

ERROR:  
FACE NOT  
RECOGNIZED



RECOGNIZED  
AS:  
SUBJECT 217

## Aumentando los cambios en intensidad para el reconocimiento facial en imágenes irreconocibles

## Augmenting intensity change to recognize faces in unrecognizable images

**Antonio Fontaine<sup>1</sup>**, alumno de 6º año.  
**Domingo Mery<sup>1</sup>**, profesor titular.

<sup>1</sup>Department of Computer Science, School of Engineering,  
Pontificia Universidad Católica de Chile.

\*Corresponding author: dmery@ing.puc.cl

**Antonio Fontaine<sup>1</sup>**, 6th year student.  
**Domingo Mery<sup>1</sup>**, full professor.

<sup>1</sup>Department of Computer Science, School of Engineering,  
Pontificia Universidad Católica de Chile.

\*Corresponding author: dmery@ing.puc.cl

## RESUMEN

La eficiencia de los algoritmos de reconocimiento facial está altamente relacionada a la calidad de las imágenes de entrada. Consecuentemente, el desafío surge al trabajar con fotografías de baja calidad, lo que, además, suele ser el caso en muchas aplicaciones desde criminología hasta redes sociales. Este artículo aborda este problema proponiendo dos algoritmos, “Tony” y “Quilladin”, para restaurar imágenes de baja calidad. Para medir el rendimiento, ambos métodos fueron comparados contra el conocido algoritmo “Blind” sobre 5 imágenes de tamaños diferentes y baja resolución. Tony tuvo los mejores resultados en los tres tamaños menores, con una mejora del 4,8% comparado con el 3,75% de Blind. Adicionalmente, estas aproximaciones fueron evaluadas en un espacio de inter-resolución, donde las imágenes de baja calidad no fueron solamente restauradas, sino que las imágenes reclutadas fueron degradadas. En estos experimentos, nuestra aproximación alcanzó más de un 300% de aumento en la eficacia en imágenes de baja resolución (8x11 pixels), al comparar sin restauración, y resultados similares a Blind en el espacio de inter-resolución, con menos de 1% de diferencia. Considerando esto, Tony indica ser un algoritmo eficiente para la restauración de imágenes de muy baja calidad..

*Palabras clave:* procesamiento de imágenes, reconocimiento facial, Quilladin, Tony, transformada de Fourier.

## ABSTRACT

The efficiency of face recognition algorithms is closely linked to the quality of the input images. Consequently, the challenge arises when working with low-quality photographs, moreover this is usually the case in many applications, from criminology to social networks. This article tackles this dilemma by proposing two algorithms, namely, ‘Tony’ and ‘Quilladin’ to restore the low-quality images. To assess performance, both methods were compared with the well-known ‘Blind’ algorithm over 5 different low-resolution image sizes. Tony had the best results on the three smaller sizes, with a 4.8% improvement compared to 3.75% improvement with Blind. In addition, these approaches were tested in an inter-resolution space, where not only low-quality images were restored but also the enrolled images were degraded. In these experiments, our approach achieved over 300% accuracy improvement in very low-resolution images (8x11 pixels) when comparing with no restoration approaches and had similar results to Blind in inter-resolution space, with less than 1% difference. With this, Tony proves to be an efficient image restoration algorithm for very low-quality images.

*Keywords:* image processing, face recognition, Quilladin, Tony, Fourier Transformation

## 1. INTRODUCCIÓN

El procesamiento de imágenes tiene múltiples áreas de aplicación, desde el mejoramiento de información pictórica para la interpretación humana, hasta el apoyo en la percepción por máquinas y software. Por ejemplo, cuando un usuario sube fotos a Facebook, el software sugiere amigos para ser etiquetados en la imagen de manera automática. Facebook es capaz de procesar estas imágenes y determinar quien está presente. Esto puede ser realizado por varios algoritmos y todos ellos tienen un alto rendimiento en imágenes nítidas, enfocadas y libres de **RUIDO** (Dutta, Veldhuis & Spreeuwiers, 2012). Sin embargo, el desafío surge cuando las imágenes son borrosas o de baja calidad. En estos casos existen dos aproximaciones diferentes; la primera, consiste en mejorar el algoritmo de reconocimiento facial a tal punto que es capaz de reconocer caras incluso en condiciones severas. La segunda opción es la de restaurar la calidad de la imagen con algún método de procesamiento antes de aplicar el algoritmo de reconocimiento facial. En este trabajo, el objetivo es restaurar las imágenes de baja

## 1. INTRODUCTION

Image processing has a vast application area, from enhancement of pictorial information for human interpretation to assist machine and software perception. For instance, whenever users post pictures on Facebook, the software automatically suggests friends to be tagged in the image. Somehow, Facebook is capable of processing these images and determine who is present. This can be achieved with several algorithms and all of them have higher performance in sharp, focused, **NOISE-free** pictures (Dutta, Veldhuis & Spreeuwiers, 2012). However, the challenge arises when the images are blurry or low quality. In these cases, there are two different approaches; the first one is to improve the face recognition algorithm to such point that is capable to recognize faces even in harsh conditions. The second option is to restore quality with some image processing method before applying the face recognition algorithm. Herein, the objective is to restore the low-quality image to a sharper and better quality file.

calidad en archivos más nítidos y de mejor calidad.

$$g = h^* f$$

**Ecuación 1.**  $f$  representa la imagen original,  $h$  una matriz de degradación y  $g$  la imagen borrosa. Considerar que  $*$  corresponde a una convolución. Revisar el **Principio Científico** para mayor explicación.

La forma intuitiva de restauración sería encontrar el inverso de  $h$  de la **Ecuación 1**. Esto se conoce como el Filtro Inverso (Gonzalez & Woods, 2017). Sin embargo, esto tiene dos fallas principales: primero,  $h$  podría contener valores 0, lo que indefiniría  $h^{-1}$ . Segundo, no considera el ruido, lo que las imágenes suelen tener. Múltiples algoritmos, a través de diferentes aproximaciones, buscan reparar estos defectos, como el Filtro Wiener, Lucy-Richardson, Filtro Limitado de Mínimos Cuadrados (del inglés, Constrained Least Squares Filtering) y Blind (Gonzalez & Woods, 2017). Este último es particularmente interesante porque asume que la degradación (matriz  $h$ ) es desconocida, lo que es habitualmente cierto, e intenta buscar una solución iterativa óptima para  $h$ .

Este artículo propone dos algoritmos de restauración, llamados “Tony” y “Quilladin”. A diferencia de los algoritmos previos, éstos no intentan encontrar  $h^{-1}$ , sino que ambos apuntan a exaltar los bordes. La ventaja de esta aproximación reside en el hecho de que no es necesario conocer de antemano o predecirla (como lo hace Blind). El objetivo de esta investigación fue de evaluar la efectividad de estos algoritmos en imágenes de baja resolución.

## 2. METODOLOGÍA

### 2.1. Algoritmos propuestos

#### 2.1.1. Tony

Tony es un algoritmo sencillo inspirado en la **MÁSCARA** de nitidez (Gonzalez & Woods, 2017). Tony se concentra en el hecho de que las imágenes borrosas suelen estarlo, mayoritariamente, en los bordes. Si los pixels borrosos son un valor promedio y todos los valores de una máscara son el mismo, i.e. negro, entonces la imagen de salida será negra. En el caso del ícono negro del ejemplo mencionado en el **Principio Científico**, los pixels grises solo aparecerán donde hay áreas blancas y negras dentro de la máscara o, en otras palabras, en los bordes. Tony busca los bordes de las imágenes borrosas y luego trata de aumentar la tasa con la cual cambia la intensidad. Para detectar los bordes, Tony realiza una **CONVOLUCIÓN** de la imagen original ( $f$ ) con un **FILTRO GAUSS** para obtener una imagen aún más borrosa ( $f'$ ). Luego, el algoritmo sustrae ambas imágenes, lo que resulta en cero cada vez que ambas imágenes tienen el mismo valor, por tanto, no en un borde. Esta diferencia entrega una matriz con valores distintos de 0 en cada lugar

$$g = h^* f$$

**Equation 1.**  $f$  is the original image,  $h$  a matrix representing the degradation, and  $g$  is the blurred image. Note that  $*$  is for convolution. See the **Scientific Principle** for further explanation.

The most intuitive restoration would be to find the inverse of  $h$  of **Equation 1**; this is called the Inverse Filter (Gonzalez & Woods, 2017). However, it has two main flaws; firstly,  $h$  might contain zero values that would undefine  $h^{-1}$ ; secondly, it does not consider noise, which images usually have. Several algorithms look for different approaches to fix these flaws, such as Wiener Filter, Lucy-Richardson, Constrained Least Squares Filtering and Blind (Gonzalez & Woods, 2017). The latter is particularly interesting as it assumes the degradation (matrix  $h$ ) is unknown, which normally is the case, and iterates to find the optimal solution for  $h$ .

This article proposes two restoration algorithms, called ‘Tony’ and ‘Quilladin’. Unlike the previous algorithms, these do not try to find  $h^{-1}$ , instead both of them try to enhance borders. The advantage of this approach resides on not needing to know  $h$ , beforehand or guess it (as ‘Blind’ does). The objective of this investigation was to evaluate how effective were these algorithms in low-resolution images.

## 2. METHODOLOGY

### 2.1. Proposed Algorithms

#### 2.1.1. Tony

Tony is a simple algorithm inspired in the sharpen **MASK** (Gonzalez & Woods, 2017). Tony focuses on the fact that blurred images are mainly blurred on edges. If the blurriness is a weight average and all the values in the mask are the same, i.e. black, the output will be black. In the case of a black icon example mentioned in the **Scientific Principle**, gray pixels only appear when there are white and black areas within the mask, in other words on a border. Tony finds the edges on the blurred image and then tries to increase the rate at which the intensity changes. To detect the borders, Tony performs a **CONVOLUTION** on the original image ( $f$ ) with a **GAUSS FILTER** to get an even more blurred image ( $f'$ ). Then, the algorithm subtracts both blurred images, resulting in zero wherever they have the same value, hence not a border. This difference gives a matrix with non-zero values in every place there is an edge; this last image is then amplified by a scalar ( $y$ ) to increment the edges and added to the initial blurred image (**Figure**

donde hay un borde. Esta última imagen es amplificada por un escalar ( $y$ ), para aumentar los ejes, y sumada a la imagen borrosa original (**Figura 1A**). Tony no intenta llegar a la imagen original, por lo que opera más como un filtro de nitidez que como algoritmo de restauración, similar a los filtros presentes en Instagram o cualquier otra herramienta de procesamiento de imágenes.

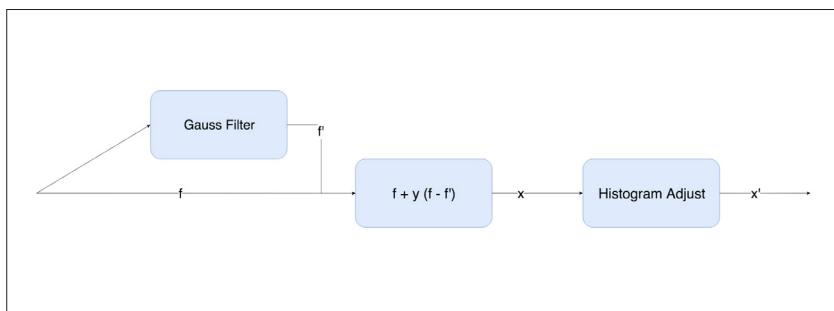
### 2.1.2. Quilladin

Los cambios radicales de color pueden ser visto como frecuencias altas en el dominio de frecuencia y dado que las imágenes borrosas pierden estos cambios radicales, pierden las frecuencias altas. Quilladin fue desarrollado para poder restaurarlos. Para lograr esto, una **TRANSFORMADA DE FOURIER** es aplicada a la imagen para transformarla al dominio de frecuencia ( $F$ ). Luego, define una máscara Gaussiana invertida (MGI) desde 1 en el centro hasta  $n+1$  en los bordes, siendo  $n$  un escalar dado. Luego,  $F$  es multiplicado por elementos con la MGI, dejando el centro casi intacto (bajas frecuencias), mientras que las altas frecuencias aumentan  $n+1$  veces. Finalmente, transforma la imagen de vuelta al dominio espacial ( $x$ ). Ver **Figura 1B**.

**1A).** Tony does not try to get to the original image, more than a restoration algorithm it works as a sharpening filter, similar to the one present in Instagram or any other image-processing tool.

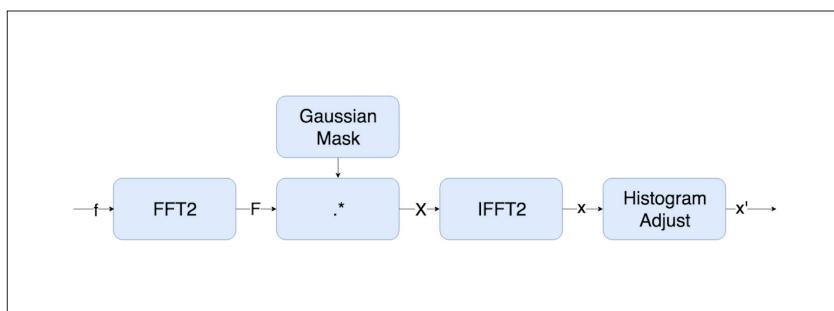
### 2.1.2. Quilladin

Radical color changes are viewed as high frequencies in the frequency domain, and blurry images lose radical changes. Given this loss in the high frequency domain, Quilladin was developed in order to restore them. In order to do so, first a **FOURIER TRANSFORMATION** is applied to the image to transform it to the frequency domain ( $F$ ). Then, it defines an inverted Gaussian mask (IGM) that goes from 1 in the center to  $n+1$  in the edges, being  $n$  a given scalar. Afterwards,  $F$  is multiplied (element-wise) with the IGM, leaving the center almost intact (low frequencies), whereas the high frequencies are incremented  $n+1$  times. Finally, it transforms the image back to the space domain ( $x$ ). See **Figure 1B**.



**Figura 1A.** Diagrama de Tony.  $f'$  corresponde a la imagen borrosa y  $y$  a un escalar. El ajuste de histograma asegura que cada pixel tenga un valor dentro de un rango válido.

**Figure 1A.** Tony Diagram.  $f'$  is the blurred image, and  $y$  a given scalar. Histogram Adjust makes sure every pixel value is within a valid range.



**Figura 1B.** Diagrama de Quilladin,  $f'$  es la imagen borrosa, FFT2 es una transformada de Fourier rápida e iFFT2 es su inverso. Adicionalmente  $\cdot^*$  Representa **MULTIPLICACIÓN DE ELEMENTOS**. Máscara Gaussiana es una máscara de Gauss invertida. El ajuste de histograma asegura que cada pixel tenga un valor dentro de un rango válido.

**Figure 1B.** Quilladin Diagram,  $f'$  is the blurred image, FFT2 is the fast Fourier transform and iFFT2 its inverse. Moreover  $\cdot^*$  denotes **ELEMENT-WISE MULTIPLICATION**. Gaussian Mask is an inverted gauss mask. Histogram Adjust makes sure every pixel value is within a valid range.

## 2.2. Reconocimiento facial

El primer paso en la metodología de reconocimiento facial es el reclutamiento, donde imágenes bien definidas de personas conocidas fueron manualmente anotadas con sus identificaciones de sujetos. Luego, se le calcula un descriptor a cada imagen. Este descriptor es un vector donde cada elemento corresponde a una característica. Por tanto, imágenes de la misma persona deberían tener descriptores similares. Por tanto, un sujeto en una imagen puede ser reconocido encontrando el descriptor que más se asemeje dentro de las personas reclutadas.

Para determinar el descriptor más similar, todos los descriptores fueron normalizados. Luego, se realizó un producto por puntos entre el descriptor de la imagen desconocida y cada descriptor. Vectores similares entregarán valores similares a 1 (referido como puntuación); por lo tanto, los descriptores con la mayor puntuación fueron seleccionados. Es necesario considerar que, para poder realizar un producto punto, ambos descriptores deben tener el mismo tamaño. Por lo tanto, todas las imágenes deben ser del mismo tamaño. Para poder cumplir con este requisito, las imágenes de consulta fueron redimensionadas para calzar con el tamaño de las imágenes reclutadas.

## 2.3. Comparación de imágenes

El trabajo hasta aquí presentado ocurrió previo a la comparación de caras. Los distintos procesos de restauración y degradación fueron hecho en las imágenes reclutadas o las de consulta. La **Figura 1C** ilustra el proceso completo.

Para poder comparar la eficiencia de los distintos procesos, se usó un sistema de clasificación (Poh, Chan, Kittler, Fierrez & Galbally, 2012). Este sistema organiza los descriptores en orden descendiente de acuerdo a su puntuación. El rango corresponde a la posición en la cual el descriptor de la persona reclutada queda ubicado en esta lista ordenada. Por ejemplo, en el caso de tres individuos reclutados A, B y C, junto a una **IMAGEN DE CONSULTA** de B. Al correr el sistema, éste entrega una lista de descriptores ordenada como: A, B, C; entonces, el rango 2 es B por estar en la

## 2.2. Face Recognition

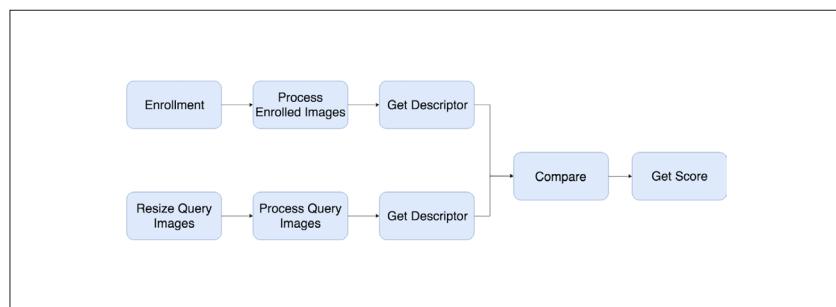
The first step in a Face Recognition methodology is the enrolment, where well-defined images with known people are manually annotated to their subject ID. Afterwards, a descriptor is calculated per image. This descriptor is a vector where each element corresponds to a characteristic; therefore, pictures of the same person should have similar descriptors. Thus, a subject in a face image can be recognized by finding the most similar descriptor within the enrolled people.

To determine the most similar descriptor, all of the descriptors were normalized. Then, a dot product between the descriptor of the unknown face and every descriptor was done. Similar vectors give values (referenced as score) close to 1; therefore, the descriptor with the highest score is selected. Note that in order to be able to do a dot product, both descriptors must have the same size; hence, the images must be the same size. In order to fulfill this requirement, query images were resized to match the enrolled image size.

## 2.3. Image comparison

The work done in this research was prior to the comparison of faces. Different restoration and degradation processes were done either to enrolled or query images. **Figure 1C** illustrates the whole process.

In order to compare the efficiency of the different processes the rank system (Poh, Chan, Kittler, Fierrez & Galbally, 2012) was used. This system arranges the descriptors in descending order by their score. The rank corresponds to the position where the person's enrolled descriptor gets placed on this ordered list. For example if we have three enrolled individuals, A, B and C, and a **QUERY IMAGE** of B, and we run the system giving an ordered list of descriptors as follows: A, B, C, then the rank is 2 as B is in



**Figura 1C.** Metodología de reconocimiento facial.

**Figure 1C.** Face recognition methodology.

segunda posición.

El sistema de clasificación es usado cuando se testea una imagen desconocida. Como en nuestro método, se analiza más de una imagen desconocida, el sistema de clasificación por si solo no es suficiente. Por lo tanto, se graficó una curva de característica de coincidencia acumulativa (del inglés, Cumulative Match Characteristic) (Bolle et al., 2005), donde el enésimo valor corresponde a la cantidad de imágenes con rango n o menos. Luego, se calculó el área bajo la curva, donde mayores áreas implica que más imágenes tienen rangos menores (mejores), mientras que menores áreas significa que más imágenes tienen mayores rangos. Esta área fue la métrica utilizada para comparar los distintos procedimientos (referido como puntuación).

#### 2.4. Caso de estudio

En este caso, 5 fotografías de 9 individuos fueron reclutadas y ordenadas desde las menos borrosa a la más borrosa, por persona. El algoritmo de Diagonal Laplaciana propuesto por Pertuz, Puig y Garcia (2013) fue usado para determinar cuan borrosa era la imagen. Los descriptores fueron calculados con el descriptor de aprendizaje profundo (del inglés, deep learning) del grupo Visual Geometry Group (VGG). Un total de 72 imágenes de consulta de este grupo de 9 personas fueron usados en el experimento. Todas las entradas fueron recolectadas de imágenes de la vida real y ninguno de los sujetos posó específicamente para esta investigación.

Al comparar contra las imágenes reclutadas, no siempre las 5 imágenes fueron utilizadas, la variable N fue usada para indicar cuantas imágenes fueron incluidas. Por ejemplo, si N=4, esto indica que fue testeado contra las primeras cuatro imágenes reclutados. El objetivo de esto fue testear si es que es mejor contar con una mayor cantidad de imágenes reclutadas, incluso si éstas eran borrosas.

Todas las imágenes reclutadas fueron forzadas a un tamaño de 120x165 pixels. Cada imagen de consulta fue redimensionada a cinco diferentes tamaños: 48x66, 24x33, 15x22, 8x11 and 5x7 pixels, denominadas L1, L2, L3, L4 y L5, como se muestra en la **Figura 2**. Sin embargo, ninguna imagen fue agrandada. Por lo tanto, si el tamaño de una imagen era de 6x8, entonces solo fue incluida en el grupo 5x7. Esto dio un total de 215 imágenes de consulta.

Las 215 imágenes de consulta fueron agrandadas, ya sea por interpolación bicúbica (Gonzalez & Woods, 2017) o mediante el algoritmo SCSR (Yang, 2010), para coincidir con el tamaño de las imágenes reclutadas. Consiguientemente, no recibieron más procesamiento (NFP, del inglés, *no further process*) o fueron procesadas con Blind, Tony o Quilladin.

the second position.

The rank system is used for when there is one unknown image tested, as in our method more than one unknown image was tested the rank by itself it is not enough. Therefore, the Cumulative Match Characteristic (Bolle et al., 2005) curve was plotted, where the nth-point corresponds to the amount of images with rank n or lower. Afterwards, the area under this curve was calculated, where higher area means most images have low ranks (better) whereas lower area means more images have high ranks. This area was the metric used to compare the different procedures (referenced as score).

#### 2.4. Study case

In this case, 5 pictures of 9 people were enrolled and ordered from less blurry to the blurriest, per person. The Diagonal Laplacian algorithm proposed by Pertuz (2013) was used to determine the blurriness level. The descriptors were calculated with the deep learning descriptor of the Visual Geometry Group (VGG). A total of 72 query images of this 9-people group, were used in the experiment. All inputs were collected from real life images, none where specifically posed for this investigation.

When compared to the enrolled images, not always the 5 enrolled images per person were used, a variable N is used to indicate how many were used. For instance, if N=4, then it was tested against the first four enrolled images. The objective of this is to test if it is better to have more enrolled images, even if they are blurrier.

All enrolled images were forced to be sized 120x165 pixels. Each query image was resized to five different sizes: 48x66, 24x33, 15x22, 8x11 and 5x7 pixels, named L1, L2, L3, L4 and L5, as shown in **Figure 2**. However, no image was enlarged; therefore, if an image was size 6x8 it would only appear in the 5x7 bucket. This gives a total of 215 query images.

This 215 query images were then enlarged, either by bicubic interpolation (Gonzalez & Woods, 2017) or by ScSR algorithm (Yang, 2010), to match the enrolled size. Subsequently, they had no further process (NFP) or processed with Blind, Tony or Quilladin.



**Figura 2.** Imagen real desde donde las imágenes de consulta fueron extraídas. En la derecha se muestran las 5 imágenes de consulta con sus respectivos tamaños (en pixels).

**Figure 2.** Real image from where query images were extracted. On the right show 5 different query images with their size (pixels).

### 3. RESULTADOS Y DISCUSIÓN

El reclutamiento de más imágenes por sujeto, aumentando el N, tuvo un efecto positivo en la puntuación, especialmente en las imágenes más pequeñas. Esto dio un mejor entendimiento de la cara de la persona, por tanto, mejores puntajes. Adicionalmente, al aumentar el N, se reclutaron imágenes borrosas de las personas, lo que dio una mejor comparación para las imágenes de baja calidad. Por tanto, N=5 obtuvo las mejores puntuaciones con un aumento promedio de 62,64%, con máximos de +120% en L4 y L5. Posteriormente, se testeó el algoritmo de redimensionamiento; SCSR mostró una mejora del 0,46% comparado con la interpolación bicúbica. Sin embargo, esta diferencia es mínima y podría deberse a la base de datos utilizada.

El mejor algoritmo de procesamiento depende del tamaño de imagen. NFP tuvo resultados sorprendentemente altos en imágenes grandes, entregando el mejor resultado en L1 y la segunda mejor puntuación en L2, como se ilustra en la **Tabla 1**. Estas imágenes estaban tan bien definidas, que el procesamiento solo agregó ruido y las tornó menos reconocibles. Por otro lado, las imágenes L3, L4 y L5 obtuvieron las peores puntuaciones con NFP y los mejores resultados con Tony, correspondiendo a un aumento del 4.8% sobre NFP (ver **Tabla 1**).

#### 3.1. Espacio de inter-resolución

Hasta este punto, las imágenes de baja resolución fueron procesadas para que se parezcan a las imágenes reclutadas. Sin embargo, existe una opción de un espacio inter-resolución (IR), donde no solo las imágenes de baja resolución son reconstruidas, sino que las imágenes reclutadas son degradadas. Dos algoritmos de degradación

### 3. RESULTS AND DISCUSSION

Enrolling more images per subject, increasing N, had a positive impact on the scores, especially on smaller images. This gave a better understanding of the person's face; hence better scores. Moreover, as N increases, blurrier images of the person are enrolled giving a better comparison for low-quality images. Therefore, N=5 had the best scores with an average score increment of 62.64%, peaking at L4 and L5 with a +120%. Afterwards, the resizing algorithm was tested; SCSR had an improvement of 0.46% over bicubic interpolation. However, the improvement is minimal, therefore it could just be due to the database.

The best processing algorithm depends of the image size. NFP had astonishing high results in larger images, giving the best score on L1 and the second best score on L2, as **Table 1** illustrates. These images are so well defined that processing them only adds noise to the image, hence less recognizable. On the other hand, L3, L4 and L5 images had the worst results with NFP and the best results with Tony, with a 4.8% improvement over NFP. See **Table 1**.

#### 3.1. Inter-resolution space

Until this point, low-resolution images have been processed to look like the enrolled images. However, there is an inter-resolution space (IR) option, where not only the low-resolution image is reconstructed but also the enrolled

fueron testeados para esto: los filtros Gaussianos y de mediana. Este último toma los valores de las medianas de las máscaras y es usado en la reducción de ruido, pues elimina los valores extremos.

El mejor tamaño de máscara aumentó en imágenes pequeñas. Éstas son de menor calidad, por lo que asemejar la **IMAGEN RECLUTADA** a la imagen de consulta requiere degradación adicional; i.e. una máscara más grande. L1 funciona mejor con máscaras de tamaño 21 para filtro gaussiano y 3 para **FILTRO DE MEDIANAS**; mientras que para L5, los mejores tamaños de máscara fueron 91 y 66 para filtro gaussiano y de medianas, respectivamente.

Antes de usar IR, las imágenes de consulta fueron altamente procesadas para parecerse a las imágenes reclutadas, resultando en imágenes de consulta ruidosas. Mediante el uso de IR, existe menos procesamiento y, por lo tanto, menos ruido incorporado, resultando en un 6,27% de mejor. Este efecto aumenta en imágenes pequeñas, dado que son las que requieren mayor procesamiento, con una mejora del +10% para L4 y L5 (ver **Tabla 1**). Entre ambas degradaciones, el filtro Gaussiano entregó mejores resultados que el filtro de medianas en todos los tamaños de imagen excepto L5. Un N mayor, similar al caso sin IR, tuvo mejores resultados. Sin embargo, su efecto disminuyó hasta un 6,27% de mejora, dado que la necesidad de más imágenes borrosas es suplido por la degradación en IR.

image is degraded. Two degradation methods were tested: Gaussian and median filter. The last one takes the median value of the mask; it is used in noise reduction as outliers are eliminated.

The best mask size used increased in smaller images. These are of lower quality; thus, to make the **ENROLLED IMAGE** similar to the query image it requires further degradation, hence a larger mask. L1 work best with masks sized 21 for Gaussian and 3 for **MEDIAN FILTERS**, whereas L5 best mask sizes where 91 for Gaussian and 66 for median.

Before IR, the query images were heavily processed to look like the enrolled images, giving noise query images. With the use of IR, there is less processing, and, therefore, less noise added giving a 6.27% average improvement. This effect is augmented in smaller images; as they require heavier processing, with L4 and L5 having +10% improvement, see **Table 1** for more details. Between the two degradations, Gaussian gave better results than median in all images sizes except L5. A higher N, such as without IR, gave better results. However, its effect decreased to a 6.27% improvement, as the need of blurrier images is fulfilled with the IR degradation.

In the restoration, NFP had better results, being the best algorithm for L2, L3 and L4. The degradation of the enrolled image makes them so similar to the query images, that only in L1 and L5 the need of a restoration algorithm



	L1		L2		L3		L4		L5	
Degradation	None	IR	None	IR	None	IR	None	IR	None	IR
NFP	0.9156	0.9244 (M)	<b>0.9048</b> (G)	<b>0.9194</b> (G)	0.7877	<b>0.8400</b> (G)	0.5972	<b>0.6958</b> (G)	0.5620	0.6577 (G)
Blind	<b>0.9178</b>	<b>0.9289</b> (G)	0.9048	0.9177 (G)	0.7938	0.8323 (G)	0.6282	0.6817 (G)	0.5917	<b>0.6819</b> (M)
Quilladin	0.9000	0.9111 (G)	0.9000	0.9016 (G)	<b>0.8031</b>	0.8231 (M)	0.6155	0.6746 (M)	0.5944	0.6764 (G)
Tony	0.9133	0.9156 (M)	0.9048	0.9065 (G)	<b>0.8031</b>	0.8277 (M)	<b>0.6324</b>	0.6817 (G)	<b>0.5986</b>	0.6542 (M)

**Tabla 1.** Mejor puntuación para cada tamaño de imagen para los algoritmos de degradación y restauración. (M) indica que el mejor resultado se obtuvo con el filtro de medianas, mientras que (G) corresponde al filtro Gaussiano. El color de relleno indica el algoritmo de redimensionamiento. Azul indica SCSR y blanco interpolación bicúbica. Arriba, imágenes representativas de cada algoritmo de procesamiento. En cada caso, 5 imágenes fueron reclutadas por individuo (N=5).

**Table 1.** Best score for every image size by Degradation and Restoration algorithm. (M) Indicates that the best result was using a Median Filter whereas (G) stands for Gaussian Filter. The fill color indicates the resizing algorithm. Blue stands for SCSR resize where white is bicubic. Over the top, sample images illustrate each processing algorithm. In every case 5 images were enrolled per subject (N=5).

En la restauración, NFP tuvo los mejores resultados, correspondiendo al mejor algoritmo para L2, L3 y L4. La degradación de las imágenes reclutadas las tornó tan similares a las imágenes de consulta, que solamente en L1 y L5 los algoritmos de restauración fueron necesarios.

En IR, el redimensionamiento bicúbico tuvo los mejores resultados, con un aumento del 0,44% sobre SCSR. Sin embargo, L2 y L5 fue mejor con SCRS. Por tanto, los resultados son poco conclusivos.

En general, reclutar más imágenes, IR y el procesamiento adicional mejoraron el reconocimiento facial en imágenes de baja calidad. Esto aumentó a menores tamaños de imagen, con más de 300% en L4 y L5 sobre N=1 con NFP (ver **Figura 3**).

Tony y Quilladin aumentaron el rendimiento del algoritmo de reconocimiento facial ya que intensificaron los bordes al mejorar el contraste de las imágenes. Lo cual lograron de manera más drástica que Blind (ver figuras en la Tabla 1), por lo que Tony tuvo mejores resultados que Blind en L3, L4 y L5. Sin embargo, en L1 y L2, las imágenes de consulta no estaban borrosas, por lo que procesarlas con Tony o Quilladin las volvió sobre contrastadas, obteniendo peores resultados que Blind.

Al incorporar IR, Tony y Quilladin se tornaron menos efectivos que Blind. El problema de usar Tony o Quilladin e IR es que los primeros generan imágenes de alto contraste, mientras que el último produce imágenes de bajo contraste. Así, operan en direcciones opuestas. Por lo tanto, una posible mejora sería probar algoritmos que aumenten el contraste en IR. Esto permitiría un uso más intenso de Tony y Quilladin en las imágenes de consulta que serían comparadas con imágenes reclutadas de alto contraste.

## CONCLUSIONES

Para el reconocimiento facial en imágenes de baja calidad, el reclutamiento de imágenes borrosas tuvo un efecto

was needed.

In IR, Bicubic resizing had better results, with an improvement of 0.44% over SCSR. However, L2 and L5 went better with SCSR. Therefore there is an unclear result.

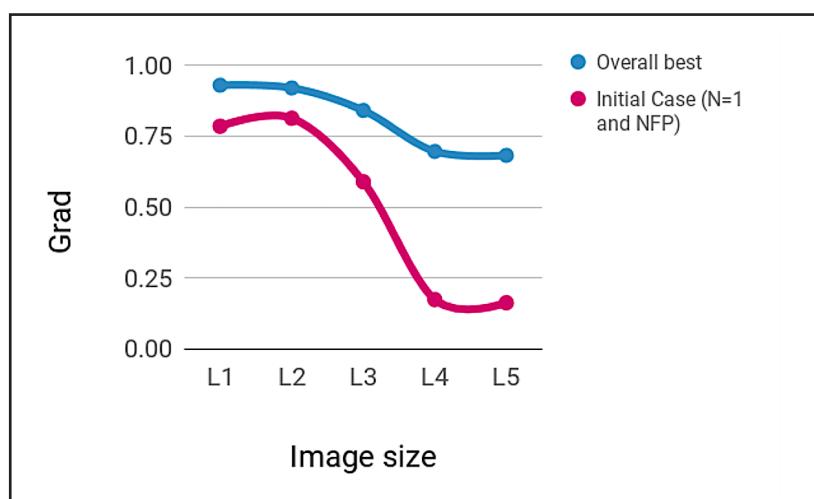
Overall, enrolling more images, inter-resolution space and further processing improves the face recognition in low-quality images. This increases as the image size decreases. Giving +300% in L4 and L5 over the N=1 with NFP, as **Figure 3** shows.

Tony and Quilladin enhance the performance of the Face Recognition algorithm as they intensify the edges by increasing the contrast of the images. They do so in a more drastic way than Blind, see figures in Table 1 as reference, therefore Tony have better results in L3, L4 and L5 than Blind. However in L1 and L2 the query images are not blurred out, therefore processing them with Tony or Quilladin make an over-contrasted image, giving worst results than Blind.

When IR comes to play, Tony and Quilladin become less effective than Blind. The issue of using Tony or Quilladin and IR is that the first generate highly contrasted images as the latter generate low contrast images. Thus, they move in opposite directions. Therefore, one possible improvement would be to test in IR not only with algorithms that lower the contrast but also with algorithms that actually heightens them. This would allow a heavier use Quilladin and Tony in the query images to be matched with a contrasted enrolled image.

## CONCLUSIONS

For the recognition of faces in low-quality images, the enrollment of blurry images had a positive effect. The



**Figura 3.** Mejora general de los mejores casos contra el caso inicial, N=1 y NFP, para cada tamaño de imagen L1, L2, L3, L4 y L5.

**Figure 3.** Overall improvement of the best case against the initial case, N=1 and NFP, for every image sizes L1, L2, L3, L4 and L5.

positivo. El aumento de N, al añadir imágenes borrosas, y el uso de IR, demuestran que es más fácil comparar contra una imagen mal definida que contra una imagen altamente reconstruida, especialmente para Blind y NFP, donde IR mostró un aumento de 6,25% y 8,55%.

Aunque Tony y Quilladin aumentaron su efectividad con IR, es discutible que esto represente la mejor aproximación. Tanto Tony como Quilladin generaron imágenes de alto contraste. Por lo tanto, compararlas contra imágenes reclutadas borrosas no es tan efectivo como el uso de un algoritmo que no genere imágenes de consulta con alto contraste, como Blind. Sin embargo, una posible aproximación para aumentar el desempeño sería mediante el uso de un algoritmo de IR que aumente el contraste en las imágenes reclutadas, en comparación con la generación de imágenes más borrosas.

## Agradecimientos

Agradecimientos especiales para Iván Sepúlveda, co-creador del algoritmo Quilladin. También a los 9 participantes que permitieron el uso de sus imágenes como parte de esta investigación.

## GLOSARIO

**IMAGEN DE CONSULTA:** imagen de un sujeto desconocido que se busca reconocer.

**IMAGEN RECLUTADA:** imágenes que son manualmente mapeadas (o reclutadas) a sus respectivos sujetos. Son utilizadas para determinar a qué sujeto corresponde la imagen de consulta.

**MÁSCARA:** matriz usada en el procesamiento de imágenes para modificar nitidez, hacer una imagen borrosa, detectar bordes y más. Estas máscaras usualmente son aplicadas a lo largo de la imagen. También se llaman matrices de núcleo o convolución.

**CONVOLUCIÓN:** proceso de mover una máscara a lo largo de una imagen y ejecutar una función dentro de la máscara y a un área específica de la imagen.

**MULTIPLICACIÓN POR ELEMENTOS:** es una matriz de operación entre dos matrices A y B, donde cada valor en la matriz resultante es producto de la multiplicación entre los valores de las mismas posiciones en A y B. Por tanto, si C es la matriz resultante,  $C(i, j) = A(i, j) * B(i, j)$ . Se indica usualmente por  $*$ .

**FILTRO GAUSSIANO:** convolución de una imagen mediante una máscara Gaussiana, donde los valores de la máscara corresponden a los valores de una distribución Gaussiana. Se utiliza para difuminar imágenes.

**FILTRO DE MEDIANAS:** convolución de una imagen mediante una función de medianas que entrega el valor de la mediana para cada área de la imagen. Es utilizada para la reducción de ruido, pues tiende a eliminar los valores extremos.

increase of N, adding blurrier images, and the use of IR demonstrate how is easier to compare to a non-well-defined image rather than to have heavily reconstructed image, especially for Blind and NFP where IR gave an improvement of 6.25% and 8.55%.

Even though Tony and Quilladin did increased with IR, it is arguable if this represents the best approach. Both Tony and Quilladin generated contrasted query images; therefore, comparing them to blurred-out enrolled images it is not as effective as using an algorithm which does not generate contrasted query images, such as Blind. However, a secondary approach for enhancing performance could be an IR algorithm that boosts the enrolled image contrast rather than blurring it out.

## Acknowledgements

Special acknowledgement to Iván Sepúlveda, co-creator of the Quilladin algorithm. Also, to the 9 participants that allowed the use of their images as part of this research.

## GLOSSARY

**QUERY IMAGE:** Image of an unknown subject we desire to recognize.

**ENROLLED IMAGE:** Images who are manually mapped (or enrolled) to subjects. They are used to determine to which subject a query image corresponds.

**MASK:** Matrix used in image processing for sharpening, blurring, edge detection and more. This mask is usually convoluted through the image. It is also named kernel and convolution matrix.

**CONVOLUTION:** Process of moving a mask through an image and executing a function within the mask and a certain area of the image.

**ELEMENT-WISE MULTIPLICATION:** It is a matrix operation between two matrix A and B, where every value in the result matrix is given by a multiplication between the values of than same position on A and B. Therefore, if C is the result matrix,  $C(i, j) = A(i, j) * B(i, j)$ . Usually denoted by  $*$ .

**GAUSSIAN FILTER:** Convolution of an image with a gauss mask. Where the values of this mask corresponds to values with a Gaussian distribution. It is used to blur out images.

**MEDIAN FILTER:** Convolution of an image with a median function, which returns the median value of every area of the image. It is used for noise-reduction, as outliers are eliminated.

**RUIDO:** en procesamiento de imagen corresponde a variaciones aleatorias del brillo o el color generando imágenes de aspecto granuloso. Usualmente se genera por errores en el sensor.

**TRANSFORMADA DE FOURIER:** transformación matemática utilizada para descomponer señales en las frecuencias que las componen. El resultado es usualmente llamado como representación del dominio de frecuencia de la imagen original.

**NOISE:** Noise in image processing is random variations of brightness or color generating grainy-looking images. Usually generated by errors in the sensor.

**FOURIER TRANSFORMATION:** Mathematical transformation used to decompose signals into the frequencies that make it up. The result is usually named the frequency domain representation of the original image.

## PRINCIPIO CIENTÍFICO

Para poder restaurar una imagen borrosa, primero es necesario entender como ésta se genera. Asumiendo la imagen de un ícono negro sobre un fondo blanco (una silueta), esta imagen solamente debería tener dos intensidades de gris: blanco y negro. Sin embargo, si se obtiene una imagen fuera de foco del mismo objeto, la nueva imagen contendrá algunos pixels grises cerca de los bordes de los objetos. Esto ocurre porque el sensor de la cámara recibirá luz de ambas áreas del objeto, blanca y negra, y promediará los valores en una intensidad de gris.

Este modelo explica como el sensor de una cámara realmente promedia la luz. Define un área finita de interés, también conocida como máscara. Por tanto, otras áreas fuera de esta máscara no afectarán el color de los pixels ya que pixels gris aparecerán cerca de áreas blancas y negras, mientras los pixels blancos aparecerán en áreas puramente blancas (ver **Figura 4**). Al interior de la máscara ocurre un promedio de valores, existen diferentes formas de realizar esto; por ejemplo, un filtro de promedios tiene un factor de ponderación constante, mientras que un filtro Gaussiano pondrá preferentemente los ítems del medio, donde los valores corresponden a una distribución Gaussiana.

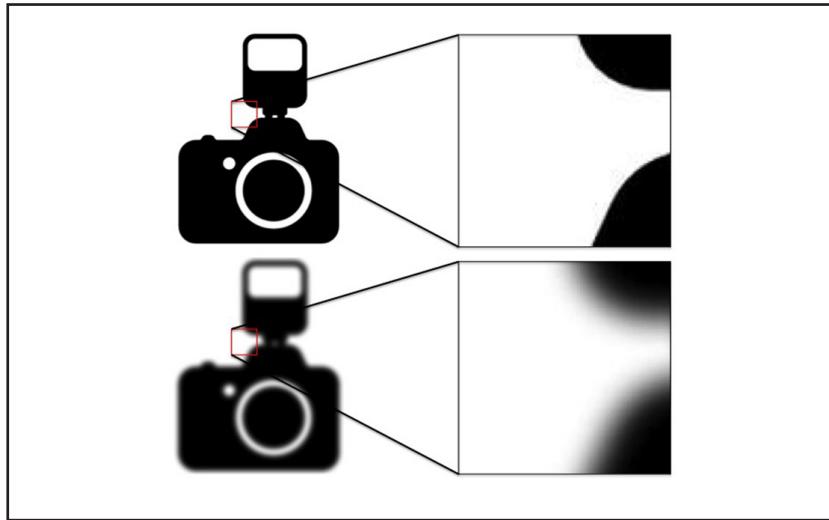
Al usar una matriz de representación de imágenes, la degradación puede ser expresada mediante la fórmula representada en la **Ecuación 1**.

## SCIENTIFIC PRINCIPLE

In order to restore a blurred image the first step is to understand how blurriness is generated. Assuming an image of a black icon over a white background (a silhouette), this image should only have two gray intensities: black and white. However, if an out-of-focus image was shot of that same icon; the new image should have some gray pixels near the borders of the object. This occurs because the camera sensor receives light from both the white and black areas of the object and averages this input to a gray intensity.

The blurriness model explains how the sensor actually averages the light. It defines a finite area of interest, also known as a mask. Thus, other areas outside this mask do not affect pixel color: gray pixels appear near white and black areas, whereas white pixels appear in white-only areas, see **Figure 4** as reference. Within the mask a weight average occurs, there are different ways of executing the weight average, for instance the average filter has constant weight whereas the Gaussian filter gives more importance to the items in the middle, where the values of the weight correspond to a Gaussian distribution.

By using the matrix representation for images, degradation can thus be expressed with the formula exposed in **Equation 1**.



**Figura 4.** Dos imágenes de íconos negros. Abajo, la versión borrosa de la imagen superior. A la derecha, aumento de las zonas demarcadas por los recuadros rojos. Arriba, solamente dos colores son apreciables, blanco y negro. Mientras que abajo aparecen una serie de tonos de gris.

**Figure 4.** Two black icon images, the one on the bottom is a blurred version of the one in the top. To the right two close-ups of the red bounding-box, on the top only two colors is present, black and white. Whereas on the bottom different gray colors appear.

## REFERENCES

- Dutta, A., Veldhuis, R. N. J., & Spreeuwiers, L. J. (2012). The Impact of Image Quality on the Performance of Face Recognition. *33rd WIC Symposium on Information Theory in the Benelux* (pp. 141-148). Enschede, the Netherlands: Centre for Telematics and Information Technology (CTIT).
- Gonzalez, R. C., & Woods, R. E. 1. (2008). Digital image processing (3rd ed.). Upper Saddle River, N.J.: Prentice Hall.
- Bolle, R.M., Connell, J.H., Pankanti, S., Rath, N.K., & Senior, A.W. (2005). The relation between the ROC curve and the CMC. *Fourth IEEE Workshop on Automatic Identification Advanced Technologies* (AutoID'05), 15-20.
- Poh N., Chan C-H., Kittler J., Fierrez J., Galbally J. (2012). Description of Metrics for the Evaluation of Biometric Performance. *Biometrics Evaluation and Testing*.
- S. Pertuz, P. Puig, and M. A. Garcia. (2013). Analysis of focus measure operators for shape-from-focus. *Pattern Recognition*, 46(5), 1415-1432.

## EQUIPO DE INVESTIGADORES / RESEARCH TEAM



Antonio  
Fontaine

Domingo  
Mery