(d(s_{i,k}^{\mathfrak{B}}, s_{j,l}^{\mathfrak{B}})) \cdot 1 \left(\sum_{l=0}^{\#S_j^{\mathfrak{B}}-1} 1(d(s_{i,k}^{\mathfrak{B}}, s_{j,l}^{\mathfrak{B}}) \leq d_N) \geq 2 \right) \right] \quad (4.6)$$

$$Q_3(\mathfrak{B}) = \frac{1}{P(P-1)} \sum_{i=0}^{P-1} \sum_{\substack{j=0 \\ i \neq j}}^{P-1} \sum_{n=1}^N \left(C(d_n) \left| \sum_{k=0}^{\#S_i^{\mathfrak{B}}-1} \sum_{l=0}^{\#S_j^{\mathfrak{B}}-1} 1(d(s_{i,k}^{\mathfrak{B}}, s_{j,l}^{\mathfrak{B}}) = d_n) - N_{n,j} \right| \right) \quad (4.7)$$

donde:

$\#S_i$: es el número de elementos en el paquete S_i .

$s_{i,k}^{\mathfrak{B}}$: es la posición del elemento k en el paquete i de la partición \mathfrak{B} .

$d(s, t)$: es el módulo distancia entre s y t dado por:

$$d(s, t) = \sqrt{(x_s - x_t) \text{ mód } W + (y_s - y_t) \text{ mód } H} \quad (4.8)$$

$C(d)$: es el costo dado por la distancia. Este costo está íntimamente asociado a la técnica de ocultación de errores (la técnica que permite estimar las intensidades de un bloque perdido en función de los bloques correctamente recibidos). En este trabajo se adoptó el promedio de los 8 vecinos directamente conectados (y, por supuesto,

correctamente recibidos), por lo que se definió $C(d)$ como:

$$C(d) = \begin{cases} 1 & \text{si } d = 1 \text{ ó } d = \sqrt{2} \\ 0 & \text{en otro caso} \end{cases} \quad (4.9)$$

$1(expr)$: evalúa la expresión $expr$. Si $expr$ es verdadero entrega uno, en otro caso entrega cero.

d_N : es la distancia en el que el más alto ENR se encuentra localizado. En este caso se considera $N = 3$, $d_N = 2$

$N_{n,j}$: es la cantidad de elementos que debería tener un paquete.

4.1.4 Selección

La elección de los individuos que se reproducirán será mediante el popular operador de selección por ruleta, que selecciona con mayor probabilidad a aquellas soluciones con el mejor valor de aptitud y, de este modo, se impone el mecanismo de la sobrevivencia del más apto sobre las soluciones candidatas (ver detalles en el apartado 3.2.4).

4.1.5 Cruzamiento

Para explotar el potencial de la reserva genética, se adopta el cruzamiento OX1 (ver detalles en el apartado 3.2.5) por su buen rendimiento por sobre operadores como PMX y POS según la evaluación realizada por Larrañaga et. al. en [27] y Deep et al. en [26].

4.1.6 Mutación

En este trabajo, se adopta el operador de mutación Inversion Mutation, por resultar el mejor método de mutación, según [27] y [26] (ver detalle en el apartado 3.2.6).

4.2 Análisis para selección de parámetros

4.2.1 Esquemas de prueba

Para propósitos de evaluación y selección de los parámetros del AG: Tp, Pc, Pm, PS para la siguiente generación y NG (correspondiente al criterio de detención), se realizó una implementación secuencial de un AG básico considerando los componentes antes descritos, en lenguaje de programación JAVA contemplando cuatro escenarios diferentes (ver Tabla

5.1). Las pruebas midieron el desempeño del AG tanto: valor de aptitud alcanzado al final del NG en cada ejecución, valor de aptitud promedio de las ejecuciones y el tiempo total promedio de las ejecuciones. Los valores de estos ultimos se encuentran en el anexo A.

Tabla 4.2: Escenarios

Escenario	Tamaño de la máscara	Particiones P
1	8x8	25
2	16x16	16
3	16x16	27
4	32x32	25

El T_p fue evaluado con tres valores diferentes en el rango sugerido por Mitchell en [30] y usadas en experimentación en [11] y [28]. Los valores son: 50, 100 y 150, número de individuos que se mantiene durante todas las generaciones. La P_c fue evaluado con 0.6, 0.8, 1, valores sugeridos por [13] utilizados en experimentación en [28]. La P_m fue evaluado con 0.01, 0.03 y 0.05, valores contenidos en el rango declarado en [28]. El P_s se evaluó con 0 %, 10 % y 20 %, valor utilizado en experimentación en [30] y [11]. El NG se evaluó con 500 1000 y 1500, valores en el rango según [30] y utilizado en experimentación por [27]. Las pruebas se ejecutaron variando uno de los parámetros y el resto con valores definidos por defecto como:

- T_p : 100
- P_c : 0.8
- P_m : 0.03
- P_s : 10 %
- NG : 1000

Se realizó diez ejecuciones del AG por escenario y el algoritmo se ejecutó en un equipo con procesador Intel i5 3ra Generación 2,6Ghz, 3MB Cache, RAM 8 GB DDR3. El esquema de las pruebas realizadas se presenta a continuación:

Tabla 4.3: Esquema de Pruebas T_p

Prueba	T_p	P_c	P_m	P_s	NG
1	50	0.8	0.03	10 %	1000
2	100	0.8	0.03	10 %	1000
3	150	0.8	0.03	10 %	1000

Tabla 4.4: Esquema de Pruebas Pc

Prueba	Tp	Pc	Pm	PS	NG
1	100	0.6	0.03	10 %	1000
2	100	0.8	0.03	10 %	1000
3	100	1	0.03	10 %	1000

Tabla 4.5: Esquema de Pruebas Pm

Prueba	Tp	Pc	Pm	PS	NG
1	100	0.8	0.01	10 %	1000
2	100	0.8	0.03	10 %	1000
3	100	0.8	0.05	10 %	1000

Tabla 4.6: Esquema de Pruebas PS

Prueba	Tp	Pc	Pm	PS	NG
1	100	0.8	0.03	0 %	1000
2	100	0.8	0.03	10 %	1000
3	100	0.8	0.03	20 %	1000

Tabla 4.7: Esquema de Pruebas NG

Prueba	Tp	Pc	Pm	PS	NG
1	100	0.8	0.03	10 %	500
2	100	0.8	0.03	10 %	1000
3	100	0.8	0.03	10 %	1500

4.2.2 Resultados

Los resultados arrojados por las pruebas, considerando de antemano la condición probabilística del algoritmo se presenta a continuación:

Resultados pruebas tamaño de población

Los resultados obtenidos al variar el Tp en 50, 100 y 150 a nivel de valor de aptitud alcanzados por escenario en cada ejecución no fueron concluyentes los cuatro escenarios se comportaron similares (ver Figura 4.3) en cuanto al valor de aptitud y tiempo promedio, los valores de aptitud no muestran una diferencia significativa a diferencia del tiempo requerido para alcanzar el mismo número de generaciones (ver Figura 4.4) por lo que, considerando que los valores usado en la evaluación están equidistantes, a través de la distancia euclídeana (Eq. 4.8) se determinó como Tp final del AG el valor mayor correspondiente a 150.

Resultados pruebas probabilidad de cruzamiento

Los resultados obtenidos al variar el P_c en 0.6, 0.8 y 1 a nivel de valor de aptitud alcanzados por escenario en cada ejecución no fueron concluyentes, debido a que no se presenta ninguna tendencia (ver Figura 4.5) en cuanto al valor de aptitud y tiempo promedio, no muestran una diferencia significativa o tendencia aparente (ver Figura 4.6) motivo que se selecciono como P_c final del AG al valor medio correspondiente a 0.08.

Resultados pruebas probabilidad de mutación

Los resultados obtenidos al variar el P_m en 0.01, 0.03 y 0.05 a nivel de valor de aptitud alcanzados por escenario en cada ejecución no fueron concluyentes, debido a que no se presenta ninguna tendencia (ver Figura 4.7) en cuanto al valor de aptitud y tiempo promedio, no muestran una diferencia significativa o tendencia aparente (ver Figura 4.8) motivo que se selecciono como P_m final del AG al valor medio correspondiente a 0.03.

Resultados pruebas de porcentaje de sobrevivencia

Los resultados obtenidos al variar el P_s en 0, 0.1 y 0.2 a nivel de valor de aptitud alcanzados por escenario en cada ejecución fue visiblemente concluyentes (ver Figura 4.9), al igual que los valores promedios de aptitud y tiempo de ejecución (ver Figura 4.10), resultando mejor cuando el P_s es igual a 0.2, motivo que es este el seleccionado para el AG.

Resultados pruebas número de generaciones

Los resultados obtenidos al variar el N_G en 500, 1000 y 1500 a nivel de valor de aptitud alcanzados por escenario en cada ejecución no fueron concluyentes; los cuatro escenarios se comportaron similares (ver Figura 4.11). Tanto el valor de aptitud como el tiempo promedio en tres de los cuatro escenarios (ver Figura 4.12) muestran un buen resultado con N_G igual a 1000 en proporción al tiempo de ejecución requerido, en comparación a N_G 500 y 1500. Por otra parte, el comportamiento del AG, en cuanto a los valores de aptitud promedio alcanzados en cada generación (ver Figura 4.13) permite observar que en el N_G 500 ya existe una tendencia a estabilizarse, motivo por el cual se considerará este como valor final para N_G .

Resultados pruebas Complementarias

Como se puede apreciar en la Figura 4.14, para los casos de T_p igual 1000, el AG en transcurso de las generaciones va alcanzando un mejor valor de aptitud (ver subfigura

(a)), inicialmente la mejora entre cada generación es notoria, pero llega a un punto donde la variación es muy baja, en tanto el tiempo requerido es el mismo para obtener los valores de aptitud de las primeras generaciones como las últimas (ver subfigura (b)). En cuanto al comportamiento de los valores de aptitud y tiempo de ejecución requerido al examinar el AG con T_p igual 1000, es el mismo (ver Figura 4.15). Para ambos casos donde se presenta una mejora mayor entre la generación 500 y 1000, motivo que se considera estos resultados como concluyentes a los valores T_p y NG seleccionados.

4.2.3 Conclusión pruebas

Las pruebas realizadas sólo fueron concluyentes en el caso de T_p , PS y NG. Tanto para T_p como para NG, los promedios de valor aptitud permitió divisar la diferencia de un valor por sobre otro. En el caso de T_p , el valor mayor (T_p 150) presentó un mejor valor de aptitud versus tiempo de ejecución en proporción a T_p 50 y T_p 100. Por otra parte, para el NG, el comportamiento del valor de aptitud promedio en cada generación fue determinante para escoger el NG 500. En relación a los resultados de las pruebas a PS fueron sorprendentemente exitosas ya que las dos pruebas realizadas presentaron claros resultados de superioridad en cuanto al valor de aptitud alcanzado en todas las ejecuciones y valor de aptitud y tiempo de ejecución promedio para PS 0.2. En el caso de P_c y P_m , las pruebas no fueron concluyentes por lo que se decidió escoger el valor medio de los tres valores de las variables. En cuanto a las pruebas complementarias permitieron establecer que a pesar que el AG alcanza mejores resultados considerando mayores valores para NG y T_p , el comportamiento del AG tiende a ser el mismo considerando el tiempo requerido en cada generación versus el valor de aptitud alcanzado. Inicialmente la mejora entre cada generación en términos de los valores de aptitud es notoria, llegando a un punto donde la variación es muy baja, en tanto que el tiempo requerido para obtener los primeros resultados como los últimos es similar y considerando que los saltos más notorios son alcanzados entre la generación 500 y 1000, no hay motivos que justifiquen alterar los valores de los parámetros antes establecidos.

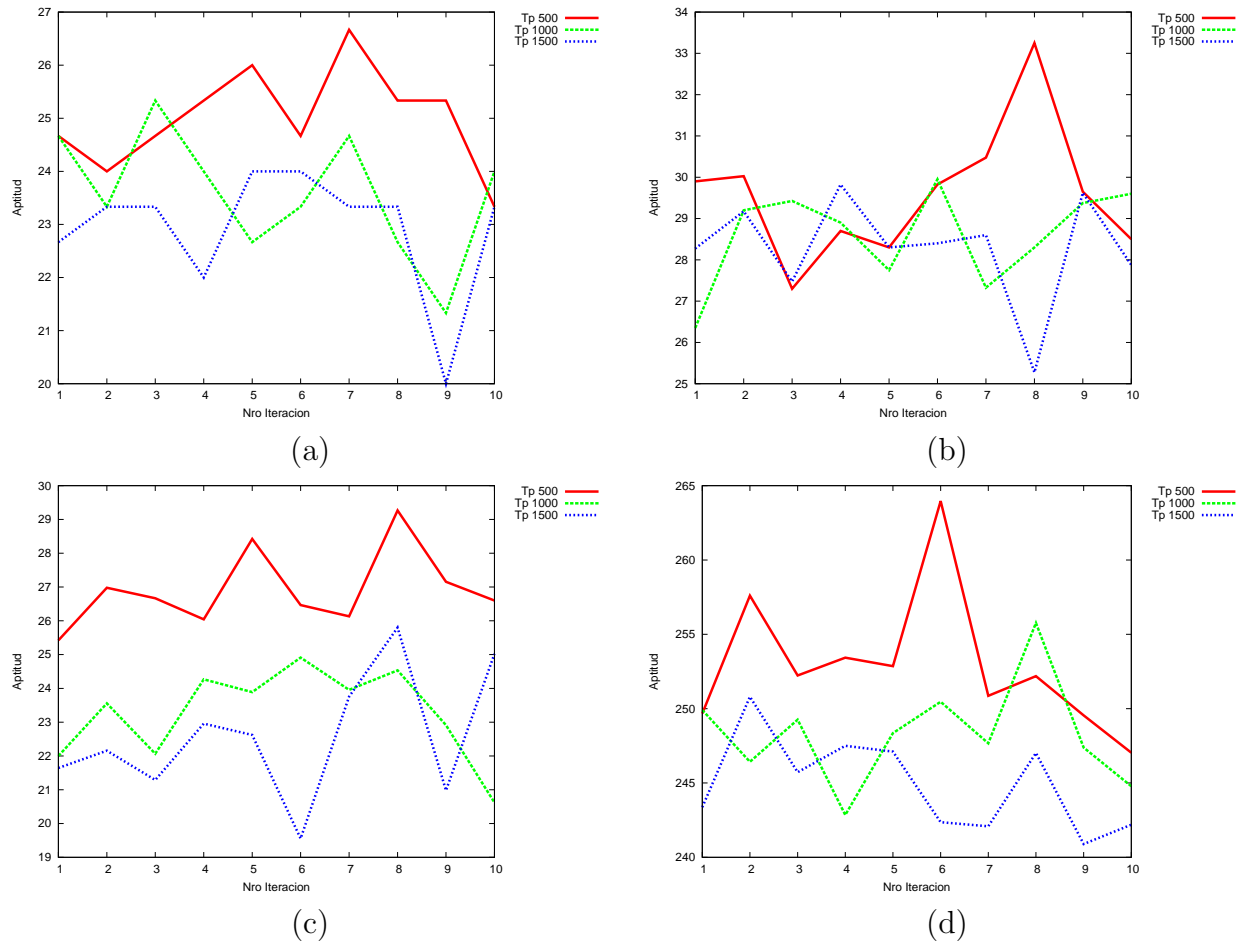


Figura 4.3: Valores de aptitud alcanzados para Tp 50, 100 y 150 en cada ejecución. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16, (c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25

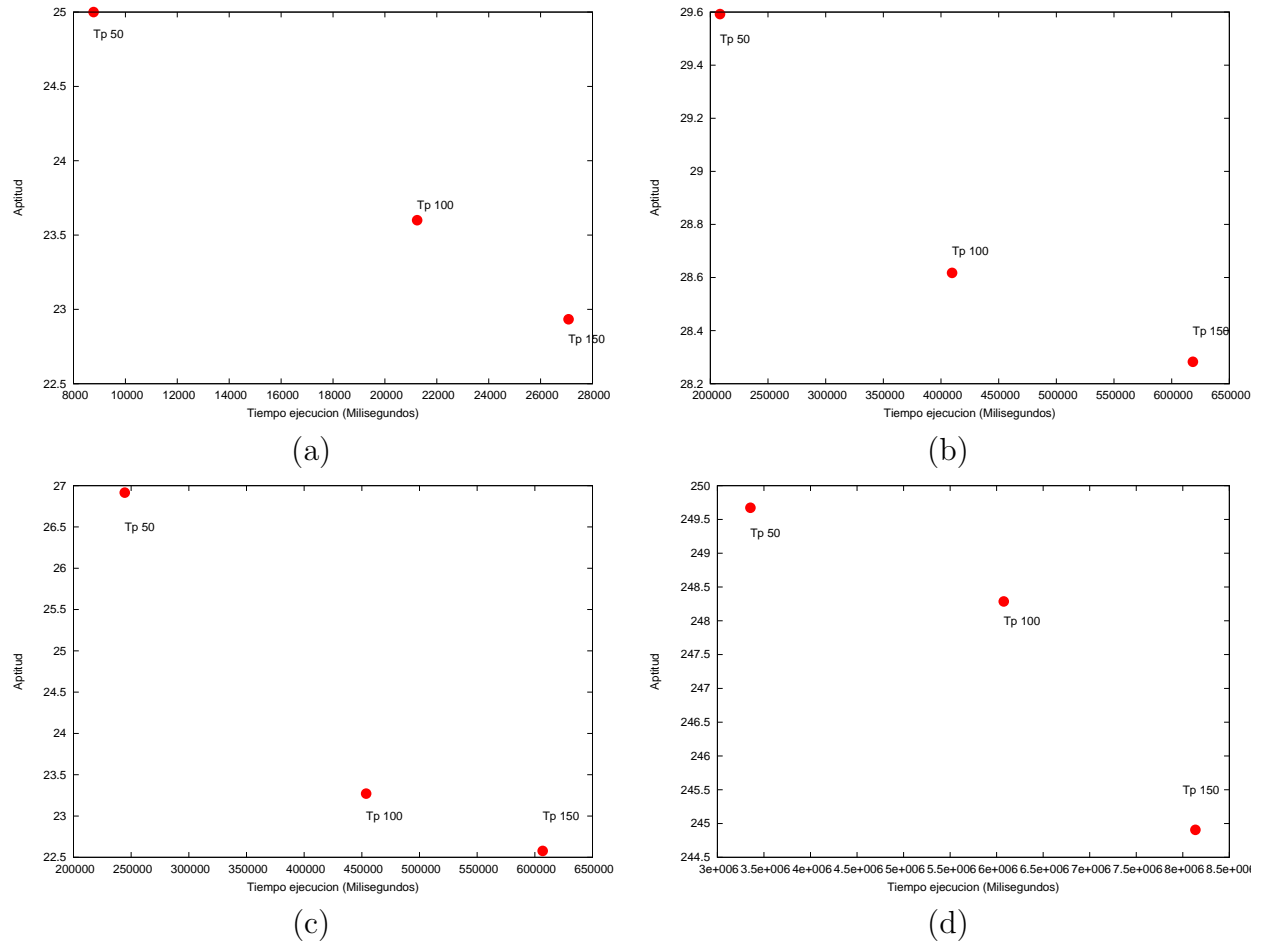


Figura 4.4: Valores de aptitud y tiempo de ejecución promedio para Tp 50, 100 y 150. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16, (c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25

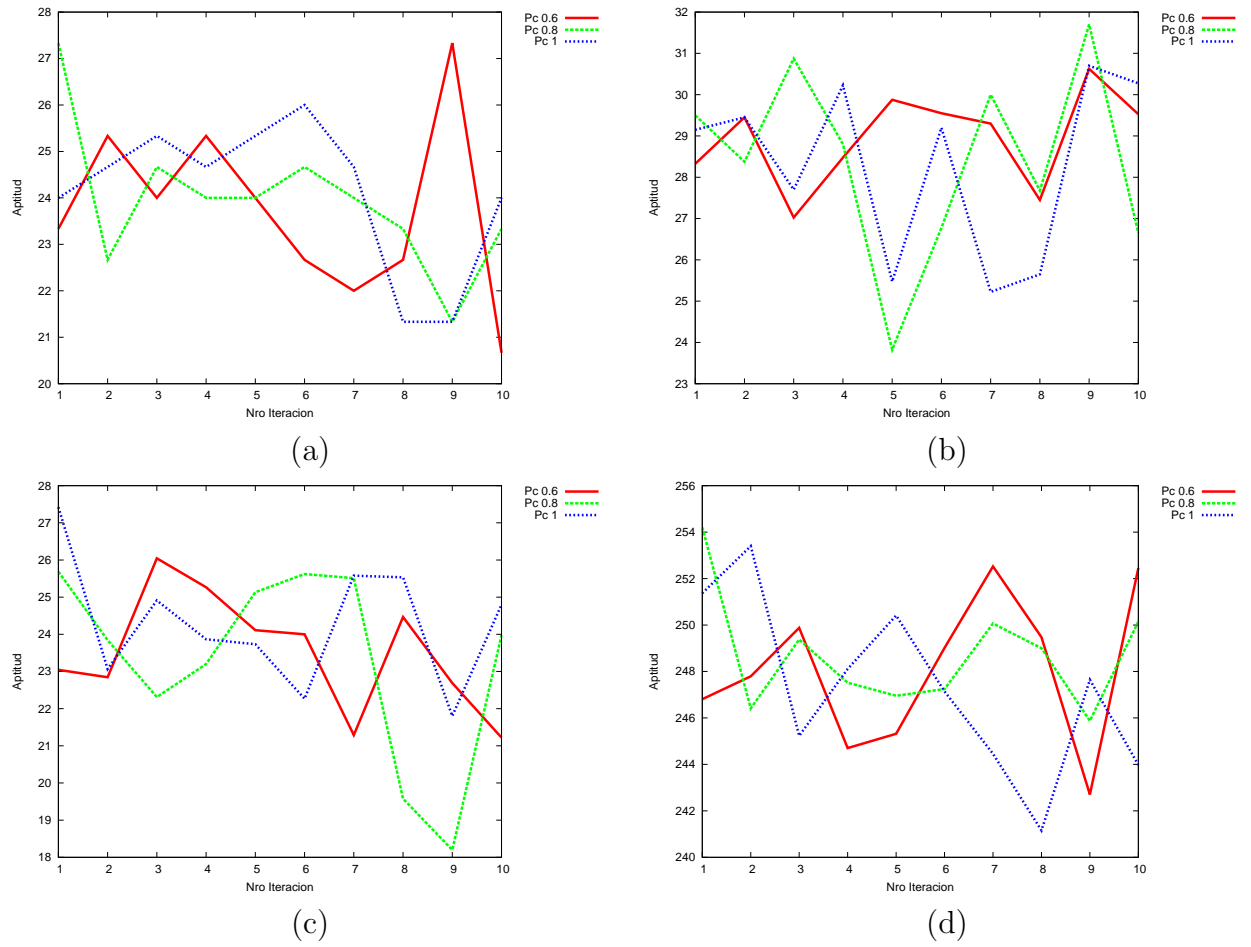


Figura 4.5: Valores de aptitud alcanzados para P_c 0.6, 0.8 y 1 en cada ejecución. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16, (c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25

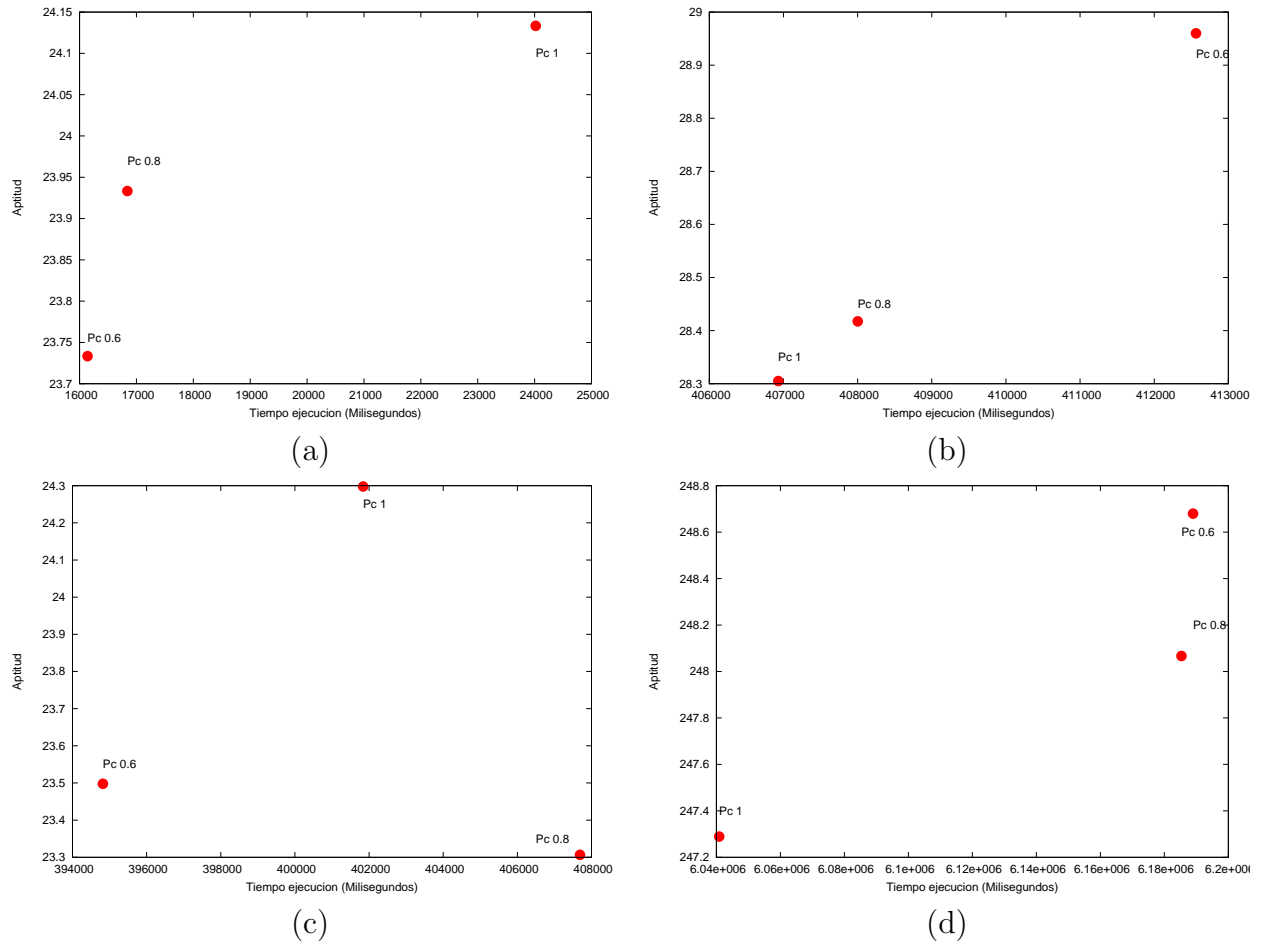


Figura 4.6: Valores de aptitud y tiempo de ejecución promedio para P_c 0.6, 0.8 y 1. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16, (c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25

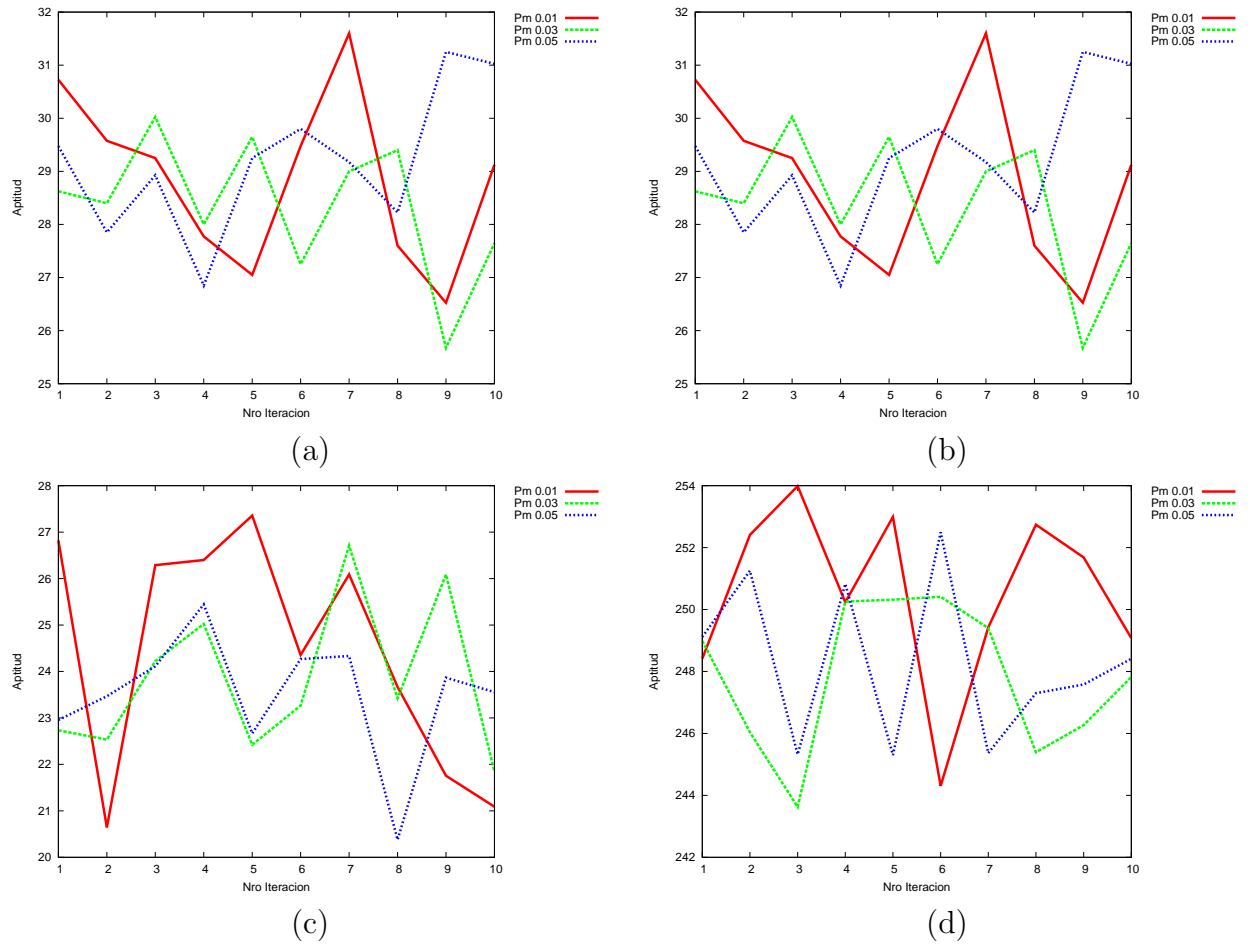


Figura 4.7: Valores de aptitud alcanzados para Pm 0.01, 0.03 y 0.05 en cada ejecución. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16, (c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25

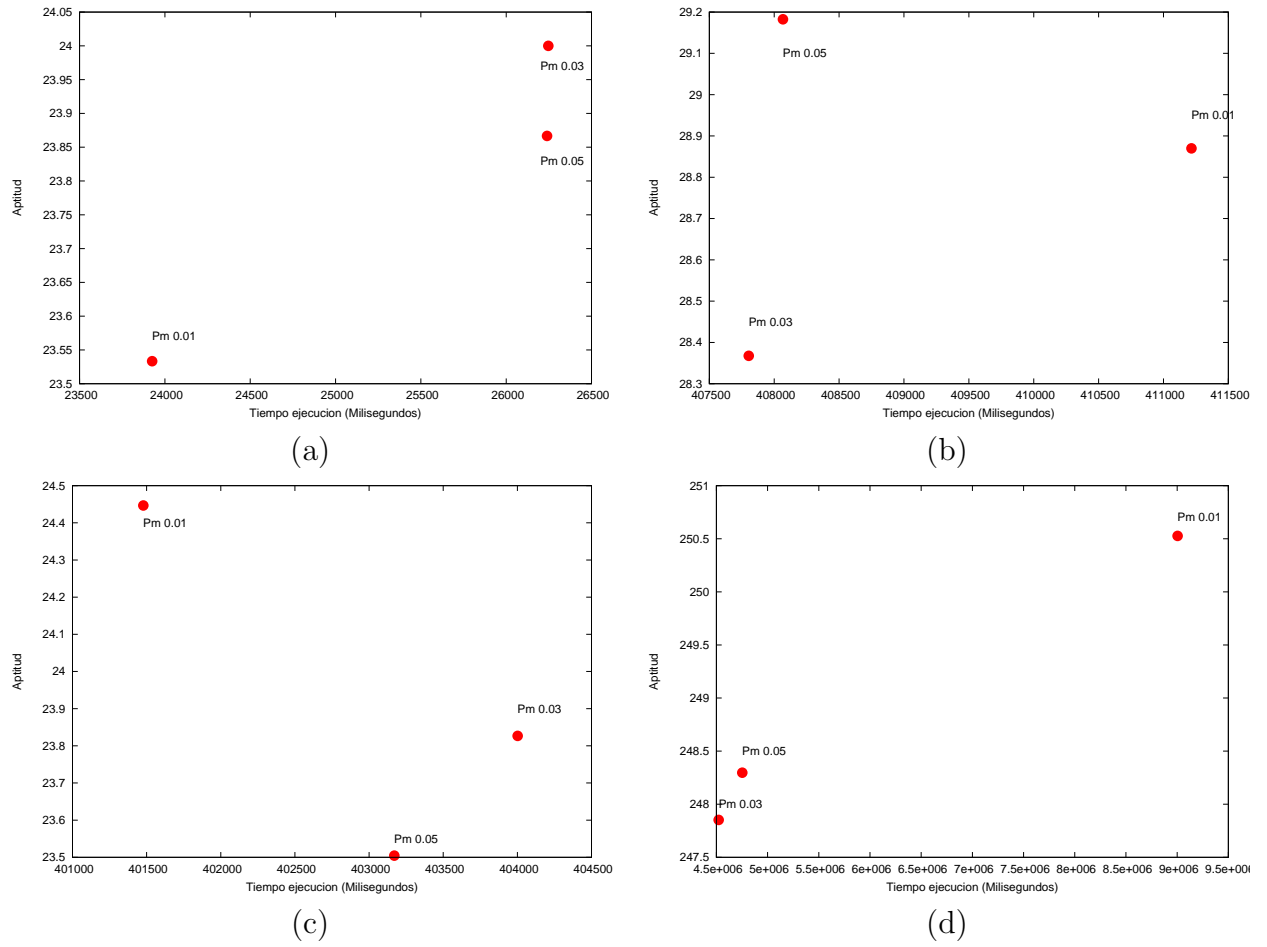


Figura 4.8: Valores de aptitud y tiempo de ejecución promedio para P_m 0.01, 0.03 y 0.05. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16, (c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25.

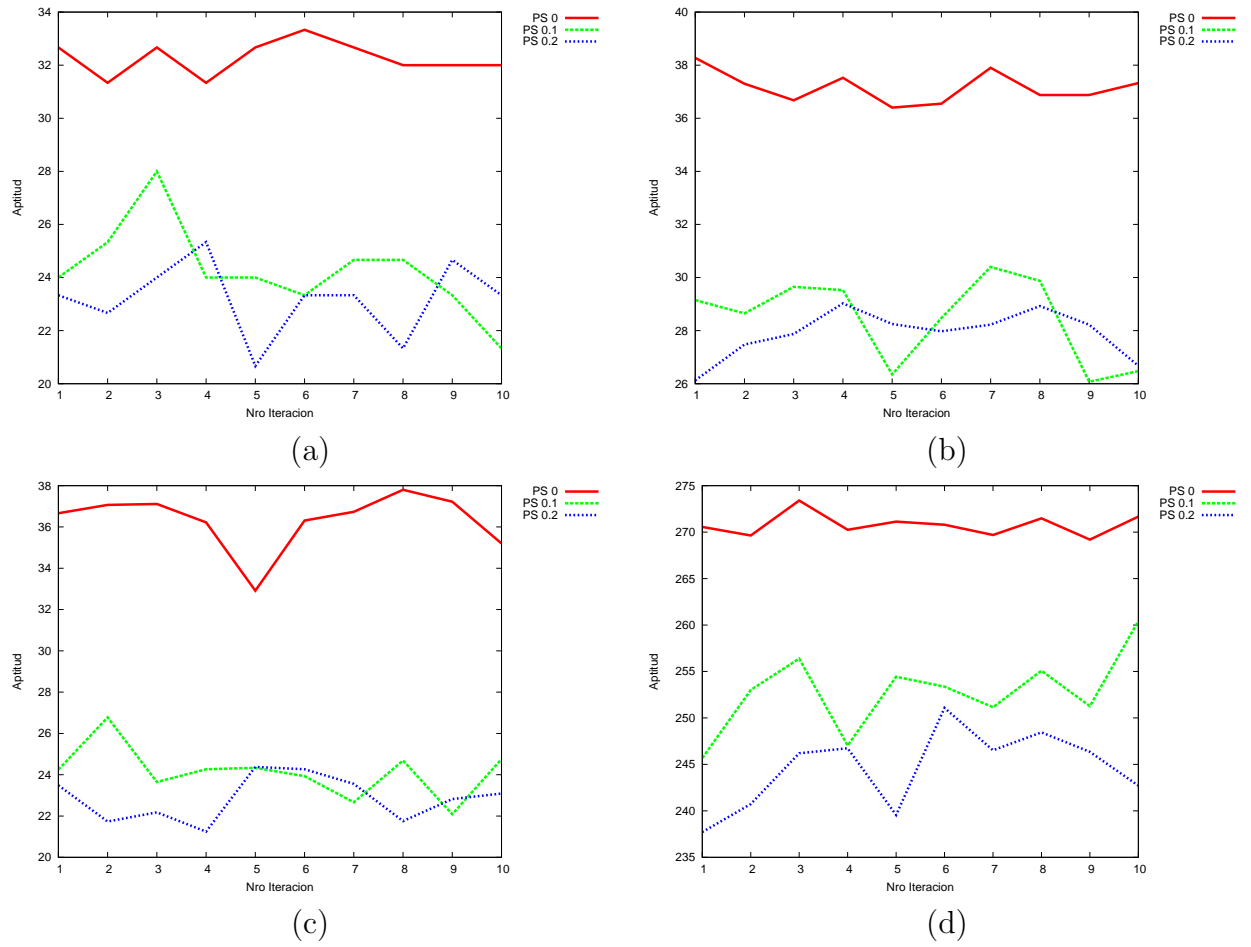


Figura 4.9: Valores de aptitud alcanzados para PS 0, 0.1 y 0.2 en cada ejecución. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16, (c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25

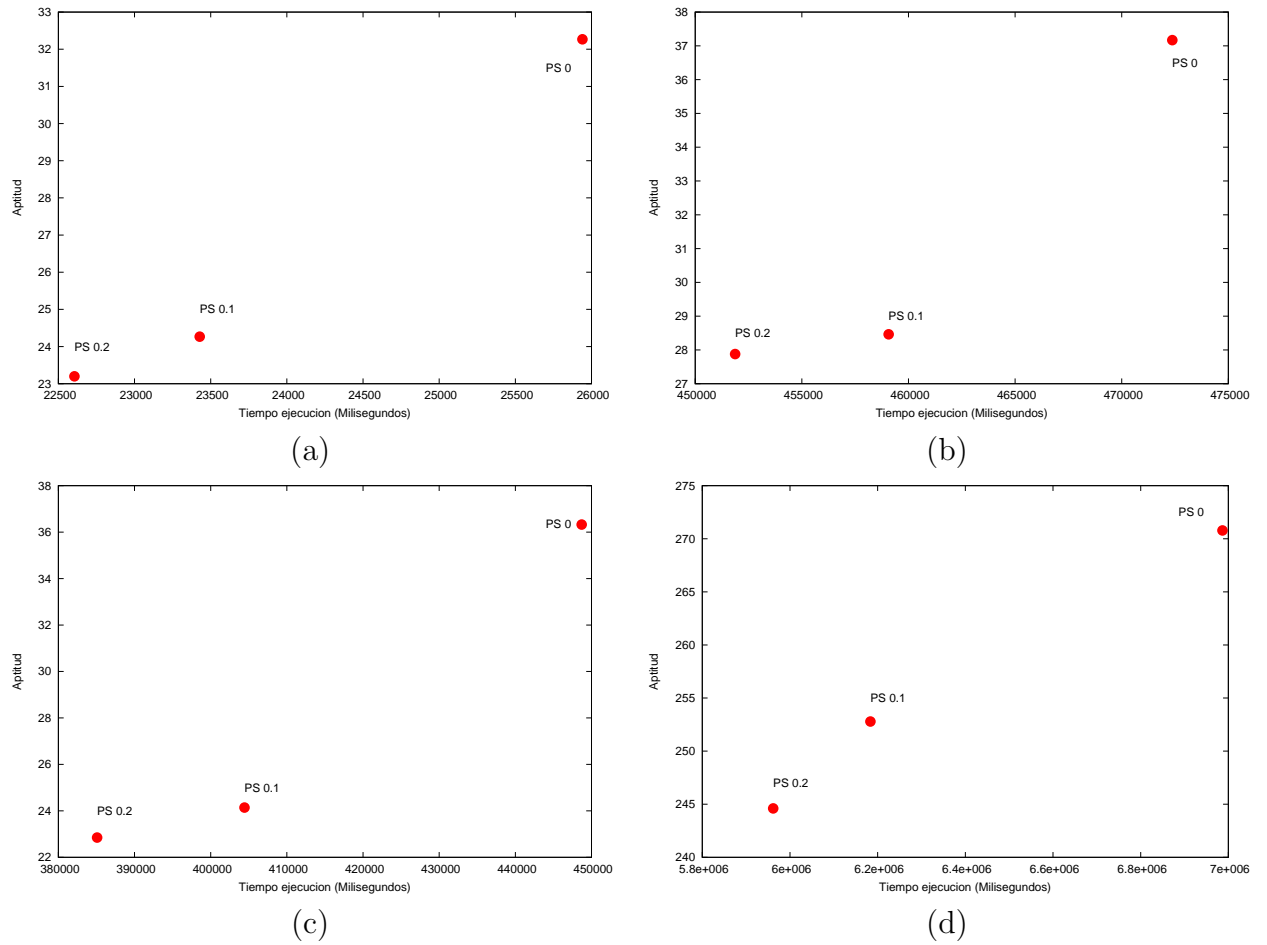


Figura 4.10: Valores de aptitud y tiempo de ejecución promedio para PS 0, 0.1 y 0.2. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16, (c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25




Figura 4.11: Valores de aptitud alcanzados para NG 500, 1000 y 1500 en cada ejecución. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16, (c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25

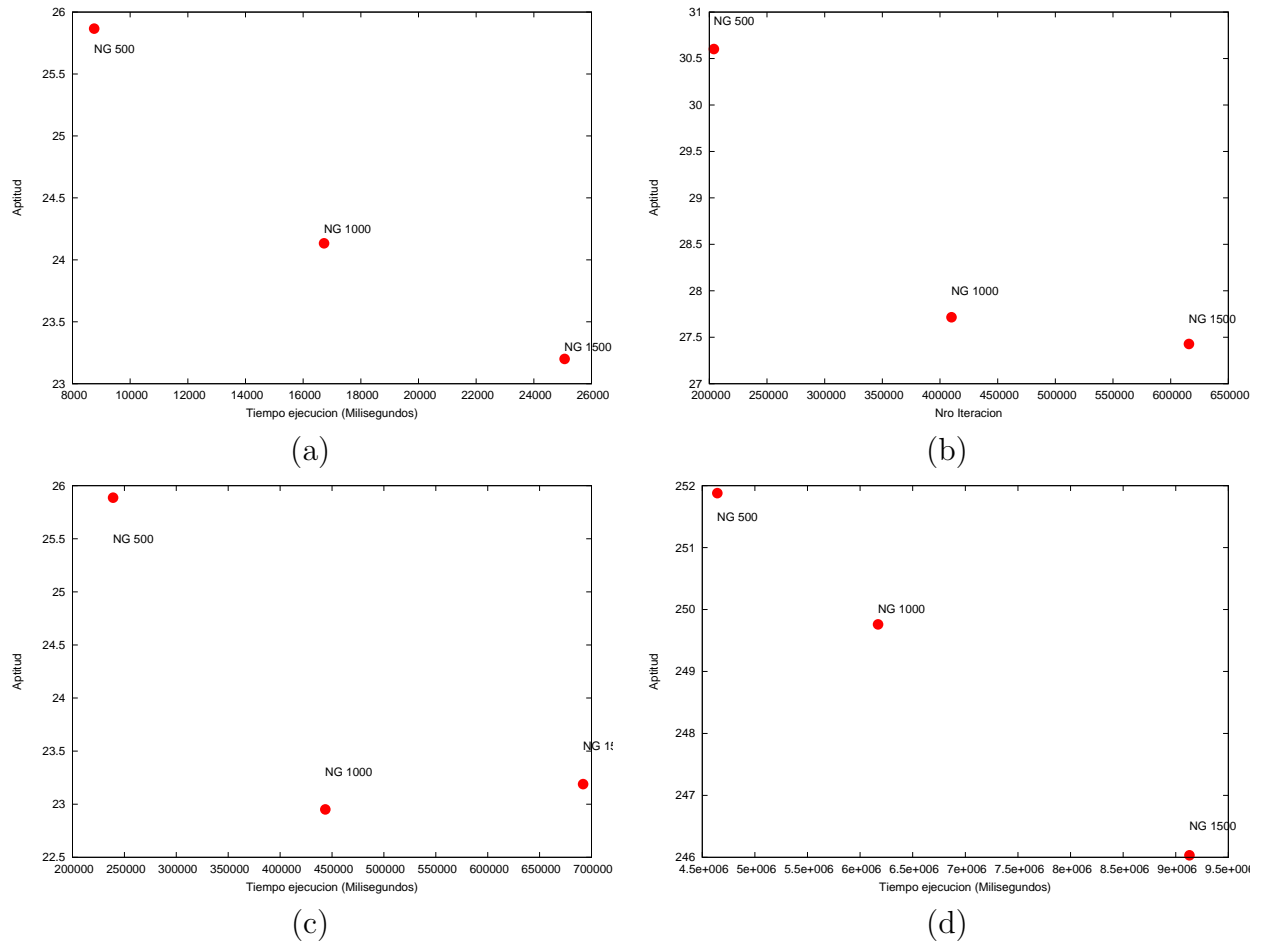


Figura 4.12: Valores de aptitud y tiempo de ejecución promedio para NG 500, 1000 y 1500. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16, (c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25.






Figura 4.13: Valor de aptitud promedio por generación. (a) resultados escenario 1, máscara 8x8 y particiones 25, (b) resultados escenario 2, máscara 16x16 y particiones 16, (c) resultados escenario 3, máscara 16x16 y particiones 27 y (d) resultados escenario 4, máscara 32x32 y particiones 25




(a)




(b)

Figura 4.14: Resultados pruebas adicionales para Máscara 16x16 y Particiones 27 (a) Gráfico número de generación versus aptitud para NG 5000. (b) Gráfico Tiempo de ejecución versus número de generación para NG 5000.



(a)



(b)

Figura 4.15: Resultados pruebas adicionales para Máscara 16x16 y Particiones 27 (a) Gráfico número de generación versus aptitud para Tp 1000. (b) Gráfico Tiempo de ejecución versus número de generación para Tp 1000.

Capítulo 5

Resultados experimentales

En el Capítulo 2, se dieron a conocer algunos de los métodos de entrelazamiento existentes y sus características, principalmente del tipo determinista, que al igual que el AG, proporcionan un patrón de entrelazamiento. Orellana et al. en [32], analiza un conjunto de estos métodos deterministas, obteniendo sus mejores parámetros a través de simulaciones exhaustivas (por fuerza bruta) utilizando la herramienta Sim-LIT presentado en [31]. Los métodos estudiados son: Turner y Peterson, DSJ-AL y AT descritos en el Capítulo 2, resultando notoriamente mejor AT, en términos de la calidad de la imagen que la comunicación secuencial y ligeramente mejor que Turner y Peterson y que DSJ-AL. Por otro lado Rombaut et al. en [41] propone un método utilizando optimización probalística, específicamente el Algoritmo Metropolis (Algoritmo 2) junto con Simulated Annealing (Algoritmo 3) para dar solución al problema de paquetización (patrón de entrelazamiento). Este es comparado con los esquemas de paquetización *slicing technique*, *parity based slicing* y la paquetización basada en la maximización de los mínimos i.p.d, resultando igual o mejor en la calidad de la imagen reconstruida, además de obtener una reducción en la fluctuación de la calidad y un significativo incremento en la calidad en escenarios de alta tasa de pérdida.

Considerando lo antes expuesto, y con el objetivo de evaluar el desempeño del AG en cuanto a la calidad de la paquetización obtenida, se realizó la implementación del AT y del método de Rombaut (denominado desde ahora como AR), los que serán utilizados como referencia comparativa para determinar qué tan buenos son los resultados entregados por la presente propuesta, resultados que serán utilizados en simulaciones mediante la herramienta Sim-LIT 2.0 con diferentes tasas de pérdida, distribución de pérdida e imágenes.

Este Capítulo se compone de dos secciones: primero, se realiza la evaluación del AG en comparación con los otros métodos mencionados y la evaluación de patrones mediante

Algoritmo 2 Pseudocódigo Metropolis muestreo de temperatura Tk.

```

1: mask:=inicializar_mask
2: mientras equilibrio_no_sea_alcanzado hacer
3:   nueva_mask:=generar_nueva_mask(mask)
4:   delta_penalización:=penalización(nuevamask)-penalización(mask)
5:   enfriamiento:=exp(delta_penalización/Tk)
6:   si rand(1) < enfriamiento entonces
7:     mask:=nueva_mask
8:     si enfriamiento > 1 entonces
9:       mejor_mask:=nueva_mask
10:    fin si
11:  fin si
12: fin mientras
13: devolver [mask, mejor_mask]
```

Algoritmo 3 Pseudocódigo Simulated Annealing.

```

1: Tk:=inicializar_Tk
2: mask:=inicializar_mask
3: mientras equilibrio_no_sea_alcanzado hacer
4:   [mask,mejor_mask]:=Metropolis(mask,mejor_mask,Tk)
5:   Tk:=decrease(Tk){ $T_k = T_0 * \alpha^k$ }
6: fin mientras
7: devolver mejor_mask
```

simulaciones, las cuales contienen el diseño de pruebas, resultados obtenidos y conclusiones. En la primera, se definen y describen los escenarios de las pruebas, en la segunda etapa se exhiben los resultados obtenidos y, en la tercera parte, se presenta un resumen con el análisis obtenido de los resultados.

5.1 Evaluación del AG y comparación con otros métodos

La evaluación del AG esta sujeto a los resultados alcanzados por AT y AR. Tanto el AG como AT y AR consideran la misma función de evaluación, tasa de pérdida, tamaño de máscara y particiones (correspondiente al número total de paquetes).

En el caso de AT, los parámetros n y k (ver apartado 2) son obtenidos mediante fuerza bruta. Para el AG y AR se considera mismo porcentajes de Loss Rate, cantidad de ciclos (AG: número de generaciones; AR: equilibrio Simulated annealing), elementos sujetos a evaluación mediante la función de costo de Rombaut (AG: tamaño población;

AR: equilibrio Metropolis) y número de ejecuciones de los algoritmos. Considerando que ambos métodos son de naturaleza probabilística se desea realizar la evaluación bajo las mismas condiciones, motivo que no se realizó mayor énfasis en el análisis para selección de parámetros (ver apartado 4). Las pruebas contemplan diferentes tamaños de máscaras y de particiones. Todos los tamaños de máscara y de particiones se calcularon considerando:

1. Tamaño de bloque máximo de acuerdo al estandar JPGE (8x8)
2. Tamaño de imagen 16x16, 32x32, 64x64 y 128x128.
3. Paquete de datos de acuerdo al valor por defecto de la aplicación de muestra para Cyclops camera firmware (27 bytes) [1] y el usado en experimentación por Jiménez y Armada en [23] y Pham en [34] (100 bytes) valor relacionado con el módulo de radio XBee de Digi [15].

Adicionalmente al final de la sección se presentarán los resultados de las pruebas complementarias, las que se determinaron una vez concluido el proceso investigativo.

Diseño de experimentos para evaluación del AG y comparación con otros métodos

Las pruebas consideran como función de evaluación la función de costo de Rombaut (FCR) detallada en la Sección 4.1.3, Loss Rate (probabilidad de pérdida $\text{Prob}(N_{\text{lost}} = i)$) del 20 %. Las máscaras (*Matriz f de $N \times N$*) y particiones (P) consideradas en cada prueba se detallan en la Tabla 5.1. En la determinación de los mejores parámetros del AT por búsqueda exhaustiva de k y n para cada escenario se consideró $0 \leq k \leq N$ y $0 \leq n \leq P$. Los algoritmos AG y AR se ejecutan un número de 20 veces. Los parámetros de AG se detallan en la Tabla 5.2 y los del AR en la Tabla 5.3. Las pruebas miden el desempeño de los algoritmos en cuanto al mejor valor otorgado por FCR (MVFCR) por iteración en el caso de los algoritmos AG y AR, el mejor resultado alcanzado por AT con sus mejores parámetros (ver Tabla 5.4) y el valor otorgado por FCR a un patrón sin entrelazar (SE). Por otro lado, con el fin de conocer más en detalle se presentará MVFCR final alcanzado por AG y AR, su valor promedio para ambos y el valor FCR (VFCR) para SE y AT. Adicionalmente se presentan los resultados de las pruebas complementarias, considerando un número de iteraciones igual a 5000 y elementos sujetos a evaluación mediante la FCR igual a 1000 para el escenario 5 (máscara 16x16, particiones 27), los cuales miden el desempeño de AG y AR en términos del VPFGR alcanzado por iteración y en cuando a tiempo requerido para alcanzar un valor aproximado de aptitud por AG, AR y AT.

Tabla 5.1: Escenarios

Escenario	Tamaño de la máscara	Particiones P
1	8x8	6
2	8x8	25
3	16x16	6
4	16x16	25
5	16x16	27
6	16x16	100
7	32x32	6
8	32x32	25

Tabla 5.2: Parámetros AG

Parámetros	Valor
NG (Número de Generaciones)	500
Tp (Tamaño población)	150
Pc (Probabilidad de cruce)	0.8
Pm (Probabilidad de mutación)	0.03
PS (Porcentaje de Supervivencia)	0.2

Tabla 5.3: Parámetros AR

Parámetros	Valor
Equilibrio SA	500
Equilibrio Metropolis	150
Temperatura inicial T_0	1500000
Temperatura final T_f	0.001
Probabilidad de aceptación α	0.9

Tabla 5.4: Mejores parámetros AT por escenario

Escenario	Tamaño de la máscara	Particiones P	k	n
1	8x8	6	4	1
2	8x8	25	3	1
3	16x16	6	1	7
4	16x16	25	4	2
5	16x16	27	12	6
6	16x16	100	1	3
7	32x32	6	1	2
8	32x32	25	12	9

Resultados evaluación del AG y comparación con otros métodos

Para la ejecución de las pruebas, se utilizaron los parámetros de AG, AR Y AT definidos en la Tabla 5.2, 5.3 y 5.4 respectivamente y las variables de entrada sujetas al problema descritas en la Tabla 5.1. Los resultados de la evaluación son presentados en la Tabla 5.5, donde las columnas corresponde a los resultados otorgados por la FCR al patrón SE, MVFCR y VPFCR alcanzado por el AG y AR, finalizando con el VFCR de AT con sus mejores parámetros. Las filas contienen el PSNR correspondientes a cada uno de los escenarios (Ver Tabla 5.1).

El comportamiento de AG y AR a lo largo de las iteraciones y los resultados de SE y AT se presentan en las Figuras 5.1, 5.2, 5.3, 5.4, 5.5, 5.7 y 5.8 de acuerdo a cada escenario (ver Tabla 5.1), donde se presenta el mejor VPFCR (eje Y) de AG y AR por iteración (eje X), además de los resultados otorgados a los patrones SE y AT con sus mejores parámetros.

Tabla 5.5: Resultados FCR por escenario.

Prueba	VFCR SE	MVFCR AG	VPFCR AG	MVFCR AR	VPFCR AR	VFCR AT
1	29.2727	5.8364	6.3186	9.3091	9.3363	8.7455
2	109.3333	20	23.7894	31.3333	31.3333	24.6667
3	383.2625	227.4618	229.1624	217.495	218.1787	295.495
4	217.3091	20.0364	21.6105	18.4364	18.5327	23.3455
5	250.8222	22.7778	24.6070	20.1778	20.5511	23.7778
6	557.3333	141.3333	150	112.6667	117.7333	114
7	2778.2573	2550.3018	2550.3139	2557.0901	2557.0901	2550.3018
8	898.7805	244.3707	249.9034	206.7951	209.8641	522.9854

Los resultados de VFCR alcanzados por AG y AR para número de iteración igual a 5000 y el tiempo requerido por iteración son presentados la Figura 5.9. Los resultados considerando elementos sujetos a evaluación igual a 1000 de acuerdo a VFCR y el tiempo requerido por iteración son exhibidos en la Figura 5.10. El desempeño relacionado con el tiempo de ejecución para alcanzar un valor aproximado por AG, AR y AT son expuestos en la Figura 5.11.




Figura 5.1: VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 1 (máscara 8x8, particiones 6).




Figura 5.2: VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 2 (máscara 8x8, particiones 25).




Figura 5.3: VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 3 (máscara 16x16, particiones 6).




Figura 5.4: VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 4 (máscara 16x16, particiones 25).




Figura 5.5: VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 5 (máscara 16x16, particiones 27).






Figura 5.6: VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 6 (máscara 16x16, particiones 100).



(a)



(b)

Figura 5.7: VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 7 (máscara 32x32, particiones 6).






Figura 5.8: VPFCR de AG y AR por iteración y VFCR para AT y SE, escenario 8 (máscara 32x32, particiones 25).



(a)



(b)

Figura 5.9: resultados considerando 5000 iteraciones, escenario 5 (máscara 8x8, pasticciones 6). (a) VPFGR de AG y AR por iteración. (b) tiempo de ejecución por iteración

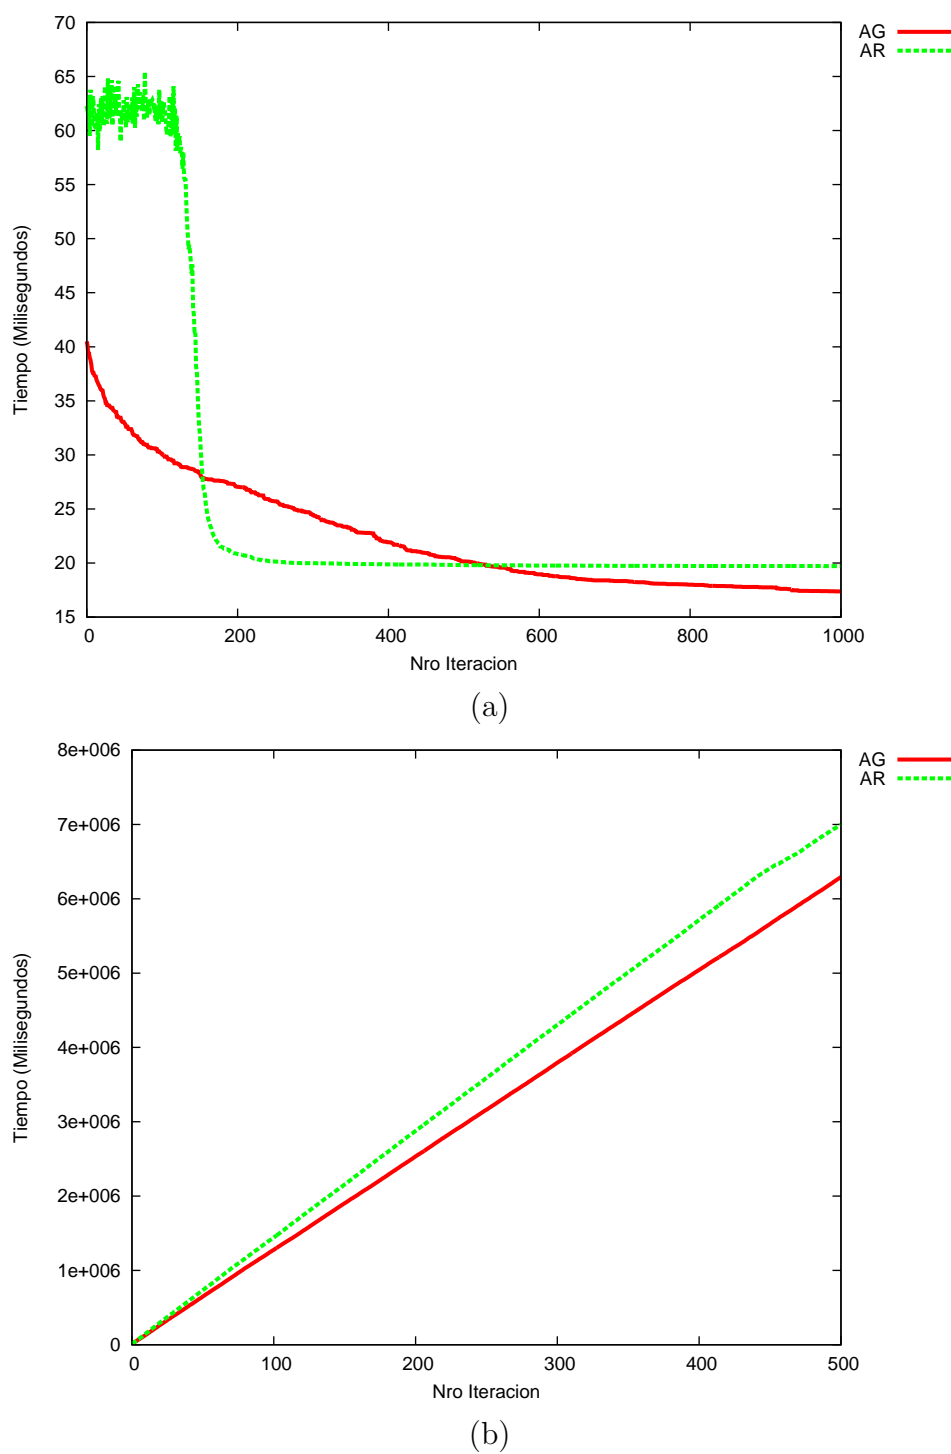


Figura 5.10: resultados considerando elementos sujetos a evaluación igual a 1000, escenario 5 (máscara 8x8, particiones 6). (a) VPFGR de AG y AR por iteración. (b) tiempo de ejecución por iteración




Figura 5.11: Gráfica de tiempos de ejecución por AG, AR y AG en alcanzar un valor aproximado bajo la evaluación de FCR.

Análisis resultados evaluación del AG basado en otros métodos

Considerando los resultados contenidos en la Tabla 5.5 y cada uno de los gráficos resultantes (Figuras 5.1, 5.2, 5.3, 5.4, 5.5, 5.6, 5.7 y 5.8), los métodos de entrelazamiento alcanzaron notoriamente un mejor desempeño que SE. Los escenarios 1, 2 y 7, según MVFCR, el patrón generado por AG obtuvo un desempeño igual o superior que AR y AT, correspondiente al 37,5 % aproximadamente de los casos evaluados. En cuanto a VPFCR solo el 25 % (escenario 1 y 2) obtuvo una mejor valorización. En tanto que los escenarios 3, 4, 5 y 8, equivalente al 50 %, la mejor valorización MVFCR y VPFCR la obtuvo el patrón generado por el AR. Finalmente, en los escenarios 6 y 7, igual 25 %, el patrón generado por AT fue el que obtuvo un desempeño igual o superior a los demás. En relación al comportamiento de AG versus AT, el 62,5 % (escenario 1, 2, 3, 4 y 8) de los escenarios el VPFCR supera a AT y en el MVFCR, el AG obtuvo el mismo valor que AT en el escenario 7. Por otra parte, el comportamiento de los métodos probabilísticos AG y AR, bajo la premisa que el número de iteraciones y el número de evaluación por la FCR fue el mismo, varió. En el 37,5 % de los escenarios (escenario 1, 2 y 7), los resultados alcanzados por AG (MVFCR y VPFCR) estuvieron por sobre AR. En el restante 62,5 %, AR arroja mejores resultados que AG. En cuanto a la conducta de AG y AR, el AG no presentó grandes cambios en las iteraciones a diferencia de AR que presentó un imponente variación en la iteración 150 aproximadamente. Considerando el desempeño de AG y AT bajo los mismos números de iteraciones (ver Figura 5.9), en términos de VFCR el crecimiento de AG es más paulatino que AR, en este caso el AG tiende a estancarse después de la iteración 1000 en cambio el AR en la iteración 600 aproximadamente, casi el doble. En ambos casos la tendencia a estabilizarse se aproxima al mismo VFCR (20). El AG pasado la iteración 4000 alcanzó mejores resultados que AR. En cuanto al tiempo de ejecución, el comportamiento es lineal alcanzando una diferencia de 1033612 milisegundos, considerando que AG tarda 9100226 y AR 10133838 milisegundos para alcanzar la iteración 5000, esta mejora se asocia a la estrategia supervivencia del AG, en relación al VPFCR alcanzado por ambos métodos al final de las iteraciones es de 19.03556 para AG y 19.72888 para AR.

En relación a los resultados de la evaluación considerando los elementos sujetos a evaluación mediante la FCR igual a 1000 (ver Figura 5.10), el comportamiento es similar a la evaluación anterior en términos de VFCR, la mejora de los valores de AG es más lento que AR, en este caso el AG tiende a estancarse después de la iteración 600 en cambio el AR en la iteración 180 aproximadamente, dos veces bajo VFCR de AG, en ambos casos la tendencia a estabilizarse se aproxima al mismo VFCR (20). El AG pasado la iteración 500 alcanzó mejores resultados que AR. En cuanto al tiempo de ejecución, el AG tarda

6291732 y AR 7000381 milisegundos en alcanzar la iteración 1000, el comportamiento de ambos métodos es lineal, alcanzando valores distantes de 708649 milisegundos, diferencia que se asocia nuevamente a la estrategia de sobrevivencia del AG. En relación al VPFCR alcanzado por ambos métodos al final de las iteraciones es de 17,3711 para AG y 19,71851111 para AR.

La conducta en términos del tiempo de ejecución de los métodos AG, AR y AT en alcanzar un valor aproximado (ver Figura 5.11), el VFCR de AT corresponde al mejor obtenido con sus mejores parámetros el que obtuvo con tan solo 783 milisegundos, por otra parte, alcanzar un VFCR similar para AG costo 115.687 milisegundos y para AR 127.738 milisegundos. Estos últimos tuvieron un valor similar pero muy por sobre de AT.

Con estos resultados, bajo la métrica de FCR, ya es posible brindar algunos comentarios sobre la primera hipótesis: “Es posible, utilizando técnicas de computación evolutiva, como algoritmos genéticos, establecer una configuración óptima de paquetización tal que sea mejor o igual, en términos de los resultados arrojados por los métodos de entrelazamiento considerados en esta investigación con sus mejores parámetros encontrados a través de simulaciones exhaustivas al ser evaluados por la función objetivo”. En primer lugar el AG demostró poseer un comportamiento competitivo en comparación a los métodos considerados en la investigación de acuerdo a los cuadros 5.2 y 5.3, alcanzando en un 37,5 % de los casos de evaluación un resultado igual o mejor, especialmente en casos de tamaño de máscara pequeños como lo es de 8x8. En el caso del AG versus AR, considerando que se estableció el mismo número de iteraciones y cantidad de elementos analizados bajo la FCR, para estos casos el AG fue superior en al menos en 3 puntos. Por otro lado considerando que el 62,5 % de los escenarios el AG no alcanzó mejor o igual resultados que AR y AT con los escenarios iniciales, los resultados son prometedores y trabajos futuros podrían mejorar estos indicadores, como es posible observar en las evaluaciones adicionales, en donde, inicialmente con iteraciones igual a 500 y elementos expuestos a evaluación igual a 150 AR presentó mejores resultados para el escenario 5 (máscara 16x16, particiones 27) pero al cambiar el número de iteraciones a 5000 y elementos analizados por la FCR a 1000, el AG alcanzó mejores resultados.

5.1.1 Evaluación de patrones mediante simulaciones

La ejecución de las pruebas de la sección anterior permitió conocer el desempeño del AG en relación a AT y AR de acuerdo a la calificación de los patrones de entrelazamiento mediante la FCR, de los cuales se seleccionó el mejor patrón obtenido de cada algoritmo para ser evaluado por medio de simulaciones a través de Sim-LIT 2.0, el cual proporciona el efecto de la pérdida en la transmisión de imágenes, además de la medida cuantitati-

va PSNR (Peak Signal-to-Noise Ratio) asociada, que es una función a maximizar, y es ampliamente utilizada como métrica de calidad por la comunidad de procesamiento de imágenes. Esto permitirá conocer el desempeño del AG en relación a AT y AR de acuerdo a otra métrica.

Diseño de Pruebas evaluación de patrones mediante simulaciones

Para las pruebas se considera 8 diferentes tasas de pérdida, 200 distribuciones de pérdida por cada tasa y 8 diferentes imágenes clásicas (Baboon (B), Barbara (BR), Cameraman (C), F-16 (F), Goldhill (G), Lena (L), Peppers (P) y Sailboat (S)) en escala de grises (8 bit) presentadas en la Figura 5.12. La técnica de ocultación error pasivo utilizada para la reconstrucción de la imagen es el valor promedio de los píxeles vecinos correctamente recibidos. A continuación, se presenta los diferentes escenarios (Tabla 5.6).



Figura 5.12: Imágenes utilizadas en simulaciones

Tabla 5.6: Escenarios

Escenario	Resolución Imagen (RI) (en píxeles)	Tamaño bloque (TB) (en bytes)	Payload (en bytes)	Particiones (Elementos)	Número de paquetes a transmitir	Tamaño de máscara
1	16x16	1x1	27	27	10	16x16
2	32x32	2x2	100	25	11	16x16
3	32x32	2x2	27	1	43	16x16
4	64x64	2x2	100	25	41	32x32
5	64x64	4x4	100	6	43	16x16

Resultados evaluación de patrones mediante simulaciones

Para la ejecución de las pruebas, se utilizaron los patrones SE y los mejores generados por AG, AR Y AT, en las pruebas anteriores (evaluación del AG basado en otros métodos), por cada escenario definidos en la Tabla 5.6. Los resultados de la evaluación son presentados por patrón e imagen, y a modo de simplificación, considerando el gran número de datos proporcionados por las pruebas, en esta sección solo se analizará el escenario 1 a nivel de datos, por ser el caso que entregó mayor variabilidad en los resultados y el escenario 5 a nivel de imágenes resultantes de la simulación de acuerdo al mejor PSNR alcanzado, por

las dimensiones de la imagen. En la Figura 5.13 se presenta una tabla de gráficas (escenario 1), donde las columnas corresponden a:

1. Patrón
2. Gráfica de PSNR promedio de las 200 distribuciones por porcentaje Loss-Rate, alcanzado por la evaluación de cada imagen
3. Gráfica de PSNR menor de las 200 distribuciones por porcentaje Loss Rate, alcanzado por la evaluación de cada imagen
4. Gráfica de PSNR mayor de las 200 distribuciones por porcentaje Loss Rate, alcanzado por la evaluación de cada imagen

Las filas presentan el valor PSNR correspondientes al patrón SE, AG, AR y AT.

Los valores asociados a los gráficos son detallados en el apartado B.1 del anexo B. De los resultados por imagen, se calculó la desviación estandar por cada porcentaje Loss Rate, los cuales son presentados en:

- Tabla 5.7 , presenta la desviación estandar de acuerdo a los resultados por imagen utilizando el patrón SE
- Tabla 5.8 , presenta la desviación estandar de acuerdo a los resultados por imagen utilizando el patrón AG
- Tabla 5.9 , presenta la desviación estandar de acuerdo a los resultados por imagen utilizando el patrón AR
- Tabla 5.10 , presenta la desviación estandar de acuerdo a los resultados por imagen utilizando el patrón AT

Los resultados obtenidos por patrón se presentan en la Tabla 5.11, correspondiente a una tabla de gráficas distribuidas en columnas:

1. Patrón
2. Gráfica de PSNR promedio de las 200 distribuciones por porcentaje Loss Rate, alcanzado por la evaluación de cada imagen
3. Gráfica de PSNR menor y mayor de las 200 distribuciones por porcentaje Loss Rate, alcanzado por la evaluación de cada imagen

Las filas presentan el valor PSNR correspondientes a la imagen B, BR, C, F, G, L, P y S.

Los valores asociados a los gráficos se detallan en el apartado B.2 del anexo B.

Los resultados del calculo de la desviación estandar por patrón los cuales son exhibidos en:

- Tabla 5.12 de acuerdo a los resultados por patrón utilizando la imagen B

- Tabla 5.13 de acuerdo a los resultados por patrón utilizando la imagen BR
- Tabla 5.14 de acuerdo a los resultados por patrón utilizando la imagen C
- Tabla 5.15 de acuerdo a los resultados por patrón utilizando la imagen F
- Tabla 5.16 de acuerdo a los resultados por patrón utilizando la imagen G
- Tabla 5.17 de acuerdo a los resultados por patrón utilizando la imagen L
- Tabla 5.18 de acuerdo a los resultados por patrón utilizando la imagen P
- Tabla 5.19 de acuerdo a los resultados por patrón utilizando la imagen S

En la Figura 5.14 se presenta un cuadro con las imágenes mejor PSNR alcanzado por el patrón SE y el patrón de entrelazamiento generado por el AG de acuerdo al escenario 5, aplicando el 50 % de Loss Rate, donde las columnas corresponde a la imagen original, sin entrelazar con pérdida, sin entrelazar reconstruida, entrelazada con pérdida y entrelazada reconstruida. Las filas muestra la imagen (B, BR, C, F, G, L, P y S) y el PSNR asociado a la imagen reconstruida.

La Figura 5.15 presenta un cuadro con las imágenes B (Baboon) reconstruidas post transmisión por patrón, aplicando el 10, 30, 50 y 70 % Loss Rate (escenario 5), donde las columnas corresponden al porcentaje Loss Rate e imagen reconstruida patrón SE, AG, AR y AT. Las filas muestra la Imagen y PSNR asociado por cada porcentaje de Loss Rate.

La Figura 5.16 y 5.17 presenta: (a) gráficos de los mejores VFCDR por algoritmo acorde al escenario 1 y 5 respectivamente. (b) gráficos de los mejores PSNR acordes a escenario 1 y 5. Tanto (a) como (b) el porcentaje de Loss Rate aplicado es del 20 %.

Tabla 5.7: Desviación estandar de acuerdo a los resultados por imagen utilizando el patrón SE, **escenario 1**.

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	1.960139575	1.396829868	1.37483536	1.335066565	1.197867886	1.119666487	1.042992546	0.878233424
BR	1.81668531	1.147156187	1.348085229	1.330206245	1.275628525	1.046792671	1.132208583	1.153730059
C	3.410861638	1.866556655	1.781974066	1.895979731	1.835725556	1.694052702	1.499986719	1.486508815
F	3.405023233	1.654227947	1.198656071	1.041781374	0.765106841	0.798589614	0.777591885	0.63035584
G	4.561152625	3.355251254	2.919765853	2.643581987	2.261897592	1.770461361	1.612741533	1.198484739
L	2.182979844	1.257481526	1.007095216	0.85546817	0.720954062	0.629881113	0.560913278	0.572765008
P	0.984516257	0.681386811	0.687471169	0.703974012	0.562258407	0.650050704	0.621143349	0.567505052
S	2.433636834	1.647429954	1.656091201	1.494848517	1.497482347	1.452116376	1.688985361	1.558041499

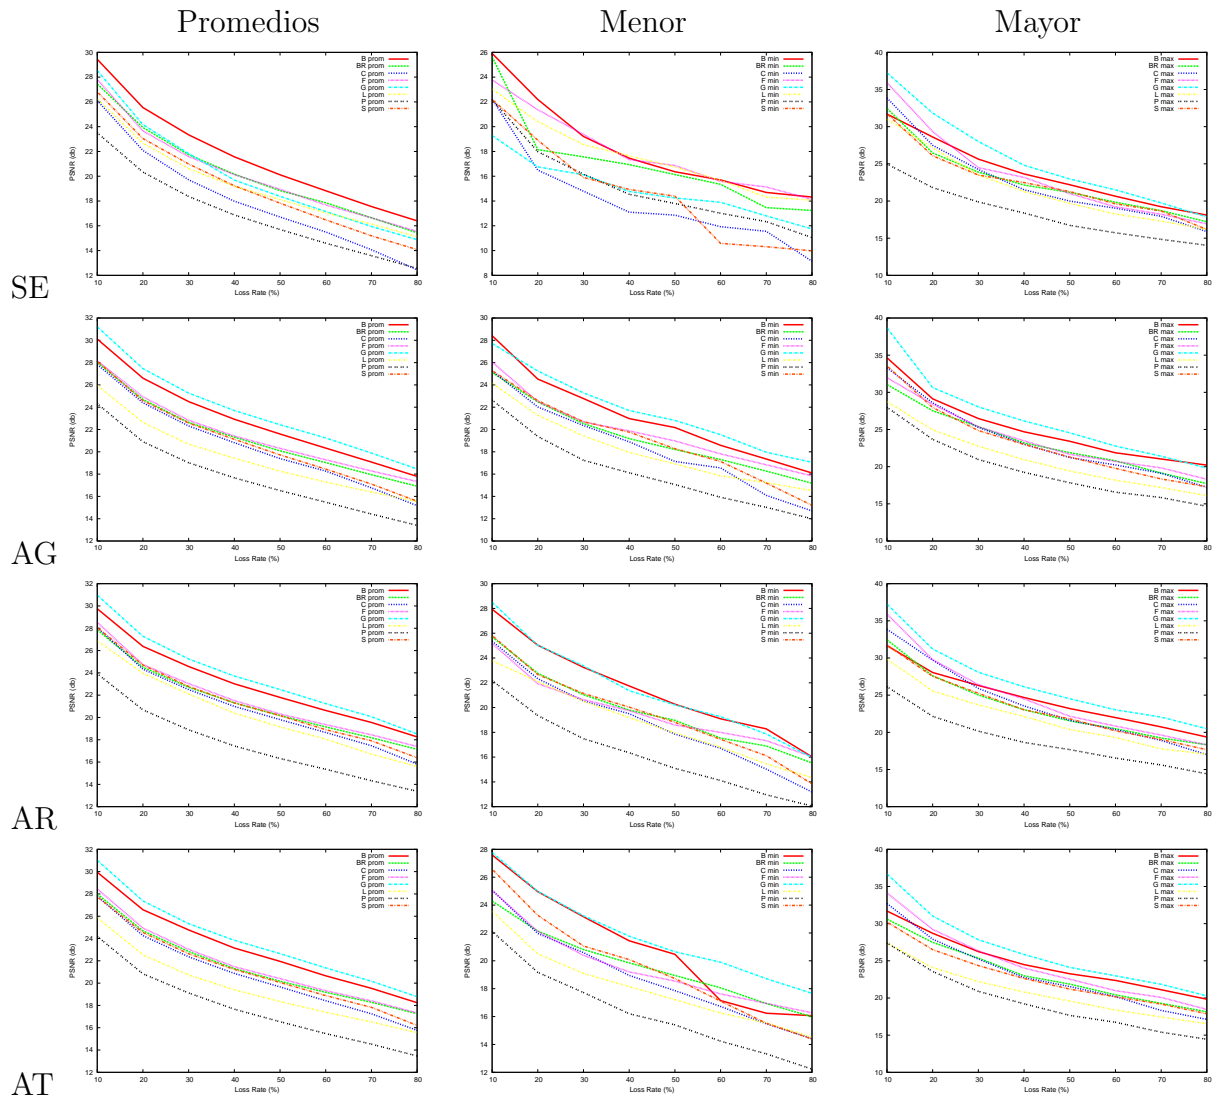


Figura 5.13: Promedio, mayor y menor PSNR alcanzado en el **escenario 1** dependiendo del patrón e imagen.

Tabla 5.8: Desviación estandar de acuerdo a los resultados por imagen utilizando el patrón AG, **escenario 1**.

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	1.873983939	1.082373366	0.780918086	0.778183	0.706020443	0.61551107	0.679524572	0.64954347
BR	1.713785385	1.048725552	0.831949023	0.697660523	0.621428082	0.579007937	0.539858834	0.539228942
C	2.381705236	1.469471276	1.016020313	0.832081043	0.838092182	0.772691042	0.93466256	0.914274405
F	1.983529617	1.198062496	0.807528055	0.672225234	0.557878849	0.525618565	0.524588152	0.577597176
G	3.007546126	1.475112131	0.995409907	0.919729199	0.805356455	0.778304255	0.781191508	0.681832937
L	1.492876483	0.920101281	0.698071856	0.593701692	0.514290575	0.405627757	0.389887174	0.407019945
P	1.628135685	0.907577389	0.835179701	0.642439284	0.606918222	0.606674396	0.553605641	0.605494864
S	2.307993456	1.177381639	0.884022741	0.700221378	0.618364958	0.571330618	0.638026042	0.831293983



Sigue en la página siguiente.

Imagen



Promedios por patrón

Mínimos y máximos por patrón



B





BR



C



F



Sigue en la página siguiente.

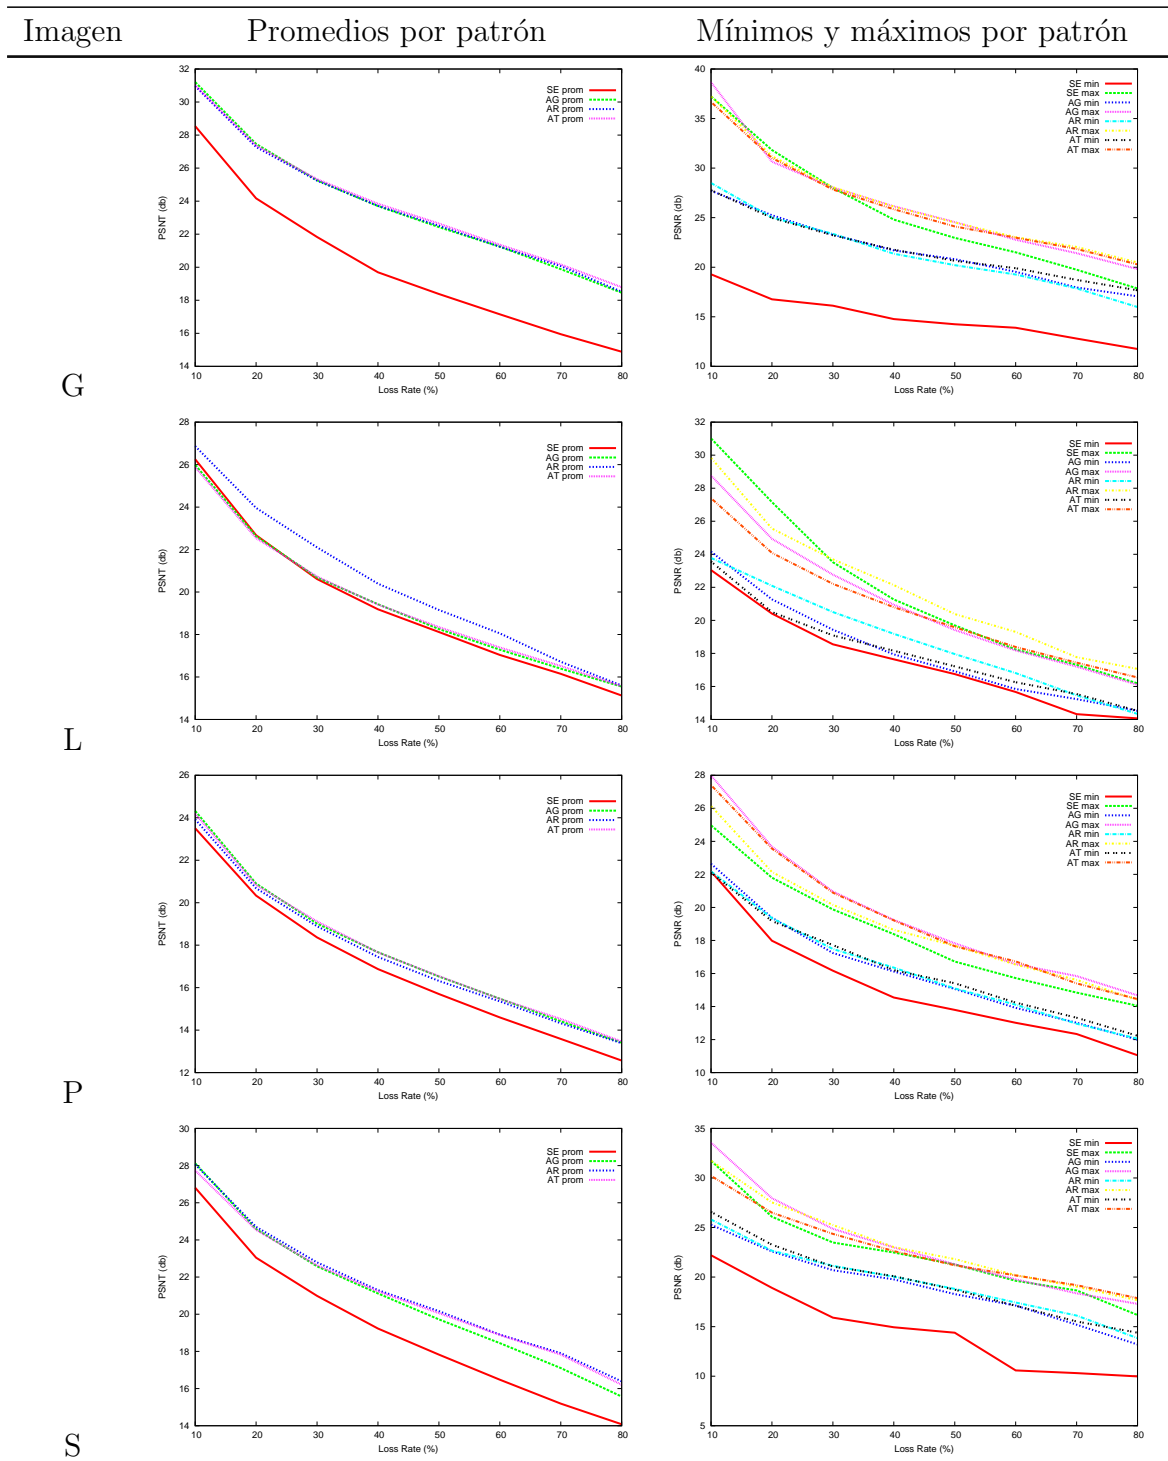


Tabla 5.11: PSNR promedio y mínimo y máximo alcanzados en el **escenario 1** por patrón e imagen.

Tabla 5.9: Desviación estandar de acuerdo a los resultados por imagen utilizando el patrón AR, **escenario 1**.

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	1.217366233	0.866446567	0.705662126	0.603900715	0.544618542	0.582640607	0.573964392	0.712377797
BR	1.894507045	1.08558719	0.759980876	0.620666418	0.516895147	0.519537636	0.497347686	0.548946307
C	2.681212769	1.284595364	1.049546171	0.888144223	0.726993308	0.736289924	0.794304186	1.110231353
F	3.149280771	1.564501375	1.15793513	0.905567448	0.693350686	0.662688618	0.520832703	0.522885005
G	2.395521529	1.25249249	1.063156805	0.95477292	0.922328824	0.913777693	0.93284372	1.016369041
L	0.900765438	0.718344089	0.628153596	0.501470394	0.49197703	0.42831676	0.443243152	0.482676319
P	1.124919561	0.690925783	0.609217072	0.458422175	0.474543425	0.469497487	0.497978779	0.475609792
S	1.725293769	1.007699862	0.8146201	0.641071328	0.657279419	0.623017857	0.631439028	0.83739074

Tabla 5.10: Desviación estandar de acuerdo a los resultados por imagen utilizando el patrón AT, **escenario 1**.

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	1.190212426	0.824491495	0.650308218	0.607941901	0.530863864	0.730730138	0.769087224	0.830837001
BR	1.842533848	1.32873181	0.967584124	0.763216519	0.579777864	0.465850941	0.446115805	0.457159796
C	2.188309173	1.233840086	0.999176678	0.738968455	0.668996463	0.637833726	0.665330375	0.70434928
F	2.740260985	1.758192791	1.173261992	1.005124396	0.832192206	0.69042758	0.580562954	0.490552311
G	2.200569765	1.128581124	0.966229099	0.853660534	0.784984666	0.754714599	0.709560671	0.568804497
L	1.054276343	0.799273917	0.664394696	0.486546029	0.42854844	0.419036178	0.419243972	0.437530358
P	1.501064016	1.003346039	0.710442168	0.59141.332	0.471807782	0.484715581	0.43071869	0.508802882
S	1.12386384	0.68608437	0.628892319	0.601708249	0.578116583	0.626708183	0.643785224	0.772789311

Tabla 5.12: Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen B, **escenario 1**.

Loss Rate (%)	SE	AG	AR	AT
10	1.960139575	1.873983939	1.217366233	1.190212426
20	1.396829868	1.082373366	0.866446567	0.824491495
30	1.37483536	0.780918086	0.705662126	0.650308218
40	1.335066565	0.778183	0.603900715	0.607941901
50	1.197867886	0.706020443	0.544618542	0.530863864
60	1.119666487	0.61551107	0.582640607	0.730730138
70	1.042992546	0.679524572	0.573964392	0.769087224
80	0.878233424	0.64954347	0.712377797	0.830837001

Tabla 5.13: Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen BR, **escenario 1**.

Loss Rate (%)	SE	AG	AR	AT
10	1.81668531	1.713785385	1.894507045	1.842533848
20	1.147156187	1.048725552	1.08558719	1.32873181
30	1.348085229	0.831949023	0.759980876	0.967584124
40	1.330206245	0.697660523	0.620666418	0.763216519
50	1.275628525	0.621428082	0.516895147	0.579777864
60	1.046792671	0.579007937	0.519537636	0.465850941
70	1.132208583	0.539858834	0.497347686	0.446115805
80	1.153730059	0.539228942	0.548946307	0.457159796

Tabla 5.14: Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen C, **escenario 1**.

Loss Rate (%)	SE	AG	AR	AT
10	3.410861638	2.381705236	2.681212769	2.188309173
20	1.866556655	1.469471276	1.284595364	1.233840086
30	1.781974066	1.016020313	1.049546171	0.999176678
40	1.895979731	0.832081043	0.888144223	0.738968455
50	1.835725556	0.838092182	0.726993308	0.668996463
60	1.694052702	0.772691042	0.736289924	0.637833726
70	1.499986719	0.93466256	0.794304186	0.665330375
80	1.486508815	0.914274405	1.110231353	0.70434928

Tabla 5.15: Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen F, **escenario 1**.

Loss Rate (%)	SE	AG	AR	AT
10	3.405023233	1.983529617	3.149280771	2.740260985
20	1.654227947	1.198062496	1.564501375	1.758192791
30	1.198656071	0.807528055	1.15793513	1.173261992
40	1.041781374	0.672225234	0.905567448	1.005124396
50	0.765106841	0.557878849	0.693350686	0.832192206
60	0.798589614	0.525618565	0.662688618	0.69042758
70	0.777591885	0.524588152	0.520832703	0.580562954
80	0.63035584	0.577597176	0.522885005	0.490552311

Tabla 5.16: Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen G, **escenario 1**.

Loss Rate (%)	SE	AG	AR	AT
10	4.561152625	3.007546126	2.395521529	2.200569765
20	3.355251254	1.475112131	1.25249249	1.128581124
30	2.919765853	0.995409907	1.063156805	0.966229099
40	2.643581987	0.919729199	0.95477292	0.853660534
50	2.261897592	0.805356455	0.922328824	0.784984666
60	1.770461361	0.778304255	0.913777693	0.754714599
70	1.612741533	0.781191508	0.93284372	0.709560671
80	1.198484739	0.681832937	1.016369041	0.568804497

Tabla 5.17: Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen L, **escenario 1**.

Loss Rate (%)	SE	AG	AR	AT
10	2.182979844	1.492876483	0.900765438	1.054276343
20	1.257481526	0.920101281	0.718344089	0.799273917
30	1.007095216	0.698071856	0.628153596	0.664394696
40	0.85546817	0.593701692	0.501470394	0.486546029
50	0.720954062	0.514290575	0.49197703	0.42854844
60	0.629881113	0.405627757	0.42831676	0.419036178
70	0.560913278	0.389887174	0.443243152	0.419243972
80	0.572765008	0.407019945	0.482676319	0.437530358

Tabla 5.18: Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen P, **escenario 1**.

Loss Rate (%)	SE	AG	AR	AT
10	0.984516257	1.628135685	1.124919561	1.501064016
20	0.681386811	0.907577389	0.690925783	1.003346039
30	0.687471169	0.835179701	0.609217072	0.710442168
40	0.703974012	0.642439284	0.458422175	0.591418332
50	0.562258407	0.606918222	0.474543425	0.471807782
60	0.650050704	0.606674396	0.469497487	0.484715581
70	0.621143349	0.553605641	0.497978779	0.43071869
80	0.567505052	0.605494864	0.475609792	0.508802882

Tabla 5.19: Desviación estandar de acuerdo a los resultados por patrón utilizando la imagen S, **escenario 1**.

Loss Rate (%)	SE	AG	AR	AT
10	2.433636834	2.307993456	1.725293769	1.12386384
20	1.647429954	1.177381639	1.007699862	0.68608437
30	1.656091201	0.884022741	0.8146201	0.628892319
40	1.494848517	0.700221378	0.641071328	0.601708249
50	1.497482347	0.618364958	0.657279419	0.578116583
60	1.452116376	0.571330618	0.623017857	0.626708183
70	1.688985361	0.638026042	0.631439028	0.643785224
80	1.558041499	0.831293983	0.83739074	0.772789311

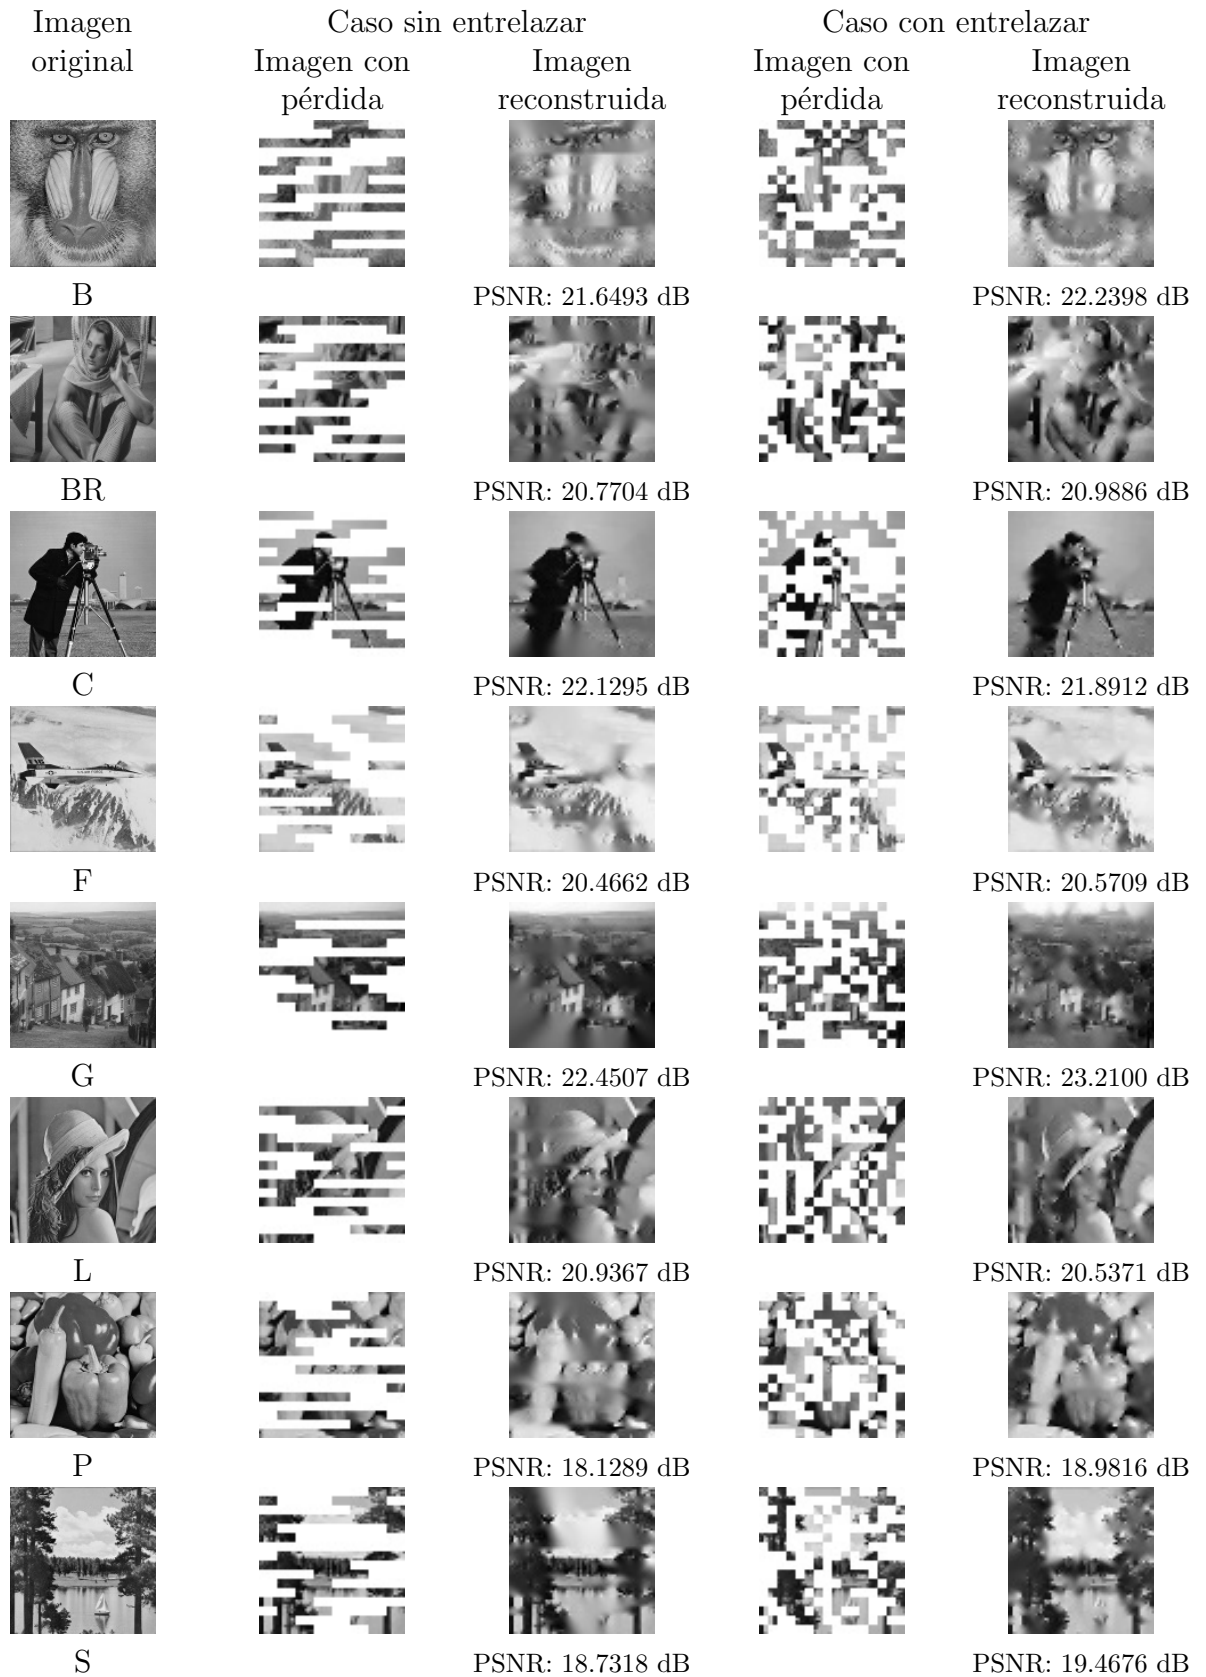


Figura 5.14: Imágenes obtenidas mejor PSNR alcanzado después de simulaciones, aplicando el 50 % de Loss Rate, **escenario 5**.













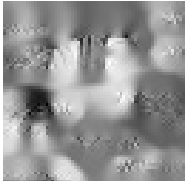
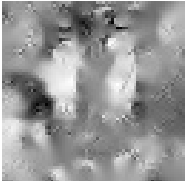
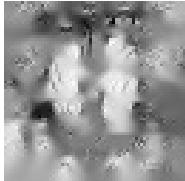
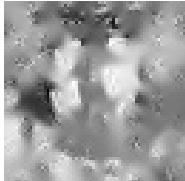
Loss Rate	Imagen reconstruida SE	Imagen reconstruida AG	Imagen reconstruida AR	Imagen reconstruida AT
10 %	 PSNR: 30.7916 dB	 PSNR: 31.1916 dB	 PSNR: 30.9109 dB	 PSNR: 31.0231 dB
30 %	 PSNR: 25.2869 dB	 PSNR: 25.6539 dB	 PSNR: 25.4085 dB	 PSNR: 25.7146 dB
50 %	 PSNR: 21.6493 dB	 PSNR: 22.2398 dB	 PSNR: 22.1582 dB	 PSNR: 22.5291 dB
70 %	 PSNR: 19.2372 dB	 PSNR: 19.6966 dB	 PSNR: 19.6124 dB	 PSNR: 19.8461 dB

Figura 5.15: Imágenes obtenidas mejor PSNR alcanzado después de simulaciones, por patrón SE, AG, AR y AT, **escenario 5**.




Figura 5.16: (a) Gráfico mejores VFCR alcanzados en evaluación del AG basado en otros métodos por SE, AG, AR Y AT, aplicando el 20 % de Loss Rate, **escenario 1**. (b) Gráfico mejores PSNR alcanzados en evaluación de patrones mediante simulaciones por patrón SE, AG, AR y AT, imagen Baboon, aplicando el 20 % de Loss Rate, **escenario 1**.




Figura 5.17: (a) Gráfico mejores VFCR alcanzados en evaluación del AG basado en otros métodos por SE, AG, AR Y AT, aplicando el 20 % de Loss Rate, **escenario 5**. (b) Gráfico mejores PSNR alcanzados en evaluación de patrones mediante simulaciones por patrón SE, AG, AR y AT, imagen Baboon, aplicando el 20 % de Loss Rate, **escenario 5**.

Análisis resultados evaluación de patrones mediante simulaciones

Considerando los resultados contenidos en la Figura 5.13, el PSNR fue variable de acuerdo a las características de la imagen. De las imágenes, el que obtuvo mejor resultados tanto en promedio como el menor y mayor PSNR es G y peor B con una distancia aproximada de 5 puntos. Los resultados de acuerdo al promedio, todos los patrones estuvieron en el rango de 12 a 30. En promedio, no se visualiza una mejora significativa por la aplicación de los patrones de entrelazamiento AG, AR y AT sobre el patrón SE. En relación al menor PSNR (en db) alcanzado por porcentaje de Loss Rate, el patrón SE estuvo en el rango 9 a 26, mientras que AG estuvo entre 11 y 28.5, AR entre 11 y 28 y AT entre 12 a 27.6. En estos resultados es posible visualizar que el patrón SE obtuvo peores resultados (PSNR es más bajo) que los patrones de entrelazamiento. Con respecto a los resultados referentes al mayor PSNR por imagen, el PSNR utilizando el patrón SE están sobre 14.04 y bajo 18.1. Los resultados de AG están sobre 14.6 y bajo los 20.2, los de AR están sobre 14.4 y bajo 20.5 y los de AT están sobre 14.4 y bajo 20.3. En este caso SE entregó al igual que en el menor PSNR un resultado peor que los métodos de entrelazamiento. Considerando tanto el menor como el mayor PSNR, el patrón generado por AR entregó mejores resultados, continuando por AT y por último AG en promedio por las 8 imágenes consideradas en las pruebas.

En las Tablas 5.7, 5.8, 5.9 y 5.10 presentan la desviación estandar por imagen alcanzada por patrón. De la Tabla 5.7 y 5.8 correspondiente a los resultados generados utilizando el patrón SE y AG respectivamente, la imagen que presentó una mayor distancia de la media es G a diferencia de AR y AT, donde es F la que presentó una mayor distancia.

En relación a los resultados por patrón, estos fueron más demostrativos que los por imagen. En la Tabla 5.11 se presenta las gráficas con el promedio de las 200 distribuciones (columna 2) donde se puede apreciar claramente que los patrones resultantes de los métodos de entrelazamiento tienen un comportamiento similar en términos de PSNR y mejor que el SE. En cuatro de las ocho imágenes utilizadas en las simulaciones (B, BR, C y S), el AG presentó claramente un peor resultados a los porcentajes de Loss Rate mayores al 40% aproximadamente. En cuanto al menor el AG en la imagen BR, C y S alcanzó el peor PSNR y en el mayor, en las simulaciones con la imagen B, el patrón del AG presenta un mejor desempeño; por otra parte en BR obtuvo la peor valoración. Los resultados presentados en las tablas 5.12, 5.13, 5.14, 5.15, 5.16, 5.17, 5.18 y 5.19, los resultados del patrón SE presenta mayor variación de la media en cada una de las imágenes que los resultados de los patrones AG, AR y AT. En cuanto al comportamiento de los patrones de entrelazamiento, este varía según la imagen. Las imágenes B, G y S, la menor desviación al valor medio los presenta AT continuados por AR y finalmente AG.

En tanto BR, F, L y P la menor desviación al valor medio los presenta AR, seguidos por AT y finalmente AG. Por último la imagen C, AT presentó la menor desviación luego por AG y AR. Considerando estos resultados, el patrón AG en 7 de las 8 imágenes presenta un deficiente desempeño.

Las imágenes resultantes de las simulaciones del escenario 5, presentadas en la Figura 5.14 muestra el efecto de la pérdida, aplicando el 50 % de Loss Rate. Donde en 6 de las 8 imágenes (B, BR, F, G, P y S) el mejor PSNR los alcanza el patrón de entrelazamiento en este caso el patrón del AG obtenido de las 200 distribuciones. Los otros 2 casos, C y L, el patrón SE alcanzó un mejor PSNR.

La Figura 5.15 presenta las imágenes reconstruidas después de aplicar porcentajes de Loss Rate del 10, 30, 50 y 70 % tanto por el patrón SE como por los patrones entrelazados AG, AR y AT de acuerdo al mejor PSNR de las 200 distribuciones. Resultando mejor los patrones entrelazados que el SE. Los resultados presentados por el 10 % el mejor PSNR los presenta el patrón del AG continuado por AT y AR. En tanto para el 30, 50 y 70 % de Loss Rate los mejores resultados los presentó AT seguido por AG y finalmente por AR.

La Figura 5.16 presenta gráficamente los mejores valores VFCR (a) y PSNR (b) alcanzados por SE, AG, AR y AT respectivamente de las simulaciones escenario 1. Considerando que VFCR, entre menor es el valor mejor es a diferencia del PSNR, donde mayor sea el valor mejor es. En el caso de VFCR los mejores resultados fueron alcanzados por AR, seguidos por AT, AG y por último SE. En tanto el PSNR los mejores resultados los obtuvo el AG seguido por AT, SE y AR. Los valores se encuentran en el apartado B.3 anexo B.

La Figura 5.17 presenta gráficamente los mejores valores VFCR (a) y PSNR (b) alcanzados por SE, AG, AR y AT respectivamente de las simulaciones escenario 5. En el caso de VFCR los mejores resultados fueron alcanzados por AR, seguidos por AG, AT y por último SE. En tanto el PSNR los mejores resultados los obtuvo el AR seguido por AT, AG y SE. Los valores se encuentran en el apartado B.3 anexo B.

5.1.2 Conclusión de las evaluaciones

Los resultados de ambas evaluaciones permitieron concluir que el AG es competitivo frente a métodos de entrelazamiento como AR y AT, ya que considerando la primera hipótesis, a pesar de no alcanzar mejor o igual resultados en todos los escenarios, si logra satisfacer la hipótesis en ciertos escenarios por ejemplo: para tamaño de máscaras pequeñas o para tasa de perdida bajas, además de tener un mejor desempeño en tiempo de ejecución y VFCR alcanzado al final de las iteraciones que AR (resultados de las pruebas complementarias).

En relación al cumplimiento de la segunda hipótesis, al comparar los resultados del

escenario 4 de la evaluación del AG mediante otros métodos y el escenario 1 y 5 de la evaluación de patrones mediante simulaciones, la FCR permitió establecer más claramente que método proporcionó un mejor patrón, en cambio según PSNR los resultados de AG, AR y AT se comportaron similares. En cuanto a los resultados de SE en relación al resto, ambas métricas otorgaron un peor resultado en promedio al patrón SE. Considerando estos resultados es posible responder a la segunda hipótesis que hace referencia a la revalidación de la función objetivo. La diferencia arrojada por la función objetivo seleccionada no se relaciona directamente con los resultados de calidad de las imágenes obtenidas por simulación, por ende no es posible revalidar la FCR.

Capítulo 6

Conclusiones

El problema de encontrar una configuración de paquetización, abreviado como patrón, fue abordado en este trabajo con el método probabilístico algoritmos genético (AG), el cual permitió abarcar la combinatoria sujeta al problema relacionado con las dimensiones en bloques de la imagen a transmitir. Este aspecto ha sido poco tratado anteriormente por los métodos de entrelazamiento existentes, punto que motivó el desarrollo de este proyecto. Los patrones generados por el AG se calificó mediante la función de evaluación a la función de costo objetivo propuesta por Rombaut et al. en [41](FCR), que evalúa la paquetización conforme a tres propiedades, por ser una función revisada y publicada por la IEEE. Además de los operadores descritos en el capítulo 5. Los parámetros del AG como tamaño de población (T_p), probabilidad de cruce (P_c), probabilidad de mutación (P_m), porcentaje de sobrevivencia (PS) y número de generaciones (NG) fue puesta a prueba dentro de los márgenes recomendados y/o utilizados en experimentación en [11, 28, 30]. En la evaluación se analizó el comportamiento de tres valores por parámetro, en términos del valor final alcanzado por ejecución y al valor promedio versus el tiempo de ejecución, donde T_p , PS y NG presentaron resultados que permitieron la selección de un valor por sobre otro, especialmente PS , que en ambos resultado presentó el mismo mejor valor. En cuanto a las pruebas de P_c y P_m ninguna de las pruebas ayudo a definir que valor era mejor por lo que se decidió seleccionar el valor medio de los tres. Adicionalmente una vez concluido el proceso investigativo se determinó la realización de pruebas complementarias, en donde los parámetros NG y T_p fueron evaluados con valores extremos (NG 5000 y T_p 1000) , permitiendo establecer que a pesar que el AG alcanza mejores resultados considerando mayores valores para NG y T_p , el comportamiento del AG tiende a ser el mismo considerando el tiempo requerido en cada generación versus el valor de aptitud alcanzado. Inicialmente la mejora entre cada generación en términos de los valores de aptitud es notoria, llegando a un punto donde la variación es muy baja, en tanto que

el tiempo requerido para obtener los primeros resultados como los últimos es similar y considerando que los saltos más notorios son alcanzados entre la generación 500 y 1000, no hubo motivos que justificaran alterar los valores establecidos en la sección 4.2 del Capítulo 4. Lo que permitió concluir que la calibración no fue inadecuada.

El AG al igual que los métodos de entrelazamiento: propuesto por Rombaut (AR) en [41] y Automorfismo Torales (AT) en [17] se ejecutó bajo distintos escenarios, esto llevó a las primeras pruebas concerniente a la evaluación del AG basados en otros métodos. La función de evaluación que se utilizó fue FCR, esto permitió conocer el comportamiento del AG en relación al patrón sin entrelazar (SE), el generado por AR bajo el mismo número de iteraciones y calificaciones de soluciones candidatas que AG y el de AT generado considerando los mejores parámetros obtenidos por fuerza bruta. Debido a la naturaleza probabilística de AG y AR los esfuerzos se centraron en realizar la evaluación bajo las mismas condiciones, motivo que no hubo un exhaustivo análisis de los parámetros del AG.

En todos los escenarios los métodos de entrelazamiento proporcionaron patrones con mejores resultados, de acuerdo a FCR que SE. De los ocho escenarios considerados, el AG solo en tres, alcanzó un resultado igual o superior a los otros métodos. A pesar de no alcanzar mejor o igual resultados en todos los escenarios, si logra satisfacer la hipótesis en ciertos escenarios por ejemplo: para tamaño de máscaras pequeñas o para tasa de pérdida bajas, además de tener un mejor desempeño en tiempo de ejecución y VFCR alcanzado al final de las iteraciones que AR, evaluaciones correspondientes a las pruebas complementarias.

De la realización de la evaluación del AG basados en otros parámetros se utilizó el mejor patrón generado por cada método y en conjunto con el SE se llevó a simulación utilizando la herramienta Sim-LIT 2.0 que permite simular la transmisión de imágenes considerando un determinado porcentaje de pérdida de paquetes (Loss-Rate), calificando el resultado post transmisión bajo la métrica PSNR. La evaluación de patrones mediante simulaciones considero 5 escenarios, con 8 Loss-Rate, 200 distribuciones de pérdida y 8 imágenes distintas, donde en general el AG no presentó mejores resultados que los otros métodos, contribuyendo al establecer que la primera hipótesis se cumple bajo ciertos parámetros y en algunos escenarios. En relación a la calificación otorgada por FCR y PSNR a los patrones, FCR permitió establecer más claramente que método proporcionó un mejor patrón en cambio según PSNR los resultados de AG, AR y AT se comportaron similares. En cuanto a los resultados de SE en relación al resto, ambas métricas otorgaron un peor resultado al patrón SE. Considerando estos resultados es posible responder a la segunda hipótesis que hace referencia a la revalidación de la función objetivo. Los resultados en cuanto a SE frente a los métodos de entrelazamiento claramente revalidan

la función, pero si solo se consideran los métodos, a pesar que los valores bajo la métrica FCR y PSNR no presentaron grandes variaciones, no fueron muy claras para la validación. Permitiendo concluir que la hipótesis se cumple para los métodos de entrelazamiento versus sin entrelazar pero no para la comparación de los métodos como tal, lo cual da pie a trabajo futuro.

6.1 Trabajo Futuro

Considerando la Hipótesis: “La aplicación de la configuración óptima encontrada a través del algoritmo genético, en simulaciones trabajando con imágenes y tasas de pérdida distintas, revalidará la función objetivo encontrada en el desarrollo del Proyecto Fondecyt número 11121657 “Optimal packetization of still images in wireless vision sensor networks” como trabajo futuro se desea revalidar la FCR a través de métricas como SSIM o la función de ocultamiento de errores (promedio de píxeles vecinos), lo cual no fue posible en este trabajo utilizando la métrica PSNR.

Bibliografía

- [1] *Center of Embedded Network Sensing*, “CENS - CVS Repository”, 2004. URL <http://cvs.cens.ucla.edu/>.
- [2] Ian F. Akyildiz, W. Su, Y. Sankarasubramaniam, and E. Cayirci. Wireless sensor networks: a survey. *Elsevier*, 2002. URL <http://www.sciencedirect.com/science/article/pii/S1389128601003024#>.
- [3] Ian F. Akyildiz, Tommaso Melodia, and Kaushik R. Chowdhury. A survey on wireless multimedia sensor networks. *Computer Networks*, 51(4):921 – 960, 2007. ISSN 1389-1286. doi: 10.1016/j.comnet.2006.10.002. URL <http://www.sciencedirect.com/science/article/pii/S1389128606002751>.
- [4] Enrique Alba and José Troya. A survey of parallel distributed genetic algorithms. URL http://neo.lcc.uma.es/Articles/albatroyaxx_2.pdf.
- [5] Vladimir I. Arnold and A. Avez. *Problèmes Ergodiques de la Mécanique Classique*. Gauthier-Villars, Paris, 1967.
- [6] Eduardo Asbun and Edward J. Delp. Real-time error concealment in compressed digital video streams. URL https://www.cerias.purdue.edu/assets/pdf/bibtex_archive/2001-114-report.pdf.
- [7] Paolo Baronti, Prashant Pillai, Vince W.C. Chook, Stefano Chessa, Alberto Gotta, and Y. Fun Hu. Wireless sensor networks: A survey on the state of the art and the 802.15.4 and zigbee standards. *Computer Communications*, 30(7): 1655 – 1695, 2007. ISSN 0140-3664. doi: 10.1016/j.comcom.2006.12.020. URL <http://www.sciencedirect.com/science/article/pii/S0140366406004749>. wired/wireless Internet Communications.
- [8] F’elix Carretero. *Optimización global con algoritmos genéticos*. PhD thesis, Universidad Polit’ecnica de Catalunya, 2010. URL <http://upcommons.upc.edu/pfc/bitstream/2099.1/10314/1/memoria.pdf>.

- [9] Marco Antonio Castrillón-Veásquez. *Efectos de la cooperación en algoritmos genéticos paralelos*. PhD thesis, Universidad de Santiago de Chile, 2010.
- [10] V. CERNY. Thermodynamical approach to the traveling salesman problem: An efficient simulation algorithm. *JOURNAL OF OPTIMIZATION THEORY AND APPLICATION*, 45(1), January 1985.
- [11] Lance Chambers. *The practical Handbook of Genetic Algorithms applications*. 2001. URL <http://read.pudn.com/downloads154/ebook/684612/Practical%20Handbook%20f%20Genetic%20Algorithms.pdf>.
- [12] Carlos A. Coello Coello. *Introducción a los algoritmos Genéticos*. 1995. URL <http://delta.cs.cinvestav.mx/~ccoello/revistas/genetico.pdf.gz>.
- [13] Kenneth Alan De-Jong. *ANALYSIS OF THE BEHAVIOR OF A CLASS OF GENETIC ADAPTIVE SYSTEMS*. 1975.
- [14] V. DeBrunner, L. DeBrunner, and Longji Wang. Recovery of lost blocks by dynamic pixel interleaving. In *Circuits and Systems, 1999. ISCAS '99. Proceedings of the 1999 IEEE International Symposium on*, volume 4, pages 131–134, jul 1999. doi: 10.1109/ISCAS.1999.779959. URL <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=779959>.
- [15] Digi. <http://www.digi.com/products/xbee-rf-solutions>. accesado 1-07-2016.
- [16] Bernab'e Dorronsoro-D'iaz. *Diseño e Implementación de Algoritmos Genéticos Celulares para Problemas Complejos*. PhD thesis, Universidad de M'alaga, 2006. URL <http://neo.lcc.uma.es/tesis/PhD-Bernabe.pdf>.
- [17] Cristian Duran-Faundez and Vincent Lecuire. Error resilient image communication with chaotic pixel interleaving for wireless camera sensors. In *Proceedings of the workshop on Real-world wireless sensor networks*, REALWSN '08, pages 21–25, New York, NY, USA, 2008. ACM. ISBN 978-1-60558-123-1. doi: 10.1145/1435473.1435480. URL <http://doi.acm.org/10.1145/1435473.1435480>.
- [18] David B Fogel. *Handbook of Evolutionary Computation*. 1991. URL <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.375.6494&rep=rep1&type=pdf>.
- [19] Michel Gendreau and Jean-Yves Potvin. Metahuristics in combinatorial optimization. *Springer Science*, 2005. URL <http://link.springer.com/article/10.1007%2Fs10479-005-3971-7>.

- [20] David Goldberg. *Genetic algorithms in search, optimization, and machine learning*. 1989.
- [21] David Goldberg. Genetic and evolutionary algorithms come of age. *Communication of the ACM*, 1994. URL <http://bi.snu.ac.kr/Courses/4ai10f/Papers/Goldberg%201994%20-%20Genetic%20and%20evolutionary%20algorithms%20come%20of%20age.pdf>.
- [22] Randy L. Haupt Sue Ellen Haupt. *Practical genetic Algorithms*.
- [23] Víctor P. Gil Jiménez and Ana García Armada. Field measurements and guidelines for the application of wireless sensor networks to the environment and security. 2009.
- [24] Bernhard Korte and Jens Vygen. *Combinatorial Optimization Theory and Algorithms*. 2005. URL <http://cs.yazd.ac.ir/hasheminezhad/COF13R1.pdf>.
- [25] Ashis Kumar-Mishra, Yogomaya Mohapatra, and Anil Kumar Mishra. Multi-objctive genetic algorithm:a comprhensive survey. *Internacional Journal of Emerging Technology and Advanced Engineering*, 2013. URL http://www.ijetae.com/files/Volume3Issue2/IJETAE_0213_13.pdf.
- [26] Hadush Mebrahtu Kusum Deep. Combined mutation operators of genetic algorithm for the travelling salesman problem. *Internacional Journal of Combinatorial Optimization Problems and Informatics*, 2(3):1–23, 2011.
- [27] P. Larrañaga, C.M.H.Kuijpers, R.H. Murga, I. Inza, and S. Dizdarevic. Genetic algorithms for the travelling saleman problem: A review of representations and operators. *Artificial Intelligence Review*, 1999. URL <http://link.springer.com/article/10.1023/A:1006529012972#page-1>.
- [28] C. Y. Lee and J. Y. Choi. A genetic algorithm for job sequencing problems with distinct due dates and general early-tardy penalty weights. 1994.
- [29] Eduardo Matthews D. M. Angélica Pinninghoff J and Héctor Díaz C. Diseño de redes viales urbanas usando algoritmos genéticos. 2004.
- [30] Melanie Mitchell. *An Introduction to Genetic Algorithms*. 1996. URL <http://www.boente.eti.br/fuzzy/ebook-fuzzy-mitchell.pdf>.
- [31] Eric Orellana-Romero, Javier SanMartin-Hernandez, Cristian Duran-Faundez, Vincent Lecuire, and Cristhian Aguilera. Sim-lit: A simulation framework for image quality assessment in wireless visual sensor networks under packet loss conditions.

- XXX *International Conference of the Chilean Computer Science Society*, 2011. URL http://jcc2011.otalca.cl/actas/SCCC/jcc2011_submission_13.pdf.
- [32] Eric Orellana-Romero, Javier SanMartin-Hernandez, Cristian Duran-Faundez, Vincent Lecuire, and Katherine Zapata-Quinones. Evaluation of block interleaving techniques for robust image communication in wireless camera sensor networks. 2014.
- [33] Christos Papadimitriou and Kenneth Steiglitz. *Combinatorial optimization*. 1998.
- [34] Congduc Pham. Communication performances of ieee 802.15.4 wireless sensor motes for data-intensive applications: A comparison of waspmote, arduino mega, telosb, micaz and imote2 for image surveillance. *Journal of Network and Computer Applications*, 2014. URL <http://www.sciencedirect.com/science/article/pii/S108480451400188X>.
- [35] E. J. Posnak, S. P. Gallindo, A. P. Stephens, and H. M. Vin. Techniques for resilient transmission of jpeg video streams. In *Proceedings of Multimedia Computing and Networking*, pages 243–252, Septiembre 1994. URL <http://www.eigence.com/downloads/Techniques.pdf>.
- [36] Arvind Raman and Murali Babu. A low complexity concealment scheme for mpeg-4 coded video sequences. 2001. URL <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.7.5664&rep=rep1&type=pdf>.
- [37] Colin Reeves. Modern heuristic techniques for combinatorial problems. *Blackwell Scientific Publications, Oxford*, 1993. URL <http://tocs.ulb.tu-darmstadt.de/53775694.pdf>.
- [38] Iganacio Robles, José Manuel Benítez, Manuel Lozano, and Francisco Herrera. Implementación de un algoritmo genético distribuido para optimización de problemas reales. 2009. URL sci2s.ugr.es/eamhco/con3.pdf.
- [39] Hugo Roman. *Solución de problemas de optimización mediante algoritmos genéticos aplicando cómputo de alto rendimiento*. PhD thesis, Instituto Politécnico Nacional, 2011. URL <http://itzamna.bnct.ipn.mx/dspace/bitstream/123456789/10144/1/203.pdf>.
- [40] Joost Rombaut, Aleksandra Pižurica, and Wilfried Philips. Locally adaptive passive error concealment for wavelet coded images. *IEEE Signal Processing Society*, 15:178 – 181, Enero 2008.

- [41] Joost Rombaut, Aleksandra Pižurica, and Wilfried Philips. Optimization of packetization masks for image coding based on an objective cost function for desired packet spreading. *IEEE Transactions on Image Processing*, 17(10), OCTOBER 2008.
- [42] M. Srinivas and L. M. Patnaik. Adaptive probabilities of crossover and mutation in genetic algorithms. *IEEE TRANSACTIONS ON SYSTEMS, MAN AND CYBERNETIC*, 1994.
- [43] Andrew S. Tanenbaum and David J. Wetherall. *Computer Networks*. Prentice Hall, 5th edition, 2011.
- [44] Anita Thengade and Rucha Dondal. Genetic algorithm-survey paper. 2012. URL <http://research.ijcaonline.org/ncrtc/number5/mpginmc1039.pdf>.
- [45] Charles J. Turner and Larry L. Peterson. Image transfer: an end-to-end design. In *Conference proceedings on Communications architectures & protocols*, SIGCOMM '92, pages 258–268, New York, NY, USA, 1992. ACM. ISBN 0-89791-525-9. doi: 10.1145/144179.144296. URL <http://doi.acm.org/10.1145/144179.144296>.
- [46] S. Kirkpatrick; C. D. Gelatt; M. P. Vecchi. *Optimization by Simulated Annealing*, volume 220, pages 671–680. 1983. URL <https://stat.duke.edu/~scs/Courses/Stat376/Papers/TemperAnneal/KirkpatrickAnnealScience1983.pdf>.
- [47] G. Voyatzis and I. Pitas. Digital image watermarking using mixing systems. *Computers & Graphics*, 22(4):405 – 416, 1998. ISSN 0097-8493. doi: 10.1016/S0097-8493(98)00030-2. URL <http://www.sciencedirect.com/science/article/pii/S0097849398000302>.
- [48] Thomas Weise. *Global Optimization Algorithms– Theory and Application*. January 4, 2008. URL <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.64.8184&rep=rep1&type=pdf>.

Anexos

Apéndice A

Análisis para selección de parámetros

A.1 Resultados pruebas tamaño de población.

A.1.1 Valores de aptitud y tiempo de ejecución promedio Tp.

Tabla A.1: Aptitud y tiempo de ejecución promedio para Tp 50, 100 y 150.

Valor Tp	Máscara 8x8, particiones 25		Máscara 16x16, particiones 16		Máscara 16x16, particiones 27		Máscara 32x32, particiones 25	
	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)
50	25	8772.9	29.5925	208372.5	26.91556	244429.7	249.6732	3354532
100	23.6	21242.3	28.6175	409609.2	23.27112	453737.7	248.28586	6075894.9
150	22.93332	27077.9	28.2825	618410.6	22.57779	606775	244.90633	8135143.1

A.1.2 Distancia Ecludianan: Valores de aptitud y tiempo de ejecución promedio Tp.

Tabla A.2: Distancia Euclidiana: Aptitud y tiempo de ejecución promedio para Tp 50, 100 y 150.

Valor Tp	Máscara 8x8, particiones 25	Máscara 16x16, particiones 16	Máscara 16x16, particiones 27	Máscara 32x32, particiones 25
50	8772.935	208372.5021	244429.7015	3354532
100	21242.3	409609.201	453737.7	6075894.905
150	27077.9	618410.6006	606775	8135143.104

Tabla A.3: Aptitud y tiempo de ejecución promedio para Pc 0.6, 0.8 y 1.

Valor Pc	Máscara 8x8, particiones 25		Máscara 16x16, particiones 16		Máscara 16x16, particiones 27		Máscara 32x32, particiones 25	
	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)
0.6	23.73333	16140	28.96	412564	23.49777	394820.5	248.06683	6185349.5
0.8	23.93333	16840.6	28.4175	408001.6	23.30666	407688.5	248.67952	6188982.6
1	24.13333	24018.8	28.305	406930.8	24.29778	401838.7 247.28927	6040857.5	

A.2 Resultados pruebas probabilidad de cruce.

A.2.1 Valores de aptitud y tiempo de ejecución promedio Pc.

A.3 Resultados pruebas probabilidad de mutación.

A.3.1 Valores de aptitud y tiempo de ejecución promedio Pm.

Tabla A.4: Aptitud y tiempo de ejecución promedio para Pc 0.01, 0.03 y 0.05.

Valor Pm	Máscara 8x8, particiones 25		Máscara 16x16, particiones 16		Máscara 16x16, particiones 27		Máscara 32x32, particiones 25	
	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)
0.01	23.53332	23925.3	28.87	411216	24.44668	401477.4	250.52682	9004139.5
0.03	24.00001	26246.9	28.3675	407803.9	23.82665	404001.9	247.85218	4521765.4
0.05	23.86666	26239.6	29.1825	408067.5	23.50446	403170.4	248.2971	4752584.5

A.4 Resultados pruebas porcentaje de supervivencia.

A.4.1 Valores de aptitud y tiempo de ejecución promedio PS.

Tabla A.5: Aptitud y tiempo de ejecución promedio para PS 0, 0.1 y 0.2.

Valor PS	Máscara 8x8, particiones 25		Máscara 16x16, particiones 16		Máscara 16x16, particiones 27		Máscara 32x32, particiones 25	
	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)
0	32.26667	25940.2	37.17	472372.4	36.32444	448711.1	270.7795	6986508.2
0.1	24.26666	23428	28.4625	459068.6	24.14	404433.7	252.78536	6183435.2
0.2	23.19999	22605.6	27.8775	451873.1	22.85112	385083.8	244.60586	5961671

A.5 Resultados pruebas número de generaciones.

A.5.1 Valores de aptitud y tiempo de ejecución promedio NG.

Tabla A.6: Aptitud y tiempo de ejecución promedio para NG 500, 1000 y 1500.

Valor NG	Máscara 8x8, particiones 25		Máscara 16x16, particiones 16		Máscara 16x16, particiones 27		Máscara 32x32, particiones 25	
	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)	VFCR	Tiempo (ms)
500	25.86667	8752.2	30.6025	203901.2	25.88666	239106.5	251.87902	4643044.55
1000	24.13334	16725.3	27.715	409962.3	22.95112	443582.4	249.76049	6170794.3
1500	23.19999	25067.1	27.4275	615822	23.18888	691944.4	246.03266	9130296.7

Apéndice B

Resultados evaluación de patrones mediante simulaciones

B.1 Resultados por Imagen

B.1.1 PSNR promedio patrón SE

Tabla B.1: PSNR Promedio patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	29.43891013	25.54338356	23.3402564	21.56670921	20.11659508	18.82786381	17.55400921	16.39952311
BR	27.44910785	23.93280915	21.73821944	20.16585166	18.83611568	17.86011849	16.64335884	15.43823273
C	26.10839423	22.0827035	19.71391767	17.98795984	16.70776435	15.49856808	14.06813851	12.44922303
F	27.82068452	23.65606923	21.58387389	20.13570264	18.94632503	17.68184508	16.64391474	15.54931529
G	28.54064323	24.16920958	21.83099966	19.69143429	18.3769733	17.15022596	15.94455932	14.88152832
L	26.25398221	22.67661561	20.61270531	19.1893894	18.11771594	17.03765386	16.14817449	15.12740451
P	23.50574844	20.33523453	18.36590183	16.87410342	15.69928565	14.59742112	13.58512407	12.56503683
S	26.80990459	23.04446012	20.99008911	19.2316408	17.82821642	16.47941023	15.191385	14.07779494

B.1.2 PSNR promedio, patrón AG

Tabla B.2: PSNR Promedio patrón AG de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	30.11009371	26.60413586	24.5017892	22.92231249	21.59692265	20.33280806	19.07995102	17.79265419
BR	28.0127885	24.69922702	22.63213393	21.32145425	20.08678272	19.03067909	17.94666444	16.91385182
C	27.82985049	24.39516913	22.3202558	20.81976564	19.39132369	18.26882662	16.76512381	15.17095791
F	28.16735584	24.92734666	22.82419291	21.41661257	20.30616175	19.28382866	18.27870065	17.33537479
G	31.20912004	27.46656358	25.26180584	23.70128761	22.42642923	21.2441848	19.88665105	18.45711012
L	25.9826939	22.63118265	20.68043493	19.4274878	18.25670949	17.28411839	16.39193151	15.54738666
P	24.32235568	20.90268869	19.01639966	17.66753009	16.52190674	15.48117246	14.41879328	13.40794901
S	28.12325172	24.58925978	22.57758433	21.11979012	19.72382069	18.44602734	17.10396119	15.5715546

B.1.3 PSNR promedio, patrón AR

Tabla B.3: PSNR Promedio patrón AR de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	29.75331331	26.37656412	24.57199359	23.02157347	21.80043702	20.62968931	19.55296001	18.25911402
BR	27.85673195	24.5020396	22.70865275	21.30882139	20.17060021	19.15340351	18.18039395	17.1403916
C	28.06032831	24.32991303	22.49421133	20.99289232	19.80813495	18.65021019	17.46578792	15.81751758
F	28.53751195	24.74206905	23.03685421	21.51304221	20.3161544	19.35727551	18.44402877	17.39620809
G	30.96587175	27.27954392	25.24543342	23.71629771	22.50992377	21.24269496	20.06901976	18.51561669
L	26.86952645	23.96250197	22.10393938	20.39360916	19.15478554	18.05430525	16.71723704	15.60230058
P	23.92295771	20.68143069	18.89231284	17.44631586	16.31770246	15.35576052	14.32225958	13.38200391
S	28.06637147	24.70256368	22.78902743	21.29958384	20.16625574	18.90502386	17.90847004	16.38872301

B.1.4 PSNR promedio, patrón AT

Tabla B.4: PSNR Promedio patrón AT de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	29.9469874	26.58296498	24.77057399	23.14651079	21.95266504	20.65406075	19.53405516	18.24501141
BR	27.99092009	24.69488065	22.83402013	21.30148497	20.17253196	19.17728826	18.28673429	17.25541053
C	27.79793506	24.26413028	22.35954801	20.87388479	19.66073654	18.42041111	17.24803423	15.76033136
F	28.44552289	24.94114325	23.03050414	21.4730283	20.40594412	19.32085977	18.40896362	17.333088
G	31.01627699	27.37309777	25.32974739	23.84393562	22.64565219	21.36310702	20.1658278	18.78866162
L	25.87584655	22.53628208	20.73058101	19.40881128	18.35026176	17.38963206	16.51924692	15.56545136
P	24.19068778	20.83512966	19.1171391	17.65928804	16.54118537	15.47178774	14.52630953	13.46633719
S	27.73727032	24.53832886	22.63243012	21.22981006	20.05971499	18.88394761	17.82796314	16.20596043

B.1.5 PSNR menor, patrón SE

Tabla B.5: PSNR menor patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	25.915845	22.196067	19.206315	17.458765	16.36344	15.699309	14.691865	14.319255
BR	25.631047	18.150596	17.564945	16.938061	16.136785	15.345498	13.464112	13.235705
C	22.237121	16.493567	14.791991	13.099045	12.858726	11.925801	11.551938	9.139991
F	23.771487	21.367205	19.376393	17.344103	16.86792	15.580884	15.134644	14.123075
G	19.283174	16.759864	16.118894	14.77074	14.247045	13.895795	12.798676	11.74661
L	23.043667	20.408861	18.551022	17.643478	16.748978	15.663421	14.32172	14.066184
P	22.178472	17.984084	16.167982	14.544261	13.797383	13.013632	12.335288	11.049225
S	22.198201	18.912038	15.904657	14.934707	14.38927	10.57893	10.311594	9.97696

B.1.6 PSNR menor, patrón AG

Tabla B.6: PSNR menor patrón AG de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	28.418909	24.52456	22.773918	20.978388	20.176625	18.583757	17.351568	16.099157
BR	25.11276	22.473871	20.533067	19.184805	18.205788	17.306674	16.265612	15.181043
C	25.237259	22.025568	20.355962	18.897449	17.134701	16.558232	14.094472	12.701615
F	26.058853	22.50359	20.674639	19.874176	18.974659	17.813653	16.837816	15.840168
G	27.7185	25.247272	23.2836	21.702437	20.814394	19.538562	17.956237	17.059027
L	24.160005	21.274083	19.432523	17.940532	16.918746	15.844041	15.234915	14.520023
P	22.643304	19.377659	17.238839	16.118964	15.062881	13.920656	13.018591	11.995075
S	25.283307	22.588913	20.698602	19.764951	18.27749	17.13073	15.194083	13.201434

B.1.7 PSNR menor, patrón AR

Tabla B.7: PSNR menor patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	27.935009	25.030785	23.242897	21.742165	20.271023	19.094988	18.280023	16.020854
BR	25.70656	22.764166	21.034563	19.796229	18.965858	17.535427	16.90153	15.52789
C	25.358773	22.329257	20.525693	19.502905	17.861318	16.711456	15.027924	13.180413
F	25.178143	21.929316	20.631362	19.752418	18.590087	17.995967	17.325324	16.038764
G	28.497214	25.018689	23.369167	21.358461	20.210798	19.267258	17.863813	15.980391
L	23.78032	22.094734	20.503301	19.184202	17.958725	16.806192	15.459936	14.33917
P	22.178472	19.352418	17.482816	16.35565	15.094385	14.110455	12.956605	12.054446
S	25.810245	22.661325	21.134329	20.037944	18.809131	17.435718	16.115675	13.840464

B.1.8 PSNR menor, patrón AT

Tabla B.8: PSNR menor patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	27.597092	24.962838	23.163621	21.436582	20.46975	17.1479	16.238367	16.066373
BR	24.293539	22.131766	20.809292	19.850131	18.94984	18.061683	16.93578	15.994793
C	25.06535	21.963316	20.58774	18.953016	17.861821	16.729035	15.480044	14.415646
F	25.054028	22.112449	20.393726	19.205383	18.548793	17.626311	16.948371	16.270708
G	27.771775	24.982141	23.229367	21.765341	20.650832	19.900832	18.720198	17.668026
L	23.562593	20.504396	19.091965	18.157979	17.213006	16.253046	15.538421	14.524392
P	22.106086	19.172537	17.721015	16.201757	15.407348	14.236822	13.322309	12.231282
S	26.573743	23.265754	21.062434	20.088557	18.728952	17.106443	15.523068	14.386759

B.1.9 PSNR mayor, patrón SE

Tabla B.9: PSNR mayor patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	31.695041	28.614506	25.634678	23.641218	22.189954	20.644967	19.234065	18.102515
BR	32.450859	26.471208	23.891194	22.146583	21.157406	19.831693	18.699145	17.200057
C	33.870239	27.491515	24.240015	21.51799	19.992237	19.037203	17.940272	15.88195
F	35.916101	29.341984	24.487622	23.175973	20.998129	19.226634	18.221946	16.927346
G	37.239177	31.823649	28.002796	24.8095	22.960132	21.505411	19.74916	17.854899
L	31.013893	27.159636	23.519341	21.262594	19.696411	18.234793	17.309753	16.185792
P	24.973001	21.80241	19.878278	18.384241	16.721925	15.723426	14.843112	14.043689
S	31.7359	26.087645	23.488365	22.481001	21.270487	19.625597	18.656429	16.172452

B.1.10 PSNR mayor, patrón AG

Tabla B.10: PSNR mayor patrón AG de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	34.648691	29.124529	26.472335	24.689704	23.414297	21.866758	21.037602	20.2069
BR	31.054079	27.520219	25.380212	23.19592	21.88126	20.793113	19.146129	17.717638
C	33.296179	28.588245	25.28506	23.019479	21.215997	20.238479	19.117772	17.228573
F	31.979216	28.392279	25.370725	23.469004	21.660956	20.702786	19.83187	18.307073
G	38.672329	30.648925	28.042885	26.152566	24.55714	22.772815	21.416629	19.811336
L	28.763674	24.940751	22.767245	20.948023	19.417735	18.177501	17.199442	16.101564
P	27.98698	23.676773	20.963457	19.237792	17.831925	16.568155	15.844395	14.676289
S	33.563865	27.960748	24.86423	22.996299	21.294713	19.77153	18.352527	17.295389

B.1.11 PSNR mayor, patrón AR

Tabla B.11: PSNR mayor patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	31.659471	28.050414	26.30487	24.684338	23.197938	21.988322	20.729275	19.364387
BR	32.450859	27.591677	25.024797	23.040635	21.538672	20.493495	19.238236	18.324944
C	33.870239	29.717124	25.90819	23.551999	21.611141	20.361839	18.90753	17.001925
F	35.916101	29.790065	26.412789	24.492944	22.163276	20.837724	19.634071	18.309881
G	37.239177	31.203836	28.074389	26.132428	24.517069	23.026918	22.048324	20.482252
L	29.837162	25.556517	23.69283	22.134236	20.379299	19.30473	17.770935	17.059148
P	26.140174	22.148097	20.157883	18.644398	17.676486	16.539987	15.612012	14.412612
S	31.7359	27.533422	25.253084	23.030652	21.813665	20.201734	19.028031	17.661294

B.1.12 PSNR mayor, patrón AT

Tabla B.12: PSNR mayor patrón SE de acuerdo al porcentaje de Loss-Rate, por imagen escenario 1

Imagen	Loss Rate (%)							
	10	20	30	40	50	60	70	80
B	31.699429	28.707987	26.235157	24.48805	23.261461	22.3636	21.111363	19.832277
BR	30.613687	27.479531	25.370183	22.983525	21.870955	20.428359	19.277436	18.142481
C	32.711655	27.903748	25.234379	22.748195	21.537053	20.190731	18.321924	17.125123
F	34.11881	29.235054	26.340247	24.02703	22.528988	20.987874	20.079005	18.461912
G	36.675284	31.022887	27.836617	25.849027	24.11592	22.981131	21.845819	20.281292
L	27.398523	24.08578	22.209395	20.79749	19.582735	18.387034	17.438491	16.545369
P	27.406823	23.565038	20.894781	19.216877	17.654348	16.732727	15.401296	14.448922
S	30.214507	26.503233	24.359706	22.620519	21.192691	20.164795	19.179506	17.873884

B.2 Resultados por patrón

B.2.1 PSNR promedio imagen B

Tabla B.13: PSNR promedio imagen B de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	29.43891013	30.11009371	29.75331331	29.9469874
20	25.54338356	26.60413586	26.37656412	26.58296498
30	23.3402564	24.5017892	24.57199359	24.77057399
40	21.56670921	22.92231249	23.02157347	23.14651079
50	20.11659508	21.59692265	21.80043702	21.95266504
60	18.82786381	20.33280806	20.62968931	20.65406075
70	17.55400921	19.07995102	19.55296001	19.53405516
80	16.39952311	17.79265419	18.25911402	18.24501141

B.2.2 PSNR promedio imagen BR

Tabla B.14: PSNR promedio imagen BR de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	27.44910785	28.0127885	27.85673195	27.99092009
20	23.93280915	24.69922702	24.5020396	24.69488065
30	21.73821944	22.63213393	22.70865275	22.83402013
40	20.16585166	21.32145425	21.30882139	21.30148497
50	18.83611568	20.08678272	20.17060021	20.17253196
60	17.86011849	19.03067909	19.15340351	19.17728826
70	16.64335884	17.94666444	18.18039395	18.28673429
80	15.43823273	16.91385182	17.1403916	17.25541053

B.2.3 PSNR promedio imagen C

Tabla B.15: PSNR promedio imagen C de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	26.10839423	27.82985049	28.06032831	27.79793506
20	22.0827035	24.39516913	24.32991303	24.26413028
30	19.71391767	22.3202558	22.49421133	22.35954801
40	17.98795984	20.81976564	20.99289232	20.87388479
50	16.70776435	19.39132369	19.80813495	19.66073654
60	15.49856808	18.26882662	18.65021019	18.42041111
70	14.06813851	16.76512381	17.46578792	17.24803423
80	12.44922303	15.17095791	15.81751758	15.76033136

B.2.4 PSNR promedio imagen F

Tabla B.16: PSNR promedio imagen F de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	27.82068452	28.16735584	28.53751195	28.44552289
20	23.65606923	24.92734666	24.74206905	24.94114325
30	21.58387389	22.82419291	23.03685421	23.03050414
40	20.13570264	21.41661257	21.51304221	21.4730283
50	18.94632503	20.30616175	20.3161544	20.40594412
60	17.68184508	19.28382866	19.35727551	19.32085977
70	16.64391474	18.27870065	18.44402877	18.40896362
80	15.54931529	17.33537479	17.39620809	17.333088

B.2.5 PSNR promedio imagen G

Tabla B.17: PSNR promedio imagen G de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	28.54064323	31.20912004	30.96587175	31.01627699
20	24.16920958	27.46656358	27.27954392	27.37309777
30	21.83099966	25.26180584	25.24543342	25.32974739
40	19.69143429	23.70128761	23.71629771	23.84393562
50	18.3769733	22.42642923	22.50992377	22.64565219
60	17.15022596	21.2441848	21.24269496	21.36310702
70	15.94455932	19.88665105	20.06901976	20.1658278
80	14.88152832	18.45711012	18.51561669	18.78866162

B.2.6 PSNR promedio imagen L

Tabla B.18: PSNR promedio imagen L de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	26.25398221	25.9826939	26.86952645	25.87584655
20	22.67661561	22.63118265	23.96250197	22.53628208
30	20.61270531	20.68043493	22.10393938	20.73058101
40	19.1893894	19.4274878	20.39360916	19.40881128
50	18.11771594	18.25670949	19.15478554	18.35026176
60	17.03765386	17.28411839	18.05430525	17.38963206
70	16.14817449	16.39193151	16.71723704	16.51924692
80	15.12740451	15.54738666	15.60230058	15.56545136

B.2.7 PSNR promedio imagen P

Tabla B.19: PSNR promedio imagen P de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	23.50574844	24.32235568	23.92295771	24.19068778
20	20.33523453	20.90268869	20.68143069	20.83512966
30	18.36590183	19.01639966	18.89231284	19.1171391
40	16.87410342	17.66753009	17.44631586	17.65928804
50	15.69928565	16.52190674	16.31770246	16.54118537
60	14.59742112	15.48117246	15.35576052	15.47178774
70	13.58512407	14.41879328	14.32225958	14.52630953
80	12.56503683	13.40794901	13.38200391	13.46633719

B.2.8 PSNR promedio imagen S

Tabla B.20: PSNR promedio imagen S de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	26.80990459	28.12325172	28.06637147	27.73727032
20	23.04446012	24.58925978	24.70256368	24.53832886
30	20.99008911	22.57758433	22.78902743	22.63243012
40	19.2316408	21.11979012	21.29958384	21.22981006
50	17.82821642	19.72382069	20.16625574	20.05971499
60	16.47941023	18.44602734	18.90502386	18.88394761
70	15.191385	17.10396119	17.90847004	17.82796314
80	14.07779494	15.5715546	16.38872301	16.20596043

B.2.9 PSNR menor y mayor imagen B

Tabla B.21: PSNR menor y mayor imagen B de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	PSNR(db)							
	menor SE	mayor SE	menor AG	Mayor AG	menor AR	mayor AR	menor AT	mayor AT
10	25.915845	31.695041	28.418909	34.648691	27.935009	31.659471	27.597092	31.699429
20	22.196067	28.614506	24.52456	29.124529	25.030785	28.050414	24.962838	28.707987
30	19.206315	25.634678	22.773918	26.472335	23.242897	26.30487	23.163621	26.235157
40	17.458765	23.641218	20.978388	24.689704	21.742165	24.684338	21.436582	24.48805
50	16.36344	22.189954	20.176625	23.414297	20.271023	23.197938	20.46975	23.261461
60	15.699309	20.644967	18.583757	21.866758	19.094988	21.988322	17.1479	22.3636
70	14.691865	19.234065	17.351568	21.037602	18.280023	20.729275	16.238367	21.111363
80	14.319255	18.102515	16.099157	20.2069	16.020854	19.364387	16.066373	19.832277

B.2.10 PSNR menor y mayor imagen BR

Tabla B.22: PSNR menor y mayor imagen BR de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	PSNR(db)							
	menor SE	mayor SE	menor AG	Mayor AG	menor AR	mayor AR	menor AT	mayor AT
10	25.631047	32.450859	25.11276	31.054079	25.70656	32.450859	24.293539	30.613687
20	18.150596	26.471208	22.473871	27.520219	22.764166	27.591677	22.131766	27.479531
30	17.564945	23.891194	20.533067	25.380212	21.034563	25.024797	20.809292	25.370183
40	16.938061	22.146583	19.184805	23.19592	19.796229	23.040635	19.850131	22.983525
50	16.136785	21.157406	18.205788	21.88126	18.965858	21.538672	18.94984	21.870955
60	15.345498	19.831693	17.306674	20.793113	17.535427	20.493495	18.061683	20.428359
70	13.464112	18.699145	16.265612	19.146129	16.90153	19.238236	16.93578	19.277436
80	13.235705	17.200057	15.181043	17.717638	15.52789	18.324944	15.994793	18.142481

B.2.11 PSNR menor y mayor imagen C

Tabla B.23: PSNR menor y mayor imagen C de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	PSNR(db)							
	menor SE	mayor SE	menor AG	Mayor AG	menor AR	mayor AR	menor AT	mayor AT
10	22.237121	33.870239	25.237259	33.296179	25.358773	33.870239	25.06535	32.711655
20	16.493567	27.491515	22.025568	28.588245	22.329257	29.717124	21.963316	27.903748
30	14.791991	24.240015	20.355962	25.28506	20.525693	25.90819	20.58774	25.234379
40	13.099045	21.51799	18.897449	23.019479	19.502905	23.551999	18.953016	22.748195
50	12.858726	19.992237	17.134701	21.215997	17.861318	21.611141	17.861821	21.537053
60	11.925801	19.037203	16.558232	20.238479	16.711456	20.361839	16.729035	20.190731
70	11.551938	17.940272	14.094472	19.117772	15.027924	18.90753	15.480044	18.321924
80	9.39991	15.88195	12.701615	17.228573	13.180413	17.001925	14.415646	17.125123

B.2.12 PSNR menor y mayor imagen F

Tabla B.24: PSNR menor y mayor imagen F de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	PSNR(db)							
	menor SE	mayor SE	menor AG	Mayor AG	menor AR	mayor AR	menor AT	mayor AT
10	23.771487	35.916101	26.058853	31.979216	25.178143	35.916101	25.054028	34.11881
20	21.367205	29.341984	22.50359	28.392279	21.929316	29.790065	22.112449	29.235054
30	19.376393	24.487622	20.674639	25.370725	20.631362	26.412789	20.393726	26.340247
40	17.344103	23.175973	19.874176	23.469004	19.752418	24.492944	19.205383	24.02703
50	16.86792	20.998129	18.974659	21.660956	18.590087	22.163276	18.548793	22.528988
60	15.580884	19.226634	17.813653	20.702786	17.995967	20.837724	17.626311	20.987874
70	15.134644	18.221946	16.837816	19.83187	17.325324	19.634071	16.948371	20.079005
80	14.123075	16.927346	15.840168	18.307073	16.038764	18.309881	16.270708	18.461912

B.2.13 PSNR menor y mayor imagen G

Tabla B.25: PSNR menor y mayor imagen G de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	PSNR(db)							
	menor SE	mayor SE	menor AG	Mayor AG	menor AR	mayor AR	menor AT	mayor AT
10	19.283174	37.239177	27.7185	38.672329	28.497214	37.239177	27.771775	36.675284
20	16.759864	31.823649	25.247272	30.648925	25.018689	31.203836	24.982141	31.022887
30	16.118894	28.002796	23.2836	28.042885	23.369167	28.074389	23.229367	27.836617
40	14.77074	24.8095	21.70237	26.152566	21.358461	26.132428	21.765341	25.849027
50	14.247045	22.960132	20.814394	24.55714	20.210798	24.517069	20.650832	24.11592
60	13.895795	21.505411	19.538562	22.772815	19.267258	23.026918	19.900832	22.981131
70	12.798676	19.74916	17.956237	21.416629	17.863813	22.048324	18.720198	21.845819
80	11.74661	17.854899	17.059027	19.811336	15.980391	20.482252	17.668026	20.281292

B.2.14 PSNR menor y mayor imagen L

Tabla B.26: PSNR menor y mayor imagen L de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	PSNR(db)							
	menor SE	mayor SE	menor AG	Mayor AG	menor AR	mayor AR	menor AT	mayor AT
10	23,043667	31,013893	24,160005	28,763674	23,78032	29,837162	23,562593	27,398523
20	20,408861	27,159636	21,274083	24,940751	22,094734	25,556517	20,504396	24,08578
30	18,551022	23,519341	19,432523	22,767245	20,503301	23,69283	19,091965	22,209395
40	17,643478	21,262594	17,940532	20,948023	19,184202	22,134236	18,157979	20,79749
50	16,748978	19,696411	16,918746	19,417735	17,958725	20,379299	17,213006	19,582735
60	15,663421	18,234793	15,844041	18,177501	16,806192	19,30473	16,253046	18,387034
70	14,32172	17,309753	15,234915	17,199442	15,459936	17,770935	15,538421	17,438491
80	14,066184	16,185792	14,520023	16,101564	14,33917	17,059148	14,524392	16,545369

B.2.15 PSNR menor y mayor imagen P

Tabla B.27: PSNR menor y mayor imagen P de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	PSNR(db)							
	menor SE	mayor SE	menor AG	Mayor AG	menor AR	mayor AR	menor AT	mayor AT
10	22,178472	24,973001	22,643304	27,98698	22,178472	26,140174	22,106086	27,406823
20	17,984084	21,80241	19,377659	23,676773	19,352418	22,148097	19,172537	23,565038
30	16,167982	19,878278	17,238839	20,963457	17,482816	20,157883	17,721015	20,894781
40	14,544261	18,384241	16,118964	19,237792	16,35565	18,644398	16,201757	19,216877
50	13,797383	16,721925	15,062881	17,831925	15,094385	17,676486	15,407348	17,654348
60	13,013632	15,723426	13,920656	16,568155	14,110455	16,539987	14,236822	16,732727
70	12,335288	14,843112	13,018591	15,844395	12,956605	15,612012	13,322309	15,401296
80	11,049225	14,043689	11,995075	14,676289	12,054446	14,412612	12,231282	14,448922

B.2.16 PSNR menor y mayor imagen S

Tabla B.28: PSNR menor y mayor imagen S de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	PSNR(db)							
	menor SE	mayor SE	menor AG	Mayor AG	menor AR	mayor AR	menor AT	mayor AT
10	22,198201	31,7359	25,283307	33,563865	25,810245	31,7359	26,573743	30,214507
20	18,912038	26,087645	22,588913	27,960748	22,661325	27,533422	23,265754	26,503233
30	15,904657	23,488365	20,698602	24,86423	21,134329	25,253084	21,062434	24,359706
40	14,934707	22,481001	19,764951	22,996299	20,037944	23,030652	20,088557	22,620519
50	14,38927	21,270487	18,27749	21,294713	18,809131	21,813665	18,728952	21,192691
60	10,57893	19,625597	17,13073	19,77153	17,435718	20,201734	17,106443	20,164795
70	10,311594	18,656429	15,194083	18,352527	16,115675	19,028031	15,523068	19,179506
80	9,97696	16,172452	13,201434	17,295389	13,840464	17,661294	14,386759	17,873884

B.2.17 Desviación estandar imagen B

Tabla B.29: Desviación estandar PSNR de las 200 distribuciones imagen B de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	1.960139575	1.873983939	1.217366233	1.190212426
20	1.396829868	1.082373366	0.866446567	0.824491495
30	1.37483536	0.780918086	0.705662126	0.650308218
40	1.335066565	0.778183	0.603900715	0.607941901
50	1.197867886	0.706020443	0.544618542	0.530863864
60	1.119666487	0.61551107	0.582640607	0.730730138
70	1.042992546	0.679524572	0.573964392	0.769087224
80	0.878233424	0.64954347	0.71237797	0.830837001

B.2.18 Desviación estandar imagen BR

Tabla B.30: Desviación estandar PSNR de las 200 distribuciones imagen BR de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	1.81668531	1.713785385	1.894507045	1.842533848
20	1.147156187	1.048725552	1.08558719	1.32873181
30	1.348085229	0.831949023	0.759980876	0.967584124
40	1.330206245	0.697660523	0.620666418	0.763216519
50	1.275628525	0.621428082	0.516895147	0.579777864
60	1.046792671	0.579007937	0.519537636	0.465850941
70	1.132208583	0.539858834	0.497347686	0.446115805
80	1.153730059	0.539228942	0.548946307	0.457159796

B.2.19 Desviación estandar imagen C

Tabla B.31: Desviación estandar PSNR de las 200 distribuciones imagen C de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	3.410861638	2.381705236	2.681212769	2.188309173
20	1.866556655	1.469471276	1.284595364	1.233840086
30	1.781974066	1.016020313	1.049546171	0.999176678
40	1.895979731	0.832081043	0.888144223	0.738968455
50	1.835725556	0.838092182	0.726993308	0.668996463
60	1.694052702	0.772691042	0.736289924	0.637833726
70	1.499986719	0.93466256	0.794304186	0.665330375
80	1.486508815	0.914274405	1.110231353	0.70434928

B.2.20 Desviación estandar imagen F

Tabla B.32: Desviación estandar PSNR de las 200 distribuciones imagen F de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	3.405023233	1.983529617	3.149280771	2.740260985
20	1.654227947	1.198062496	1.564501375	1.758192791
30	1.198656071	0.807528055	1.15793513	1.173261992
40	1.041781374	0.672225234	0.905567448	1.005124396
50	0.765106841	0.557878849	0.693350686	0.832192206
60	0.798589614	0.525618565	0.662688618	0.69042758
70	0.777591885	0.524588152	0.520832703	0.580562954
80	0.63035584	0.577597176	0.522885005	0.490552311

B.2.21 Desviación estandar imagen G

Tabla B.33: Desviación estandar PSNR de las 200 distribuciones imagen G de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	4.561152625	3.007546126	2.395521529	2.200569765
20	3.355251254	1.475112131	1.25249249	1.128581124
30	2.919765853	0.995409907	1.063156805	0.966229099
40	2.643581987	0.919729199	0.95477292	0.853660534
50	2.261897592	0.805356455	0.922328824	0.784984666
60	1.770461361	0.778304255	0.913777693	0.754714599
70	1.612741533	0.781191508	0.93284372	0.709560671
80	1.198484739	0.681832937	1.016369041	0.568804497

B.2.22 Desviación estandar imagen L

Tabla B.34: Desviación estandar PSNR de las 200 distribuciones imagen L de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	2.182979844	1.492876483	0.900765438	1.054276343
20	1.257481526	0.920101281	0.718344089	0.799273917
30	1.007095216	0.698071856	0.628153596	0.664394696
40	0.85546817	0.593701692	0.501470394	0.486546029
50	0.720954062	0.514290575	0.49197703	0.42854844
60	0.629881113	0.405627757	0.42831676	0.419036178
70	0.560913278	0.389887174	0.443243152	0.419243972
80	0.572765008	0.407019945	0.482676319	0.437530358

B.2.23 Desviación estandar imagen P

Tabla B.35: Desviación estandar PSNR de las 200 distribuciones imagen P de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	0.984516257	1.628135685	1.124919561	1.501064016
20	0.681386811	0.907577389	0.690925783	1.003346039
30	0.687471169	0.835179701	0.609217072	0.710442168
40	0.703974012	0.642439284	0.458422175	0.591418332
50	0.562258407	0.606918222	0.474543425	0.471807782
60	0.650050704	0.606674396	0.469497487	0.484715581
70	0.621143349	0.553605641	0.497978779	0.43071869
80	0.567505052	0.605494864	0.475609792	0.508802882

B.2.24 Desviación estandar imagen S

Tabla B.36: Desviación estandar PSNR de las 200 distribuciones imagen S de acuerdo al porcentaje de Loss-Rate, por patrón escenario 1

Loss Rate (%)	SE	AG	AR	AT
10	2.433636834	2.307993456	1.725293769	1.12386384
20	1.647429954	1.177381639	1.007699862	0.68608437
30	1.656091201	0.884022741	0.8146201	0.628892319
40	1.494848517	0.700221378	0.641071328	0.601708249
50	1.497482347	0.618364958	0.657279419	0.578116583
60	1.452116376	0.571330618	0.623017857	0.626708183
70	1.688985361	0.638026042	0.631439028	0.643785224
80	1.558041499	0.831293983	0.83739074	0.772789311

B.3 Resultados VFCE v/s PSNR.

B.3.1 VFCE escenario 1.

Tabla B.37: Mejores VFCE alcanzados en evaluaciones del AG basados en otros métodos por SE, AG, AR y AT, aplicando el 20 % de Loss Rate, escenario 1.

Algoritmo	VFCR
SE	557.3333
AG	141.3333
AR	112.6667
AT	114

B.3.2 PSNR escenario 1.

Tabla B.38: Mejores PSNR alcanzados en evaluación de patrones mediante simulaciones por patrón SE, AG, AR y AT, imagen Baboon, aplicando el 20 % de Loss Rate, escenario 1.

Algoritmo	PSNR
SE	28.614506
AG	29.124529
AR	28.050414
AT	28.707987

B.3.3 VFCR escenario 5.

Tabla B.39: Mejores VFCR alcanzados en evaluaciones del AG basados en otros métodos por SE, AG, AR y AT, aplicando el 20 % de Loss Rate, escenario 5.

Algoritmo	VFCR
SE	898.7805
AG	244.3707
AR	206.7951
AT	522.9854

B.3.4 PSNR escenario 5.

Tabla B.40: Mejores PSNR alcanzados en evaluación de patrones mediante simulaciones por patrón SE, AG, AR y AT, imagen Baboon, aplicando el 20 % de Loss Rate, escenario 5.

Algoritmo	PSNR
SE	27.018915
AG	27.559811
AR	27.845278
AT	27.610477