

# Analysis of the Image Quality in a Multiobjective Context based on SMPSO-CLAHE

Adriana Coronel S.  
Universidad Nacional de Asunción  
Facultad Politécnica  
San Lorenzo, Paraguay  
Email: adrianapy04@gmail.com

Monserrat Mora B.  
Universidad Nacional de Asunción  
Facultad Politécnica  
San Lorenzo, Paraguay  
Email: monserratmorab@gmail.com

Ms. Luis G. Moré R.  
Universidad Nacional de Asunción  
Facultad Politécnica  
San Lorenzo, Paraguay  
Email: lmore@pol.una.py

PhD. Diego Pinto-Roa  
Universidad Nacional de Asunción  
Facultad Politécnica  
San Lorenzo, Paraguay  
Email: dpinto@pol.una.py

Ms. José L. Vázquez N.  
Universidad Nacional de Asunción  
Facultad Politécnica  
San Lorenzo, Paraguay  
Email: jlvazquez@pol.una.py

**Abstract**—Searching for adequate input parameters of a Contrast Enhancement Algorithm is a fundamental task, aimed to get more suitable images, in terms of contrast, for decision making or further applications. Several Optimization approaches take a single image as the input of the process, so they get poor performance. In this proposal, a group of several images of the same type are taken as input of a Robust Multi-Objective Particle Swarm Optimization approach, in order to achieve more suitable input parameters for a kind of images, instead of a single image. The results are a set of input parameters for the Contrast Enhancement Algorithm, suitable for Contrast Enhancement of a group of images of the same type.

**Index Terms**— Contrast Improvement, CLAHE, SMPSO, Local Entropy, SSIM, Multi-objective Optimization

## I. INTRODUCCIÓN

Las imágenes digitales están expuestas a sufrir una variedad de distorsiones durante su procesamiento, compresión, almacenamiento, transmisión y reproducción, cualquiera de estas puede resultar en la degradación de la calidad visual [3].

Aunque el campo de procesamiento digital de imágenes está construido sobre una base de formulaciones matemáticas y probabilísticas, la intuición y el análisis humano juegan un papel central en la elección de una técnica frente a otra. Esta elección se hace a menudo sobre la base de juicios subjetivos visuales, por lo tanto, se necesitan conseguir medidas cuantitativas que puedan valorar de forma objetiva la calidad de la imagen percibida.

El histograma de una imagen *HE* [4] es ampliamente utilizado como herramienta tanto cualitativa como cuantitativa, es una buena herramienta para la mejora de contraste. Sin embargo, éste y la mayoría de los otros métodos de mejora de contraste pueden producir imágenes de aspecto no natural, lo que ocasiona que aquellas obtenidas por estos métodos no sean las deseables.

Existen varias técnicas de mejoras de contraste basadas en *HE*, usando técnicas de optimización con el uso de Algoritmos

Genéticos [5], la Lógica Difusa [6], Sintonización de Parámetros de *CLAHE* basado en Optimización Por Enjambres de Partículas [7].

El objetivo de la optimización es encontrar una solución que represente el valor óptimo para una función objetivo. La optimización multi-objetivo no se restringe a la búsqueda de una única solución, sino de un conjunto de soluciones que representan los mejores compromisos entre los distintos criterios, llamados **soluciones no-dominadas** o **Conjunto Pareto Óptimo** con el fin de ofrecer al algoritmo que tomará las decisiones las mejores alternativas entre las disponibles, para que este último seleccione una de ellas [8].

Dado que las soluciones óptimas de Pareto dominan colectivamente cualquier otra solución factible en el espacio de búsqueda, todas se consideran mejores que cualquier otra solución. Se dice que una solución domina a otra solución si no es peor en ninguno de los objetivos y es estrictamente mejor en al menos uno de los objetivos. Para calificar como una solución robusta, cada solución óptima de Pareto ahora tiene que demostrar su insensibilidad frente a pequeñas perturbaciones en sus valores de variables de decisión [25].

En la literatura, los enfoques de mejora local demuestran ser sumamente útiles al momento de resaltar detalles en imágenes con gran cantidad de detalles finos. Existen diversas propuestas que se centran en mejorar el contraste en radiografías [9], [10], [11]. Debido a ello, en esta propuesta se realiza un análisis para la selección de métricas de calidad a utilizar en el Optimizador de Parámetros de *CLAHE*, de manera a identificar las métricas más adecuadas para el proceso de Optimización Multi-Objetivo de parámetros de mejora de contraste de la imagen.

Luego, se aplicará una metaheurística de optimización de objetivos *SMPSO* [2], de manera a sintonizar los parámetros de entrada del algoritmo de mejora del contraste *CLAHE* [1] en un contexto de robustez, de manera a obtener un grupo de imágenes contrastadas, las cuales serán evaluadas en cuanto a

la ganancia de información proveída y distorsión introducida por la ecualización. Éste proceso busca encontrar un conjunto de parámetros de entrada del algoritmo de mejora de contraste que puedan considerarse óptimos en un contexto de robustez.

El resto del trabajo se organiza de la siguiente manera: En la sección II se describen las métricas de evaluación de calidad que fueron objeto de análisis; en la sección III se plantea de manera formal el problema que se intenta resolver; en la sección IV se describe la selección de las métricas de evaluación de calidad y la metaheurísticas de optimización robusta; en la sección V se discuten los resultados obtenidos, y finalmente en la sección VI se detallan las conclusiones correspondientes.

## II. MÉTRICAS DE EVALUACIÓN DE IMÁGENES

Existen varios mecanismos para determinar la calidad de la imagen, generalmente asociados a una medida comparativa frente a una referencia. Se realiza una selección de alternativas a partir de la necesidad de encontrar métricas que proporcionen el mejor balance entre mejora del contraste y distorsión.

### II-A. Entropía

La Entropía de la Información es un concepto definido originalmente por Shannon [12]. La *Entropía* nos indica la riqueza de los detalles de una imagen. Cuanto más cercano sea el valor de la entropía de la imagen resultante con respecto a la imagen original, se puede decir que los detalles de la imagen se han conservado [13].

Matemáticamente se lo define como:

$$\mathcal{H} = - \sum_{k=0}^{L-1} \mathcal{P}_k \log_2(\mathcal{P}_k) \quad \mathcal{H} \in [0, \log_2(L-1)] \quad (1)$$

- $\mathcal{P}_k = \frac{n_k}{Z}$ , donde  $n_k$  es la cantidad de ocurrencias del  $k$ -ésimo nivel de gris y  $Z$  la cantidad total de píxeles, en la imagen;
- $L-1$  es el máximo nivel de gris que se puede utilizar para representar la imagen

### II-B. Entropía Local

La *Entropía Local* [14] está relacionada con la variación de los niveles de gris en la vecindad de un pixel. Divide la imagen en bloques y luego analiza cada bloque como fuente de información separada. Mide la aleatoriedad de la imagen calculando la media de la muestra de la *Entropía* sobre una serie de bloques no superpuestos de la imagen y seleccionados al azar, debido a esto es capaz de superar algunas debilidades de la Entropía de Shannon [15].

Matemáticamente se lo define como:

$$E(\nu_k) = \sum_{j=0}^{L-1} \mathcal{P}_j \log_2\left(\frac{1}{\mathcal{P}_j}\right) \quad (2)$$

$$\mathcal{E}(f) = \sum_{i=1}^T \frac{E(\nu_k)}{T} \quad (3)$$

Donde:

- $\nu_k$  representa una vecindad de tamaño  $M_k \times N_k$  de una imagen;
- $\mathcal{P}_j = \frac{n_j}{M_k \times N_k}$  denota la probabilidad del nivel de gris de  $j$  en la vecindad  $\nu_k$ , donde  $n_j$  es la cantidad de ocurrencias del  $i$ -ésimo nivel de gris  $J$  en  $\nu_k$ ;
- $E(\nu_k)$  representa la Entropía local de  $(\nu_k)$ ;
- $f$  representa la imagen;
- $T$  es cantidad de bloques en que se dividió la imagen, y
- $\mathcal{E}(f)$  representa la Entropía local de la imagen  $f$ .

### II-C. Índice de Similitud Estructural (SSIM)

El *SSIM* [16] pretende cuantificar de forma numérica y automática la calidad visual de una imagen para un observador humano, comparando entre la imagen original y reconstruida en cuanto a sus luminancias, contrastes e información de estructura; proporciona un valor de calidad acotado entre 0 y 1. Matemáticamente se lo define como:

$$SSIM(f, f') = \frac{(2\mu_f \mu_{f'} + C_1)(2\sigma_{ff'} + C_2)}{(\mu_f^2 + \mu_{f'}^2 + C_1)(\sigma_f^2 + \sigma_{f'}^2 + C_2)} \quad (4)$$

Donde:

- $\mu_f$  es el promedio de intensidades de  $f$ ;
- $\mu_{f'}$  es el promedio de intensidades de  $f'$ ;
- $\sigma_f^2$  y  $\sigma_{f'}^2$  son las varianzas de intensidades de  $f$  e  $f'$ , respectivamente;
- $\sigma_{ff'}$  es la covarianza entre  $f$  e  $f'$ ;
- $C_1 = (K_1 L^2)$ ,  $K_1 \ll 1$  es una constante pequeña;
- $C_2 = (K_2 L)^2$ , y  $K_2 \ll 1$ ;
- tanto  $C_1$  y  $C_2$  son constantes que se usan para estabilizar la división en caso de que el denominador tienda a cero.

### II-D. Local Tuned Global Model (LTG)

El modelo *LTG* [17] es un enfoque basado en el gradiente de la imagen, ya que ésta es muy sensible a las distorsiones de la misma; así también extrae información sobre la luminancia (brillo percibido por el ojo humano) y la crominancia (información del color) de la imagen de entrada y la imagen distorsionada, luego mide la distorsión local resaltante y la degradación global de la calidad en la información obtenida sobre la luminancia y compara las diferencias en la información obtenida sobre la crominancia, derivando así el valor global de la calidad de la imagen [18].

La magnitud del gradiente para una imagen  $f$  está definida por:

$$G = \sqrt{G_h^2 + G_v^2} \quad (5)$$

Donde:

- $G_h$  y  $G_v$  son las derivadas parciales de la imagen a lo largo de las direcciones horizontal y vertical utilizando el operador Scharr [18].

$$LTG(f, f') = \frac{\Phi(G_s^{\theta_1})}{\Phi(G_m^{\theta_2})} \Phi(I_m^{\theta_3} \cdot Q_m^{\theta_3}) \quad (6)$$

Donde:

- $G_m$  es el gradiente medio de la imagen original y distorsionada;

- $G_s$  indica los píxeles con valores  $s\%$  más altos en  $G_m$ ;
- $I_m$  and  $Q_m$  indica la información de crominancia de la imagen original y distorsionada.
- $\theta_1, \theta_2, \theta_3$  ( $\theta_1 > \theta_2$ ) son parámetros del modelo.

### III. PLANTEAMIENTO DEL PROBLEMA

En el tratamiento de imágenes, frecuentemente es necesario detectar características de interés que pueden ser utilizadas para un análisis posterior, por ello es necesario ajustar la apariencia de la imagen. Por ejemplo, con la mejora de contraste, se resaltan ciertas características para el ojo humano. La selección correcta de las métricas para la evaluación de la calidad de la imagen, que permita evaluar la ganancia o pérdida de información, así como la distorsión en la misma, en el contexto de mejora de contraste, y que esto nos posibilite establecer un criterio objetivo de calidad, es el ideal buscado; así como también obtener una solución óptima para un grupo de imágenes del mismo tipo, para lo cual se deben diseñar los algoritmos de optimización multiobjetivo.

#### III-A. Contrast Limited Adaptive Histogram Equalization (CLAHE)

CLAHE [1] se basa en la ecualización adaptativa del histograma AHE (por sus siglas en inglés *Adaptive Histogram Equalization*) [19], [20], [21], ambos métodos procesan la imagen por subregiones (regiones rectangulares de la imagen), o *regiones contextuales*, con dimensiones de región definidas como  $(\mathcal{R}_i, \mathcal{R}_j)$ , sobre las cuales se aplica el procedimiento de ecualización de forma independiente, mejorando localmente el contraste [22].

CLAHE es un refinamiento de AHE donde el cálculo de realce se modifica imponiendo un máximo especificado por el usuario, llamado nivel del Clip Limit  $\mathcal{C}$ , a la altura del histograma local, y por lo tanto sobre el factor de mejora del contraste máximo. La mejora se reduce de este modo en zonas muy uniformes (en términos de contraste) de la imagen, lo que evita un aumento excesivo del ruido y resuelve el problema de “sobrecontraste” del AHE.

### IV. PROPUESTA

#### IV-A. Selección de métricas.

Se buscan métricas cuyos valores sean los más adecuados, de manera a obtener un resultado satisfactorio con respecto a la contradicción existente entre mejora del contraste y distorsión de la imagen en escala de grises.

Dados la imagen de entrada  $f_1$ , de tamaño  $M \times N$  y el algoritmo CLAHE, se desea calcular la mejor solución que nos indique que dichas métricas son altamente contradictorias, minimizando la correlación de las funciones objetivo  $T_A$  y  $T_B$ , tal que:

$$\min(\gamma_{T_A T_B}) \quad (7)$$

Donde:

- $\gamma$  es la correlación entre  $T_A$  y  $T_B$ .
- $T_A \in [\mathcal{H}, \mathcal{E}]$ .

Tabla I: Resultados de la correlación de Pearson usando Entropía  $\mathcal{H}$ , Entropía Local  $\mathcal{E}$ , SSIM y LTG

	$\mathcal{H}/\text{SSIM}$	$\mathcal{E}/\text{SSIM}$	$\mathcal{H}/\text{LTG}$	$\mathcal{E}/\text{LTG}$
Tórax frontal 1	-0.96144	<b>-0.98922</b>	-0.94591	-0.97524
Tórax frontal 2	-0.96593	<b>-0.98262</b>	-0.96956	-0.96667
Tórax frontal 3	-0.90827	-0.98688	-0.76528	<b>-0.98991</b>
Tórax frontal 4	-0.94637	<b>-0.98674</b>	-0.93997	-0.97990
Tórax frontal 5	-0.97756	<b>-0.99421</b>	-0.95371	-0.99215
Tórax frontal 6	-0.95388	<b>-0.98591</b>	-0.93648	-0.97583
Tórax frontal 7	-0.93398	<b>-0.99384</b>	-0.92731	-0.98412
Tórax frontal 8	-0.93753	<b>-0.98069</b>	-0.95158	-0.97246
Tórax frontal 9	-0.97092	<b>-0.98479</b>	-0.95007	-0.96898
Tórax frontal 10	-0.97623	<b>-0.98317</b>	-0.95824	-0.97025
Tórax frontal 11	-0.96056	<b>-0.98899</b>	-0.92036	-0.98069
Tórax lateral 1	-0.97190	<b>-0.99063</b>	-0.95249	-0.97182
Tórax lateral 2	-0.94089	<b>-0.98513</b>	-0.91902	-0.98113
Tórax lateral 3	-0.96688	<b>-0.98144</b>	-0.87671	-0.96848
Tórax lateral 4	-0.95489	<b>-0.98424</b>	-0.94559	-0.97289
Tórax lateral 5	-0.95628	<b>-0.98503</b>	-0.88451	-0.97466
Tórax lateral 6	-0.97777	<b>-0.98377</b>	-0.92698	-0.97129
Tórax lateral 7	-0.95915	<b>-0.98538</b>	-0.92323	-0.97565
Tórax lateral 8	-0.96441	<b>-0.98168</b>	-0.94855	-0.97541
Tórax lateral 9	-0.95236	<b>-0.98963</b>	-0.93932	-0.93272

- $T_B \in [\text{SSIM}, \text{LTG}]$ .

Se hace uso de la correlación de Pearson [23]; cuyo índice se utiliza para medir el grado de relación de dos métricas distintas, siempre y cuando ambas sean cuantitativas. El valor del índice de correlación varía en el intervalo  $[-1, 1]$ , entonces:

$$-1 < \gamma_{xy} < 1 \quad (8)$$

Donde:

- Si  $\gamma = 1$ , existe una correlación positiva perfecta. Cuando una de ellas aumenta, la otra también lo hace en proporción constante.
- Si  $0 < \gamma < 1$ , existe una correlación positiva.
- Si  $\gamma = 0$ , no existe relación lineal.
- Si  $-1 < \gamma < 0$ , existe una correlación negativa.
- Si  $\gamma = -1$ , existe una correlación negativa perfecta. El índice indica que existe una relación inversa entre las dos variables: cuando una de ellas aumenta, la otra disminuye en proporción constante.

Los resultados obtenidos de las correlaciones entre los pares de métricas utilizados se muestran en la **Tabla I**. Los valores marcados en negrita demuestran la fuerte relación inversa lineal existente entre los pares de métricas, lo cual indica que estos pares de métricas se complementan para mantener el compromiso entre aumento de contraste y minimización de la distorsión.

#### IV-B. Mejora del contraste basada en una Metaheurística de Optimización Robusta.

Se realiza la optimización multiobjetivo, dado un conjunto de imágenes de prueba con sus correspondientes imágenes mejoradas, tomando las métricas obtenidas como resultado de la Correlación de Pearson, representadas en  $T_A$  y  $T_B$ , durante el proceso.

Se utiliza la metaheurística *SMPSO* [2], que es el encargado de generar los valores para los parámetros de entrada del algoritmo *CLAHE*( $f, x$ ), donde  $f$  es la imagen a ser mejorada y las soluciones potenciales  $x$  se denominan *partículas* y se definen de la siguiente manera:

$$x = (\mathcal{R}_i, \mathcal{R}_j, \mathcal{C}) \quad (9)$$

y el conjunto de partículas  $\Omega$  se denomina *enjambre*. Cada partícula  $i$  se actualiza en cada generación  $t$  de acuerdo a la siguiente ecuación:

$$\chi_i^{t+1} = \chi_i^t + v_i^{t+1} \quad (10)$$

Donde el factor  $\vec{v}_i^t$  se conoce como la velocidad y está dado por:

$$v_i^{t+1} = \omega v_i^t + \varphi_1 \times rand_1 \times (\rho Best_i - \chi_i^t) + \varphi_2 \times rand_2 \times (g_i - \chi_i^t) \quad (11)$$

$\rho Best_i$  es la mejor solución encontrada por la partícula  $i$  hasta el momento,  $g_i$  es la mejor partícula (también conocida como *líder*) que se encuentra en todo el enjambre,  $\omega$  es el peso de la inercia de la partícula,  $r_1, r_2$  son dos números aleatorios entre 0 y 1, y  $\varphi_1, \varphi_2$  son parámetros que controlan el efecto de las partículas locales y globales.

Se incorpora un mecanismo de restricción, (veáse Ecuación 12) sobre la ecuación 11 para limitar la velocidad máxima de las partículas y mejorar la capacidad de búsqueda del algoritmo [2].

$$\kappa = \frac{2}{2 - \sigma - \sqrt{\sigma^2 - 4\sigma}} \quad (12)$$

Donde:

$$\sigma = \begin{cases} \varphi_1 + \varphi_2 & \text{si } \varphi_1 + \varphi_2 > 4 \\ 0 & \text{si } \varphi_1 + \varphi_2 \leq 4 \end{cases} \quad (13)$$

Además, se introduce un mecanismo de tal manera que la velocidad acumulada de cada variable  $j$  (en cada partícula  $\rho_i$ ) esté limitada por medio de la siguiente ecuación de restricción de velocidad:

$$v_{i,j}^t = \begin{cases} \delta_j & \text{si } v_{i,j}^t > \delta_j \\ -\delta_j & \text{si } v_{i,j}^t \leq -\delta_j \\ v_{i,j}^t & \text{para otros casos} \end{cases} \quad (14)$$

Donde:

$$\delta_j = \frac{\text{maximo}_j - \text{minimo}_j}{2} \quad (15)$$

para:

- $\text{maximo}_j$  = máximo valor para la variable  $j$  a optimizar.
- $\text{minimo}_j$  = mínimo valor que puede tomar la variable  $j$ .

Con el enfoque *SMPSO*, la velocidad de las partículas  $\rho_i$  se calcula de acuerdo con la (ecuación 11); la velocidad resultante se multiplica por el factor de restricción de la

(ecuación 12) y el valor resultante se limita usando la (ecuación 14).

Dado el conjunto de imágenes de entrada  $F = \{f_1, f_2, f_3, f_4, \dots, f_n\}$  el algoritmo busca calcular el conjunto de soluciones no dominadas  $X = \{x_1, x_2, x_3, \dots, x_m\}$ , tal que se maximice simultáneamente las siguientes funciones objetivo:

$$\overline{\mathcal{E}}_i = \sum_{k=1}^m \mathcal{E}(f'_{ki}); \quad (16)$$

$$\overline{SSIM}_i = \sum_{k=1}^m SSIM(f'_{ki}); \quad (17)$$

Donde:

- $x_i = (\mathcal{R}_x, \mathcal{R}_y, \mathcal{C})$ , es la  $i$ -ésima partícula.
- $f'_{ki} = \text{CLAHE}(f_k, x_i) \quad \forall k, i$

Sujeto a:

$$\mathcal{R}_x \in [2, M] \quad \forall \mathcal{R}_x \in \mathbb{N} \quad (18)$$

$$\mathcal{R}_y \in [2, N] \quad \forall \mathcal{R}_y \in \mathbb{N} \quad (19)$$

$$\mathcal{C} \in (0, 1] \quad \forall \mathcal{C} \in \mathbb{R} \quad (20)$$

El pseudocódigo del *SMPSO-CLAHE* se presenta en el Algoritmo 1.

---

#### Algoritmo 1 Algoritmo *SMPSO-CLAHE*.

---

**Entrada:** conjunto de imágenes  $F$ , número de partículas, cantidad de líderes, número de iteraciones  $t$ .

- 1: inicializarEnjambre().
  - 2: inicializarConjuntoPareto().
  - 3: iteracionActual=0
  - 4: **mientras** iteracionActual <  $t$  **hacer**
  - 5:   calcularVelocidad().
  - 6:   actualizarPosicion().
  - 7:   mutacion().
  - 8:   evaluacion().
  - 9:   actualizarConjuntoPareto()
  - 10:   actualizarParticulas()
  - 11:   generacion ++
  - 12: **fin mientras**
  - 13: **Retornar:** Conjunto Pareto  $X$
- 

A continuación, se describe el funcionamiento del algoritmo 1 *SMPSO-CLAHE*.

- **Entrada:** se reciben los datos para inicializar los parámetros necesarios para el funcionamiento del algoritmo *SMPSO*.
- **Línea 1:** Se inicializa el enjambre, que incluye la posición, la velocidad y la mejor posición individual de las partículas.
- **Línea 2:** Se inicializa el Conjunto Pareto con los valores de cantidad de líderes y cantidad de objetivos.
- **Línea 3:** Se inicializa la iteración (generación inicial).

- Línea 4: Se ejecuta el bucle principal del algoritmo hasta que se cumpla el criterio de parada que en este caso es una cantidad máxima de iteraciones ( $t$ ).
- Línea 5: Se calcula la velocidad de cada partícula.
- Línea 6: Se calcula y actualiza la posición de cada partícula.
- Línea 7: Se aplica un operador de mutación con una probabilidad dada.
- Línea 8: Se evalúan las partículas resultantes utilizando las métricas de calidad (Ecuaciones 16 y 17).
- Línea 9 y 10 : Se actualizan tanto las partículas como el archivo de líderes.
- Línea 13: El algoritmo devuelve el archivo de líderes como el conjunto de aproximación encontrado.

## V. RESULTADOS Y DISCUSIÓN

Las pruebas se realizaron empleando 30 imágenes radiológicas previamente digitalizadas del tórax obtenidas del sitio <https://openi.nlm.nih.gov/>. Las mismas se seleccionaron a partir de la cantidad de detalles que poseen, lo que representa un desafío adecuado para la *mejora del contraste*.

Durante el proceso previo de optimización se realizaron 30 ejecuciones por cada imagen de prueba. Se obtuvieron aproximadamente 300 imágenes soluciones Pareto por cada una de ellas, las cuales fueron nuevamente filtradas una vez terminadas las ejecuciones.

Los resultados experimentales obtenidos en **Tabla II** muestran que los pares de métricas *Entropía local/SSIM* demuestran ser los más contradictorios según la correlación obtenida, esto indica que el mejoramiento de una función objetivo es logrado a costa del empeoramiento de la otra función objetivo en un contexto de minimización o maximización de ambas.

Tabla II: Promedio de la correlación de Pearson.

Métricas	Correlación
Entropía / SSIM	-0.9554
Entropía Local / SSIM	<b>-0.9870</b>
Entropía / LTG	-0.9319
Entropía Local / LTG	-0.9731

En la **Figura 1** se muestran dos de las soluciones, correspondientes a una imagen de tórax lateral, que se encuentran en el Conjunto Pareto para las métricas *Entropía Local/SSIM*, además de las imágenes originales como referencia visual.

La relación inversa entre las métricas se refleja en los resultados obtenidos. A partir de la Figura 1(c) se observa que a medida que la métrica *SSIM* se aproxima a **1** los resultados se asemejan más a la imagen original, Figura 1(a), en términos de contraste, y de visibilidad de detalles; en cambio, mientras la *Entropía Local* aumenta se diferencian más los detalles no visibles debido al bajo contraste, Figura 1(b).

Las imágenes que conforman el Conjunto Pareto resaltan distintos detalles a medida que los objetivos varían, lo cual se logra a partir de que se asegura la selección de las métricas más adecuadas para la optimización, basada en el análisis descrito anteriormente.



(a)  $SSIM = 1$   $\mathcal{E} = 2,8157$  (b)  $SSIM = 0,8871$   $\mathcal{E} = 3,4791$  (c)  $SSIM = 0,9016$   $\mathcal{E} = 3,4296$

Figura 1: Tórax lateral 2.

Imagen Original 1(a), Imágenes resultantes 1(b) y 1(c)

Las imágenes se dividieron en dos grupos, el primer grupo A, imágenes de tórax lateral y el segundo grupo B, imágenes de tórax frontal.

Se analizó el comportamiento del Conjunto Pareto resultante de cada imagen procesada, por cada grupo, al considerar como una sola entrada el conjunto de todas las imágenes y realizar el cálculo de la Entropía Local II-B y SSIM II-C entre todas las imágenes; de esta forma se obtuvieron dos *Frentes Pareto Robusto*, uno para el grupo A como se observa en la Figura 2 y en la Figura 4 y otro para el grupo B como se observa en la Figura 6 y en la Figura 8.

En la **Figura 2** y en la **Figura 4** se aprecia que las formas de ambos frentes son similares, tanto el Frente Pareto óptimo como el Frente Pareto robusto; aunque un frente se desplaza con respecto al otro. El Frente Pareto robusto está claramente retrasado, como se puede ver tanto en la **Figura 2** como en la **Figura 4**, lo que nos indica que el Frente Pareto robusto no es el óptimo.

Además se verifica que el Frente Pareto robusto cae en su óptimo con respecto a la optimización realizada sobre una sola imagen, pero en general se comporta de manera satisfactoria para el grupo de imágenes analizadas. Con esto también se observa que la solución óptima de una imagen  $f$  no necesariamente es la mejor solución para una imagen  $f_n$ .

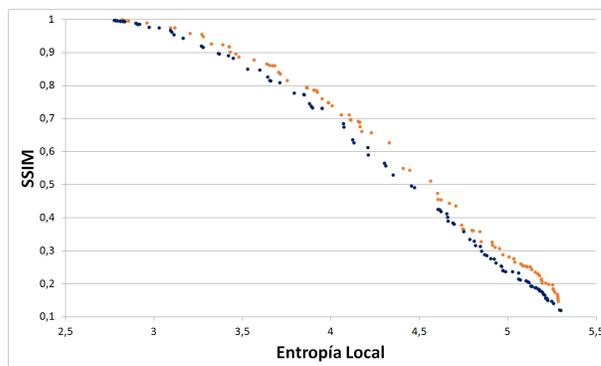
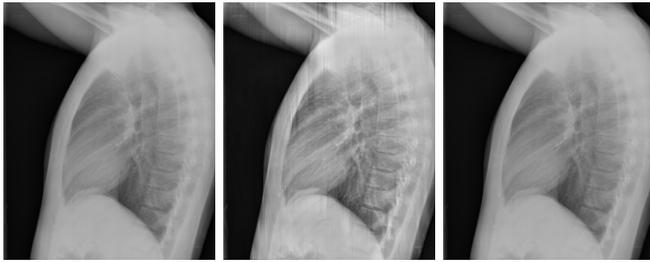


Figura 2: Frente Pareto  $\mathcal{E}/SSIM$ . Tórax lateral 2.

- ⊗ Frente Pareto robusto
- ⊗ Frente Pareto óptimo

Así mismo en la **Figura 3** se muestran dos de las soluciones que se encuentran en el conjunto Pareto para las métricas *Entropía Local/SSIM*.



(a)  $SSIM = 1$   $\mathcal{E} = 2,9594$  (b)  $SSIM = 0,9206$   $\mathcal{E} = 3,5748$  (c)  $SSIM = 0,9986$   $\mathcal{E} = 2,9748$

Figura 3: Tórax Lateral 7.

Imagen Original 3(a), Imágenes resultantes 3(b) y 3(c)

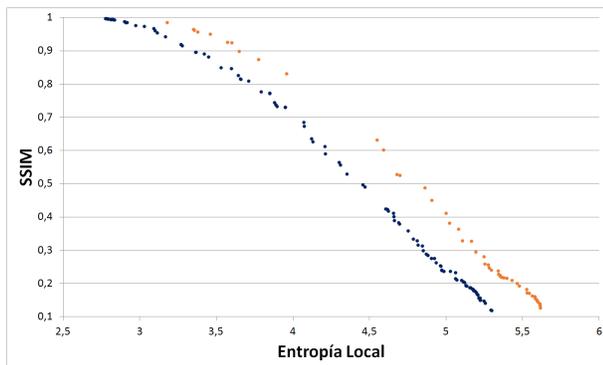


Figura 4: Frente Pareto  $\mathcal{E}/SSIM$ . Tórax lateral 7.

- ⊗ Frente pareto robusto
- ⊗ Frente pareto óptimo

También en la **Figura 5** y en la **Figura 7** se muestran dos de las soluciones que se encuentran en el conjunto Pareto para las métricas *Entropía Local/SSIM*, con sus respectivas imágenes originales como referencia visual.



(a)  $SSIM = 1$   $\mathcal{E} = 3,4754$  (b)  $SSIM = 0,7402$   $\mathcal{E} = 4,5639$  (c)  $SSIM = 0,9724$   $\mathcal{E} = 3,8264$

Figura 5: Tórax Frontal 1.

Imagen Original 5(a), Imágenes resultantes 5(b) y 5(c)

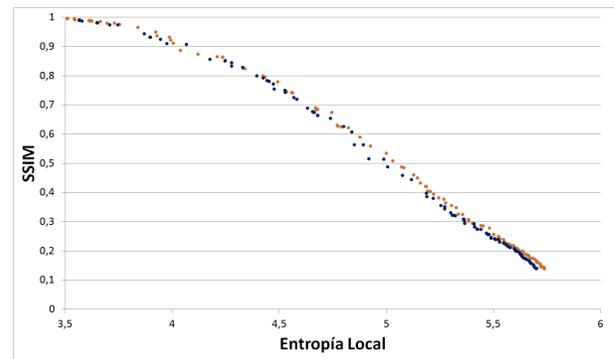
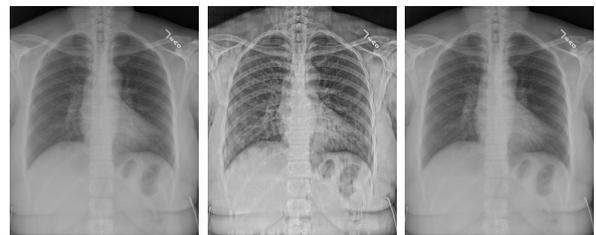


Figura 6: Frente Pareto  $\mathcal{E}/SSIM$ . Tórax frontal 1.

- ⊗ Frente pareto robusto
- ⊗ Frente pareto óptimo



(a)  $SSIM = 1$   $\mathcal{E} = 3,3196$  (b)  $SSIM = 0,8227$   $\mathcal{E} = 4,3786$  (c)  $SSIM = 0,9979$   $\mathcal{E} = 3,4106$

Figura 7: Tórax Frontal 8.

Imagen Original 7(a), Imágenes resultantes 7(b) y 7(c)

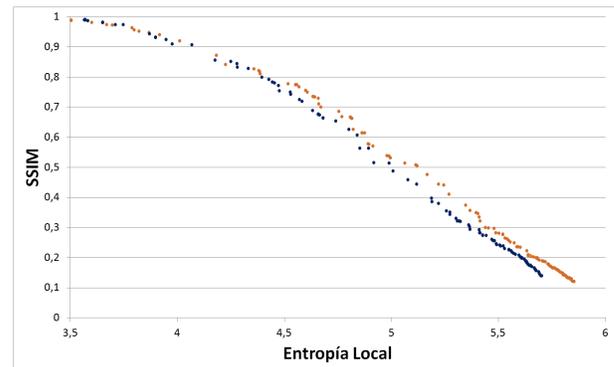


Figura 8: Frente Pareto  $\mathcal{E}/SSIM$ . Tórax Frontal 8.

- ⊗ Frente pareto robusto
- ⊗ Frente pareto óptimo

## VI. CONCLUSIONES Y TRABAJOS FUTUROS

Se analizaron varias métricas para determinar la calidad de la imagen, basados en un enfoque de referencia completa, se seleccionaron 4 métricas, las cuales se trabajaron de a pares *Entropía/SSIM*, *Entropía local/SSIM*, *Entropía/LTG* y *Entropía local/LTG*, junto a un algoritmo metaheurístico *SMPSO* y el algoritmo *CLAHE*, con el objetivo de obtener las métricas

que maximicen el contraste y minimicen la distorsión de la imagen de manera simultánea.

A partir de las pruebas realizadas y de los resultados obtenidos, se pueden considerar las siguientes conclusiones:

- Los resultados experimentales obtenidos en **Tabla II** muestran que los pares de métricas *Entropía local/SSIM* demuestran ser los más contradictorios según la correlación obtenida, por tanto son más adecuado para incorporar a un proceso de optimización.
- Los resultados de las imágenes generales para SMPSO-CLAHE muestran una mejora en el contraste, manteniendo la apariencia natural de las mismas. Este algoritmo se muestra aplicable tanto en imágenes médicas o biométricas, mostrando resultados satisfactorios.
- Este trabajo es un caso general del trabajo de Moré y Brizuela [7], cuyos resultados caen en el frente pareto de esta propuesta, y cuya solución corresponde a la mínima similaridad. No se consideraron pruebas experimentales debido a que son enfoques diferentes.

Como trabajos futuros de manera a seguir con esta tesis de grado se propone:

- Utilizar la implementación *SMPSO-CLAHE* con otras métricas de evaluación de calidad y hallar el índice de correlación.
- Utilizar otros índices de Correlación y realizar una comparación con la utilizada en este trabajo.
- Analizar el desempeño de esta propuesta en imágenes de otra naturaleza.

## REFERENCIAS

- [1] Zuiderveld, K. (1994, August). Contrast limited adaptive histogram equalization. In Graphics gems IV (pp. 474-485). Academic Press Professional, Inc..
- [2] Nebro, A. J., Durillo, J. J., Garcia-Nieto, J., Coello, C. C., Luna, F., and Alba, E. (2009, March). Smpso: A new pso-based metaheuristic for multi-objective optimization. In Computational intelligence in multi-criteria decision-making, 2009. mcdm'09. ieeee symposium on (pp. 66-73). IEEE.
- [3] Roman-Gonzalez, A. (2012). Digital Images Analysis. Revista ECIPeru, 9(1), 61-68.
- [4] Poddar, S., Tewary, S., Sharma, D., Karar, V., Ghosh, A., & Pal, S. K. (2013). Non-parametric modified histogram equalisation for contrast enhancement. IET Image Processing, 7(7), 641-652.
- [5] Hashemi, Sara, et al. An image contrast enhancement method based on genetic algorithm. Pattern Recognition Letters 31.13 (2010): 1816-1824.
- [6] Jenifer, Sheeba, S. Parasuraman, and Amudha Kadirvelu. Contrast enhancement and brightness preserving of digital mammograms using fuzzy clipped contrast-limited adaptive histogram equalization algorithm. Applied Soft Computing 42 (2016): 167-177.
- [7] Moré, L. G., and M. A. Brizuela. "PSO applied to parameter tuning of CLAHE based on Entropy and Structural Similarity Index."
- [8] Coello, Carlos A. A short tutorial on evolutionary multiobjective optimization". International Conference on Evolutionary Multi-Criterion Optimization. (2001).
- [9] Frosio, Iuri, and N. Alberto Borghese. Real time enhancement of cephalometric radiographies."3rd IEEE International Symposium on Biomedical Imaging: Nano to Macro, 2006. IEEE, 2006. (pp. 972-975). IEEE. doi:10.1109/ISBI.2006.1625082.
- [10] Mou, Xuanqin, and Min Zhang. "Nonlinear multi-scale contrast enhancement for chest radiograph."2008 15th IEEE International Conference on Image Processing. IEEE, 2008. doi:10.1109/ICIP.2008.4712472.
- [11] Parveen, N. Ravia Shabnam, and M. Mohammed Sathik. Enhancement of bone fracture images by equalization methods. Computer Technology and Development, 2009. ICCTD'09. International Conference on. Vol. 2. IEEE, 2009. doi:10.1109/ICCTD.2009.115.
- [12] Shannon, Claude Elwood. A mathematical theory of communication. The Bell System Technical Journal, 1948.
- [13] Daumas Ladouce, Federico J. and Jara G., Diana E. Ecuación del histograma en un contexto Multiobjetivo Pareto, 2016.
- [14] Maji, Pradipta, et al., eds. Pattern Recognition and Machine Intelligence: 5th International Conference, PReMI 2013, Kolkata, India, December 10-14, 2013. Proceedings. Vol. 8251. Springer, 2013.
- [15] Wu, Zhou, Saveriades, Agaian, Noonan, Natarajan. Local Shannon Entropy Measure with Statistical Tests for Image Randomness.
- [16] Wang, Zhou, et al. Image quality assessment: from error visibility to structural similarity. IEEE transactions on image processing 13.4 (2004): 600-612.
- [17] Gu, Ke, et al. An efficient color image quality metric with local-tuned-global model."2014 IEEE International Conference on Image Processing (ICIP). IEEE, 2014.
- [18] Jähne, Bernd, Horst Haussecker, and Peter Geissler, eds. Handbook of computer vision and applications. Vol. 2. San Diego: Academic Press, 1999.
- [19] KETCHAM, David J.; LOWE, Roger W.; WEBER, J. William. Image enhancement techniques for cockpit displays. HUGHES AIRCRAFT CO CULVER CITY CA DISPLAY SYSTEMS LAB, 1974.
- [20] PIZER, Stephen M., et al. Adaptive histogram equalization and its variations. Computer vision, graphics, and image processing, 1987, vol. 39, no 3, p. 355-368.
- [21] KURAK JR, Charles W. Adaptive histogram equalization, a parallel implementation. 1990.
- [22] Lee, Chulwoo and Lee, Chul and Kim, Chang-Su. Contrast Enhancement Based on Layered Difference Representation of 2D Histograms. IEEE Transactions on Image Processing, 2013.
- [23] NIEVES HURTADO, A. N. T. O. N. I. O., Domínguez Sánchez, and FEDERICO CLICERO. "Probabilidad y Estadística para Ingeniería, un enfoque moderno."México DF: McGra-Hill (2010).
- [24] Durillo, J. J., and Nebro, A. J. (2011). jMetal: A Java framework for multi-objective optimization. Advances in Engineering Software, 42(10), 760-771.
- [25] DEB, Kalyanmoy; GUPTA, Himanshu. Introducing robustness in multi-objective optimization. Evolutionary computation, 2006, vol. 14, no 4, p. 463-494.