


UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE ELECTRÓNICA
VALPARAÍSO - CHILE



“METODOLOGÍAS PARA LA AUTOMATIZACIÓN DE
LA EXTRACCIÓN DE CARACTERÍSTICAS DE LA
FORMA EN EL CONTEXTO DEL DISEÑO DEL
MODELO DE LA PERSONALIDAD DE PRODUCTOS”

GUILLERMO ERICH PLAZA HERNÁNDEZ

MEMORIA DE TITULACIÓN PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL ELECTRÓNICO

PROFESOR GUÍA:

MARCOS ZÚÑIGA BARRAZA

PROFESOR CORREFERENTE:

PABLO PRIETO CABRERA

9 DE NOVIEMBRE DE 2017

Resumen

La razón de que una persona decida comprar un producto, no pasa solo por la funcionalidad del objeto, ni en su capacidad de satisfacer la necesidad del usuario, existe una componente emocional que define el porqué una persona escoge un producto por sobre otro, cuando ambos son para la misma tarea. Esta emocionalidad esta relacionada a distintas características física de los productos, como la forma, color, textura, olor o incluso el sonido, que le entregan las características de personalidad a los objetos.

Los diseñadores buscan potenciar ciertas características de personalidad a través del diseño, pero no existe una herramienta que les permita cuantificar en que grado lo han logrado.

En este trabajo se analiza la relación que tiene la forma de los objetos, en específico el contorno en dos dimensiones de ellos, con las características de personalidad que le dan las personas.

Se inicia con el descriptor de diferencia angular acumulada desarrollado por Zuñiga et al. [13] y se incluyen los descriptores área, perímetro, circularidad, rectangularidad, excentricidad y simetría, los cuales permiten identificar las características principales y cuantificarlas numéricamente. Además, se extiende el estudio de conceptos partiendo con los pares Gentil - Agresivo y agregando los pares opuestos Amable - Agresivo, Dinámico - Estático y Elegante – Tosco. Para esto, se analizaron distintos sets de imágenes de copas previamente utilizados en encuestas, que permitieron identificar la presencia de las características de personalidad anteriormente mencionadas. Los resultados de las encuestas, junto con las caracterizaciones numéricas de los descriptores, son usados como datos de entrada en el entrenamiento de una red neuronal artificial supervisada, que aprende a relacionar las características estéticas de los objetos con las características de personalidad que les da la gente.

Finalmente, se logran crear meta-descriptores (combinación de descriptores) para cada par de conceptos.

Los resultados de estos son variados, demostrando que las representaciones deben ser mixtas y los análisis desde distintos aspectos. Hay conceptos que se relacionan más con el contorno y las características más específicas de la forma, mientras que otros se relacionan con la información más general.

Palabras Claves: Personalidad de los objetos, descriptores de forma, aprendizaje supervisado.

Índice general

1. Introducción	1
1.1. Motivación y problema a resolver	1
1.2. Hipótesis	2
1.3. Objetivos	3
1.3.1. Objetivos generales	3
1.3.2. Objetivos específicos	3
2. Estado del Arte	4
2.1. Trabajos relacionados	4
2.1.1. Características geométricas y personalidad en los productos	4
2.1.2. Adjetivos de personalidad	5
2.1.3. Descriptor de forma: Firma basada en la diferencia angular	6
2.2. Técnicas a utilizar	6
2.2.1. Procesamiento digital de imágenes	6
2.2.2. Descriptores de forma	7
2.2.3. Algunos descriptores simples	9
2.2.4. Descriptores basados en contorno	11
2.2.5. Descriptores basados en región	18
2.2.6. Criterios de Selección	18
2.2.7. Redes Neuronales Artificiales	18
3. Discusión y propuesta de trabajo	22
3.1. Trabajo previo	22
3.2. Normalización	23
3.3. Pruebas	23
3.4. Aprendizaje	23

3.5. Análisis	23
4. Desarrollo de la solución	24
4.1. Punto de partida	24
4.2. Firma de contorno: Descriptor de diferencia angular acumulada “A2D2”	25
4.2.1. Resultados	26
4.3. Ponderación: Puntos de interés	27
4.3.1. Obtención de los puntos de interés	28
4.3.2. Ponderación de puntos	30
4.3.3. Análisis de los nuevos resultados	31
4.4. Puntos de interés 1.1	31
4.4.1. Aproximación del contorno	31
4.5. Ponderación: Min, max, sum, prom	36
4.6. Resumen de los resultados	37
4.7. Descriptor de simetría	37
4.8. Meta-Descriptor	40
5. Aprendizaje	42
5.1. Datos de aprendizaje	42
5.1.1. Gentil - Agresivo	44
5.1.2. Amable - Agresivo	45
5.1.3. Dinámico - Estático	46
5.1.4. Elegante - Tosco	47
5.2. Diseño de la red neuronal artificial - OpenCV	47
5.3. Problemas - Leave One Out Cross Validation	48
6. Conclusiones y Trabajo a Futuro	50
6.1. Análisis de objetivos	50
6.2. Trabajo a Futuro	51

Índice de imágenes

2.1. Definición geométrica de un cuchillo	5
2.2. Ejemplo perfiles de personalidad	5
2.3. Logo OpenCV	7
2.4. Esquema de clasificación de los tipos de descriptores de forma [23]	8
2.5. Área de un objeto	9
2.6. Perímetro de un objeto	9
2.7. Rectangularidad de un objeto	10
2.8. Excentricidad de un objeto	11
2.9. Representación gráfica de la similitud basada en correspondencia	12
2.10. Contexto de forma	12
2.11. Firma de forma: Distancia al centroide.	13
2.12. Firma de forma: Longitud de cuerda	14
2.13. Método de espacio escala	16
2.14. Códigos de cadena	17
2.15. Ejemplo de la arquitectura de una red neuronal artificial	19
2.16. Neurona	20
4.1. Firma de contorno: Descriptor de diferencia angular acumulada	25
4.2. Puntos de inflexión	27
4.3. Puntos fuertes.	27
4.4. Sentido de giro en el contorno	28
4.5. Calculo de pendientes	29
4.6. Ejemplo de ponderación de puntos fuertes	30
4.7. Aproximación por mínimos cuadrados	33
4.8. Funcionamiento algoritmo Douglas-Peucker	34

4.9.	<i>Comparación del resultado de las aproximaciones por mínimos cuadrados y con approx-PolyDP.</i>	35
4.10.	<i>Descriptor de simetría: Mariposa dividida por un eje central</i>	38
4.11.	<i>Explicación del funcionamiento del descriptor de simetría</i>	39
5.1.	<i>Ejemplo de encuesta. Encuesta: Amable - Agresivo</i>	43
5.2.	<i>Set de imágenes usadas en el análisis de los conceptos: Gentil - Agresivo</i>	44
5.3.	<i>Set de imágenes usadas en el análisis de los conceptos: Amable - Agresivo</i>	45
5.4.	<i>Set de imágenes usadas en el análisis de los conceptos: Dinámico - Estático</i>	46
5.5.	<i>Set de imágenes usadas en el análisis de los conceptos: Elegante - Tosco</i>	47
5.6.	<i>Topología de la RNA usada</i>	48
5.7.	<i>Ejemplo de validación cruzada</i>	49

Índice de tablas

4.1. Resultados Gentil - Agresivo.	26
4.2. Resultados Amable - Agresivo.	26
4.3. Resultados Dinámico - Estático.	26
4.4. Resultados Elegante - Tosco.	26
4.5. Resumen de errores.	26
4.6. Resumen de errores puntos de interés.	31
4.7. Comparación de resultados de A2D2.	35
4.8. Comparación resultados de los puntos de interés aproximados.	36
4.9. Comparación de los resultados de aproximar por distancia mínima, máxima, suma o promedio.	37
4.10. Resumen de resultados de los distintos descriptores.	37
4.11. Tabla de resultados de simetría para cada imagen de los sets.	40
4.12. Resultado de los descriptores simples junto con el descriptor de simetría.	41
4.13. Resumen de los meta-descriptores.	41
5.1. Tabla resumen de los datos de las encuestas: Gentil - Agresivo.	44
5.2. Tabla resumen de los datos de las encuestas: Amable - Agresivo.	45
5.3. Tabla resumen de los datos de las encuestas: Dinámico - Estático.	46
5.4. Tabla resumen de los datos de las encuestas: Elegante - Tosco.	47

Capítulo 1

Introducción

1.1. Motivación y problema a resolver

En un principio, el desarrollo de productos estaba basado en la idea de cubrir las necesidades funcionales de la gente, pero la mejora de las tecnologías de fabricación y la globalización hicieron que la oferta de productos que cubren esas necesidades creciera e hicieron que el consumidor fuera más exigente y buscara algo más que solo la funcionalidad.

Es por esto, que actualmente el proceso de desarrollo de un producto es mucho más complejo y tiene nuevos factores a considerar como la elección del material, el método de fabricación, la forma en que el producto es publicitado, costo, facilidad y entendimiento del uso, entre otros. Sin embargo, lo que en muchos casos no se considera es la fuerte componente emocional que tiene el diseño del producto [1].

El apego con un producto se define como el vínculo emocional que experimenta el consumidor con un objeto [2]. La razón de esta sensación de apego ha sido ampliamente estudiada [1], [3], [4]. Uno de los motivos, es la sensación de que el producto comparte características similares a las propias y, de esta forma, ayuda a expresar la identidad a la persona [5]. A estas “características similares” las llamaremos “la personalidad del producto”, término introducido por Patrick Jordan y que él define como: “el conjunto de características de la personalidad humana utilizado para describir una variante específica del producto” [6].

Anteriormente, ya se hablaba de los sentimientos y su relación con los productos. Por ejemplo, la Ingeniería Kansei, inventada en la década del 1970 por Mitsuo Nagamachi [7], [8], es una metodología de desarrollo de productos orientada al usuario, que establece los procedimientos para traducir las percepciones, gustos y sensaciones que manifiesta el consumidor acerca del producto, en términos de requisitos

o elementos de diseño y viceversa [9].

Pero la pregunta ahora es, ¿Por qué se siente que se comparten características con los productos? ¿En qué parte del objeto está la “personalidad”? Las respuestas a estas preguntas son de gran interés para los diseñadores, quienes buscan estimular la experiencia de unión a través del diseño del producto.

Es por esto que se necesita encontrar una forma de describir los objetos y encontrar cuál de todas las características que tiene es la que refleja la personalidad. Según Janlert y Stolterman, la personalidad del producto puede basarse en la forma, en el color, textura, olor o incluso el sonido puede ser relevante para definirla [10]. Entre todas estas características, esta memoria sea ha centrado en la forma, específicamente en el contorno de la forma en 2D, por ser el aspecto que más se relaciona con la apariencia estética de un producto [11].

En los estudios hechos por Prieto *et al.* [12] se ha verificado la existencia de una correlación entre la forma y la percepción de personalidad, realizando una serie de encuestas y análisis estadístico de los resultados.

La investigación en el contexto de este trabajo de memoria se enfoca en la **identificación de características y métodos de medición para evaluar cuantitativamente la personalidad del producto en objetos 2D, en blanco y negro.**

Para esto se desarrollan descriptores de la forma, continuando el trabajo realizado por Zuñiga *et al.* [13], implementando un nuevo descriptor basado en el descriptor *accumulated angular difference descriptor* (A2D2), extendiendo el análisis y buscando mejorar los resultados obtenidos en la investigación.

1.2. Hipótesis

Dado lo anterior, se generan diferentes cuestionamientos, tales como “¿Se pueden crear descriptores lo suficientemente precisos que logren describir los rasgos más importantes de un cuerpo?”, “¿Es factible que un computador logre identificar la “personalidad” de los objetos, tal cual lo haría una persona?”.

Según estas preguntas, se plantea la hipótesis: “**Es posible crear una técnica que logre asociar de manera automatizada, la forma de los objetos con las características de personalidad que los usuario perciben de ellos**”.

1.3. Objetivos

1.3.1. Objetivos generales

Desarrollar una metodología que permita, a través de la extracción automática de características visuales, categorizar de manera cuantitativa un objeto según sus atributos estéticos.

1.3.2. Objetivos específicos

Los objetivos específicos del trabajo son los siguientes:

- I. **Implementación de algoritmos para la extracción de las características geométricas más importantes de un objeto.**
- II. **Aprendizaje supervisado de grupos de objetos según atributos estéticos (personalidad):** esto se realizará a través de las características visuales de una base de datos de objetos previamente definida. Esta base de datos se encontrará etiquetada con atributos estéticos determinados a través de análisis previo de focus groups.
- III. **Análisis de nuevos objetos para corroborar el correcto aprendizaje de la identificación de las personalidades.**

Capítulo 2

Estado del Arte

En el presente capítulo se muestran soluciones existentes y trabajos relacionados con esta investigación para luego explicar las técnicas que se utilizaron, dando especial énfasis a los descriptores de forma, junto con las herramientas que han sido usadas en el transcurso de esta memoria.

2.1. Trabajos relacionados

Tal como se mencionó anteriormente, la base principal de esta memoria corresponde al trabajo de Zuñiga *et al.* [13]. No obstante, pese a que no existan fuentes que cubran cabalmente con el objetivo, otras investigaciones han brindado herramientas y conocimientos importantes para el desarrollo del presente proyecto, las cuales se muestran a continuación.

2.1.1. Características geométricas y personalidad en los productos

El trabajo realizado por Chen *et al.* [21] logra relacionar características de la forma de cuchillos con percepciones de personalidad. La investigación se centró en el establecimiento de definiciones precisas de la forma del producto y en el estudio de la correlación estadística entre las características de la forma y la respuesta de los consumidores. Los resultados presentados muestran la viabilidad del método vinculando características geométricas con personalidades de productos. El problema de la metodología expuesta, es que hace necesario desarrollar una definición detallada de la forma para cada producto (**ver imagen 2.1**), lo que no permite extender la investigación a una gama de productos diferentes para averiguar si existe una relación universal entre la personalidad del producto y las características geométricas.




Imagen 2.1: Completa definición geométrica de la forma de un cuchillo [21].

2.1.2. Adjetivos de personalidad

Por otro lado, el trabajo hecho por Mugge *et al.* [22] es de gran utilidad, pues no solo afirma que las características de personalidad dadas por las personas a los objetos afectan la forma en que se relacionan con ellos, sino que además, entrega criterios para escoger los adjetivos de personalidad a usar.

Ya que el análisis hecho en el trabajo considera el color, es probable que existan adjetivos que toman relevancia solo si se toma en cuenta esta característica. Es por esto que los criterios usados servirán para escoger bien los adjetivos de personalidad para nuestro trabajo usando los resultados de este trabajo, pero modificándolos para generar nuestra propia lista de adjetivos de personalidad.




Imagen 2.2: Perfiles de personalidad de dos autos [22].

En la imagen 2.2 se pueden ver los adjetivos de personalidad finales usados en el estudio y el análisis de dos tipos de autos.

2.1.3. Descriptor de forma: Firma basada en la diferencia angular

Por último, en el trabajo de Zuñiga *et al.* [13] se presenta el descriptor de **firma basada en la diferencia angular**, el cual se centra en los cambios angulares en el contorno de los objetos (el descriptor es explicado más adelante en **sección 4.2**) y los relaciona con los conceptos *gentileza* y *agresividad*, esto a través de aprendizaje supervisado con redes neuronales artificiales.

El mismo esquema se utiliza en esta memoria, extendiendo los conceptos con los que se analizan los objetos, además de los descriptores de forma.

2.2. Técnicas a utilizar

2.2.1. Procesamiento digital de imágenes

Si consideramos el procesamiento digital de imágenes como “*el conjunto de técnicas que se aplican a las imágenes digitales con el objetivo de mejorar la calidad o **facilitar la búsqueda de información***” [14], podemos decir que este trabajo se enfoca principalmente en esta tarea: buscar y extraer información de las imágenes de siluetas de objetos, que permita crear las caracterizaciones numéricas de su forma.

2.2.1.1. OpenCV

Para la realización de esta memoria se utiliza la biblioteca OpenCV (Open Source Computer Vision). Esta biblioteca, escrita en C/C++, multiplataforma y de uso libre con licencia BSD, está principalmente enfocada a la visión por computador en tiempo real. Esto la convierte en una herramienta indispensable, ya que facilita la tarea de implementar los algoritmos de descripción que se usan para caracterizar numéricamente las siluetas.



Imagen 2.3: *Logo OpenCV.*

2.2.1.2. Video Analysis Tool (VAT)

Además, todo el desarrollo de esta investigación esta reflejado en el software VAT (Video Analysis Tool) [16], en el módulo *PersonalityModule* que busca generar un aporte a futuras investigaciones y aprovechando las herramientas ya desarrolladas en el mismo software.

El procesamiento digital de imágenes, junto con las herramientas anteriormente detalladas, sirven como base para generar los descriptores de forma, lo que se desea relacionar con las características de personalidad.

2.2.2. Descriptores de forma

Los descriptores de forma son representaciones de objetos que tienen como objetivo, tal como lo dice su nombre, describir numéricamente la forma de un elemento. Estos son un tema ampliamente tratado [17] [18] [19] [20] [13] en la literatura, principalmente usados en la búsqueda de objetos similares, para reconocimiento, clasificación o comparación de ellos. La gran pregunta es: ¿Cómo encontramos características geométricas de forma que sean lo suficientemente significativas para representar a los objetos de interés?

Como se mencionó anteriormente, este trabajo analiza objetos en 2D, en blanco y negro, tarea que presenta algunas dificultades, debido a que al transformar un objeto 3D en uno 2D, mucha información relevante se pierde, por lo que la representación del objeto es sólo parcial, pero es un buen punto de partida y los resultados entregarán líneas generales para futuras investigaciones.

2.2.2.1. Tipos de descriptores y categorías

De todos los trabajos desarrollados, el trabajo realizado por Zhang *et al.* [23] es uno de los más completos y entrega un entendimiento general de la clasificación, ramificación y funcionamiento de los métodos para obtener un descriptor.

Según los autores, los descriptores de forma se dividen en dos grupos, los **basados en la información del contorno** y los **basados en la región**. La diferencia radica en el origen de la información: el primer grupo solo utiliza la información de los bordes, mientras que el segundo utiliza la información de toda la región, los bordes y todo lo que hay dentro. Además, ambos métodos se dividen en otros dos subgrupos: **los estructurales o discretos** y **los globales o continuos**. La diferencia está en si consideran los objetos como un todo o si lo dividen en varios segmentos. Finalmente, estos pueden ser diferenciados dependiendo del dominio en que se generen los descriptores, desde el **dominio espacial** o desde el **dominio de transformación** (e.g. **dominio de frecuencia**).




Imagen 2.4: Esquema de clasificación de los tipos de descriptores de forma [23].

Es importante, considerar en un buen descriptor, no solo la calidad de la caracterización numérica, sino también que el método empleado sea robusto y tenga la capacidad de detectar y corregir problemas como ruido, distorsión y rotación, entre otros. Además, debe ser eficiente y con baja complejidad computacional, para así poder manejar múltiples imágenes sin ocupar excesivos recursos computacionales.

A continuación se explican las distintas alternativas de solución para la formulación de descriptores. Se revisan sus características principales, sus métodos de funcionamiento, ventajas y desventajas, con el fin de evaluar su uso en la obtención de características geométricas que pudiesen ser relacionadas con las

percepciones de personalidad de los objetos.

Primero se analizan algunos descriptores simples, siguiendo con descriptores de contorno, para luego terminar con los de región.

2.2.3. Algunos descriptores simples

2.2.3.1. Área

Número de píxeles en la silueta del objeto.




Imagen 2.5: Área de un objeto.

2.2.3.2. Perímetro

Número de píxeles en el contorno del objeto.




Imagen 2.6: Perímetro de un objeto.

2.2.3.3. Circularidad / Capacidad de compactación

Define qué tan estrechamente esta compactada la forma del objeto.

Se calcula como:

$$c(o) = \frac{\text{perimetro}(o)^2}{\text{area}(o)} \quad (2.1)$$

Donde o es la forma en 2D del objeto analizado.

El objeto más compacto es el círculo que posee una circularidad de (4π) . Toda otra forma tiene una circularidad mayor.

2.2.3.4. Rectangularidad

Define qué tan rectangular es un objeto, se calcula como:

$$r(o) = \frac{\text{area}(o)}{H * W} \quad (2.2)$$

Donde o es la forma en 2D del objeto analizado, mientras que H y W son el alto y ancho de la caja englobante respectivamente (ver imagen 2.7).




Imagen 2.7: Rectangularidad de un objeto.

2.2.3.5. Excentricidad

Se define como la relación de la longitud de la cuerda más larga del objeto ($L1$) con la cuerda más larga perpendicular a ella ($L2$).

$$e(o) = \frac{L1}{L2} \quad (2.3)$$




Imagen 2.8: Excentricidad de un objeto. Las rectas L1 y L2 son las más largas y perpendiculares entre sí.

El problema de estos descriptores es que, al ser muy generales, solo permiten caracterizar formas con diferencias muy notorias y generarían, aún en conjunto, descripciones idénticas para formas distintas.

2.2.4. Descriptores basados en contorno

Los descriptores de contorno se basan en la información que pueda entregar el perímetro del objeto, dejando de lado el interior de este. Normalmente se dividen en dos categorías: los descriptores globales, que utilizan los bordes completos como una única fuente de información, y los métodos estructurales, los cuales dividen el borde en segmentos llamados primitivas.

2.2.4.1. Similitudes basadas en correspondencia

Este método encuentra la similitud entre las formas, midiendo la correspondencia punto a punto. Para esto se mide la distancia entre los puntos de los objetos a comparar, normalmente a través de la distancia de Hausdorff [24], la cual mide la distancia entre las figuras, representadas por un conjuntos de puntos $X = (x_1, x_2, x_3, \dots, x_n)$ e $Y = (y_1, y_2, y_3, \dots, y_n)$.

La distancia de Hausdorff entre las figuras se define como:

$$d_H(X, Y) = \max\left\{\sup_{x \in X} \inf_{y \in Y} d(x, y), \sup_{y \in Y} \inf_{x \in X} d(x, y)\right\} \quad (2.4)$$

siendo *sup* el supremo, *inf* el ínfimo y $d(x, y)$ la distancia euclidiana.

Informalmente, la distancia de Hausdorff es la distancia más grande de todas las distancias desde un punto en un conjunto hasta el punto más cercano del otro conjunto.




Imagen 2.9: Representación gráfica del método.

En la **imagen 2.9** se muestran las mayores distancias entre los conjuntos de puntos X e Y , la mayor de esas dos es la distancia de Hausdorff.

Esta no es invariante a la rotación, traslación y escalamiento entre los objetos. Para solucionar estos problemas hay que comparar los objetos variando cada uno de estos parámetros, lo que hace que el método sea extremadamente caro.

Este método puede ser mejorado utilizando el contexto de la forma propuesto por Belongie *et al.* [25]. El método extrae una característica global, llamada contexto de forma, para cada punto del contorno y luego utiliza estos contextos para hacer la comparación entre los objetos.




Imagen 2.10: (a) Objeto original; (b) Contorno de (a); (c) Vectores desde un punto p ; (d) Mapa de histograma; (e) Contexto de la imagen.

Para extraer el contexto de la forma en un punto p , se calculan todos los vectores de p a cada uno de los puntos del borde del objeto (**ver imagen 2.10 (c)**). Luego se toman todos los largos (r) y las orientaciones θ de los vectores para crear un mapa de histograma, que es usado para representar el punto p como se observa en la **imagen 2.10 (d)**, en donde el eje θ representa el ángulo con respecto a cada vector en **2.10 (c)** y el eje $\log r$ representa el logaritmo del radio r . El histograma de cada punto se aplanan y se concatenan. De esta forma cada fila del contexto de forma (**ver imagen 2.10 (e)**) es un histograma aplanado de un

punto, por lo tanto el numero de filas es el número de muestras del contorno. La similitud entre dos formas se realiza mediante la correspondencia de los dos mapas de contexto de las formas.

2.2.4.2. Firmas de forma

Estas representan la forma como una función unidimensional $r(t)$ obtenida con la información de los puntos del contorno de la figura $(x(t), y(t))$ con $t=0, 1, \dots, N-1$, siendo N la cantidad de puntos a utilizar del contorno. Existen muchos tipos de firmas: distancia al centroide, ángulo tangente, coordenadas complejas, ángulo acumulativo, curvatura, longitud de cuerda, entre otros.

Las firmas de forma generalmente están normalizadas para que sean invariantes en la escala y traslación. El problema de estos descriptores es que son muy sensibles al ruido y ligeros cambios en la frontera pueden originar grandes cambios en la representación.

2.2.4.2.1 Distancia al centroide

Esta función es calculada como la distancia entre los puntos del borde y el centroide de la figura (x_c, y_c) .

$$r(t) = \sqrt{[x(t) - x_c]^2 + [y(t) - y_c]^2} \quad (2.5)$$

donde

$$x_c = \frac{1}{N} \sum_{t=0}^{N-1} x(t) \quad (2.6)$$

$$y_c = \frac{1}{N} \sum_{t=0}^{N-1} y(t) \quad (2.7)$$

$r(t)$ es invariante a la traslación. La rotación crea un desfase en la representación y el escalamiento modifica linealmente $r(t)$.




Imagen 2.11: (a) Forma de una manzana. (b) Bordes de la manzana(a). (c) Representación a través de la distancia al centroide [19].

2.2.4.2.2 Firma de longitud de cuerda

Este método, introducido en [26], busca solucionar el problema de las figuras no convexas, en donde el centroide queda fuera de la forma, pero más importante aún es que según el autor este método puede generar descriptores similares para un mismo objeto que ha sido deformado.




Imagen 2.12: Diferencias entre firma de *distancia al centroide* y *longitud de cuerda*. (a) y (b): Formas de serpiente con distintas deformaciones; (c) y (d): Firmas de distancia al centroide de (a) y (b) respectivamente; (e) y (f): Peaks de las firmas (c) y (d); (g) y (h): Firmas de longitud de cuerda de (a) y (b) [26].

En la **imagen 2.12** se puede apreciar la diferencia entre la firma basada en el centroide (c) y (d) y la de longitud de cuerda (g) y (h).

La metodología, en vez de utilizar el centroide como punto de referencia, utiliza otro punto de la frontera p' que se encuentre perpendicular a la tangente del punto analizado p . En caso de existir otro punto, como es el caso en **imagen 2.12 (a)** donde p_1 también es un punto perpendicular a p , se analizan los puntos medios de todos los posibles puntos de referencia. Si alguno de esos puntos medios quedara fuera de la imagen, el punto de referencia correspondiente queda fuera.

El problema de este método es ser muy sensible al ruido en la imagen y, al igual que otros métodos invariantes a la traslación, la rotación crea un desfase y el escalamiento modifica la representación linealmente.

2.2.4.3. Momentos de la frontera

Los momentos de frontera son usados para disminuir la representación de los bordes. Asumiendo que el borde ha sido representado por una firma de forma $z(i)$, el r -ésimo momento m_r y el momento central μ_r se puede calcular por:

$$m_r = \frac{1}{N} \sum_{i=1}^N [z(i)]^r \quad (2.8)$$

$$\mu_r = \frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^r \quad (2.9)$$

Siendo N el número de puntos en la frontera. Los momentos normalizados son:

$$\overline{m_r} = \frac{m_r}{\mu_2^{\frac{r}{2}}} \quad (2.10)$$

$$\overline{\mu_r} = \frac{\mu_r}{\mu_2^{\frac{r}{2}}} \quad (2.11)$$

Estas representaciones son invariantes a traslación, rotación y escalamiento. El problema es que, aunque su implementación es muy sencilla, no es simple asociarlas a interpretaciones físicas.

2.2.4.4. Método de espacio escala

Este método analiza y crea la representación de forma de los objetos a través del estudio, a distintas escalas, de los puntos de inflexión del borde, utilizando un filtro Gaussiano Pasa Bajo de variable σ . Al aumentar esta variable, los puntos de inflexión insignificantes van desapareciendo, quedando únicamente la forma “principal”, que es la forma suavizada del original. Los puntos de inflexión restantes son los más significativos, por lo que representan de mejor forma al objeto (**ver imagen 2.13 (a)**).




Imagen 2.13: (a) Evolución de la forma, disminución de los puntos de inflexión; (b) Gráfica de la evolución de los puntos de inflexión. Imagen CSS; (c) Peaks del gráfico CSS.

Como se decía anteriormente el método va suavizando la imagen en cada iteración. La imagen de *curvature scale space* o CSS (ver imagen 2.13 (b)) se construye con la información de cada una de esas iteraciones, mapeando los puntos de inflexión durante el paso de cada filtro gaussiano. De esta forma en el eje x se representan las posiciones de los puntos de inflexión en el contorno y en el eje y el “ σ ” desde cero hasta el valor en el que no quedan puntos de inflexión. El método procesa cada límite de la imagen CSS, encontrando los puntos máximos de los contornos y usándolos como descriptores de formas para comparar objetos (ver imagen 2.13 (c)).

Este método, introducido por Mokhtarian *et al.* en [27], utiliza los picos para la correspondencia entre dos curvas a analizar. Para cada correspondencia individual, la ramificación del contorno tiene que ser escalada y acomodada de tal manera que sea invariante a traslación y al escalamiento. Además, el algoritmo es robusto con respecto al ruido y rotación.

Un aspecto muy importante del método es que guarda información de cada convexidad de la forma de la imagen, ya que cada una tiene su propio contorno en la imagen CSS.

2.2.4.5. Descriptor Discreto de Fourier

El descriptor de Fourier es muy popular por ser invariante a la rotación, escala y traslación. Es por este motivo, que son muchos los trabajos realizados con este método [18], [19], [28], [29].

Este utiliza como base una función $r(t)$, obtenida a través de algún descriptor del tipo 2.2.4.2 Firmas de

forma, a la cual se le aplica la Transformada de Fourier para obtener los coeficientes.

$$a_n = \frac{1}{N} \sum_{t=0}^{N-1} r(t) \exp\left(\frac{-j2\pi nt}{N}\right), n = 0, 1, \dots, N-1 \quad (2.12)$$

Las magnitudes de los coeficientes $a_n (n = 0, 1, \dots, N-1)$ normalizados por la magnitud a_0 son usadas como el descriptor de forma. Estos descriptores representan la forma en el dominio de la frecuencia. Los coeficientes de frecuencias bajas contienen información de la forma en general, mientras que los de altas frecuencias contienen información de los detalles pequeños [30].

Existen varias modificaciones a este descriptor para los casos donde el borde del objeto no se encuentra completo, pero como ya sabemos con anterioridad que en los casos de estudio de este trabajo siempre lo están, se eliminan del estudio.

2.2.4.6. Códigos de cadena

Este método describe la forma a través de sucesiones de segmentos de igual tamaño [31]. Para su realización, es necesaria la superposición de una grilla, para luego, aproximar la forma del objeto a los puntos de intersección de esta (**ver imagen 2.14**).




Imagen 2.14: (a) Aproximación de la forma a través de una grilla superpuesta; (b) Análisis de la forma a través de conectividad 8 (c). El código resultante es 0,1,7,0,0,7,5,4,4,4,4,2,2 usando como punto de partida el de más a la izquierda.

Primero se selecciona un punto de inicio y desde ahí se genera el código de cadena a través de conectividad 4 u 8, anotando la secuencia con la que se ha recorrido la frontera del objeto. Para que el método solo entregue un código por figura, es necesario normalizar el punto de partida. Un método es elegir como pixel inicial aquel que genere el código menor.

El problema del código de cadena es que es muy sensible al ruido y de dimensiones grandes.

2.2.5. Descriptores basados en región

Los descriptores de región obtienen la información a través del análisis de toda la figura, no solo el contorno del objeto. Al igual que los anteriores, se dividen en dos categorías: los descriptores **globales**, que utilizan el objeto completo como una única fuente de información, y los métodos **estructurales**, los cuales dividen el objeto en segmentos llamados primitivas.

Existen muchos descriptores de región tales como: “Momentos invariantes geométricos” [32], “Momentos invariantes algebraicos” [33], “Momentos ortogonales” [34] y “Descriptores generales de Fourier” [35].

Sin embargo, se toma la decisión de solo utilizar los de contorno, pues se piensa que los de región entregan información redundante, son complejos computacionalmente y en la práctica, la primera vez que se ve un objeto, los ojos comienzan a moverse primero alrededor del contorno del objeto [13].

2.2.6. Criterios de Selección

Un buen descriptor es aquel que considera no solo la calidad de la caracterización numérica, sino también que sea robusto al detectar y corregir problemas tales como ruido, distorsión y rotación. Además, es de esperar que sea de baja complejidad computacional, para poder manejar múltiples imágenes sin ocupar excesivos recursos.

El problema de los descriptores, en general, es el enfoque con el que han sido desarrollados. Como se ha mencionado anteriormente, su elaboración está enfocada en la búsqueda de similitudes física entre ellos, para clasificarlos, reconocerlos y compararlos. Es por esto que muchos de ellos no son de utilidad para los objetivos de esta investigación.

Los descriptores de la sección 2.2.3 son considerados directamente como parte de la solución escogida, ya que no presentan complejidad alguna en su implementación y dan información base para el o los descriptores escogidos.

Teniendo esto en cuenta, en el próximo capítulo se explica como se aborda el problema de la descripción de los objetos.

2.2.7. Redes Neuronales Artificiales

El fin del desarrollo de los descriptores anteriormente mencionados, es lograr una relación entre las características geométricas y las características de personalidad que la gente percibe de los objetos. Para

lograr esta tarea, se implementa un sistema de aprendizaje supervisado llamado **redes neuronales artificiales**. Estos algoritmos están inspirados en el funcionamiento biológico del cerebro humano, generando interconexiones de las neuronas artificiales como el cerebro lo hace con las neuronas cerebrales.

Las redes neuronales artificiales, en su práctica más elemental, usan algoritmos para procesar información, aprender de ella, y luego hacer una determinación o predicción acerca de algo en el mundo. Para esto la red es “entrenada” usando grandes cantidades de información y algoritmos que le dan la habilidad de aprender cómo realizar la tarea.




Imagen 2.15: Ejemplo de la arquitectura de una red neuronal artificial. Una capa de entrada de tamaño N , una de salida de tamaño M y varias ocultas que pueden ser de varios tamaños.

La morfología de una red puede ser variada, dependiendo de la aplicación que se le vaya a dar a la red. Todas poseen varias capas de neuronas que se interconectan entre sí. Las neuronas de una capa afectan a las de la siguiente capa y así sucesivamente hasta la capa final de salida (ver imagen 2.15).

2.2.7.1. Tipos de capas

Estas pueden agruparse en tres:

1. **Capa de entrada:** Esta capa es la que recibe los datos del exterior, por lo que necesita tener una cantidad de neuronas igual a la cantidad de datos que se le van a entregar a la red. Estos pueden ser los datos para el entrenamiento de la red o los datos a analizar una vez que la red ya ha sido entrenada.

- II. **Capas intermedias u ocultas:** Estas capas son las encargadas de hacer el procesamiento de la información. Mientras más capas, existe una mayor cantidad de posibilidades de combinación de los datos, pero aumenta la complejidad de la red y el tiempo de procesamiento. Más capas no implica mejores resultados, y lamentablemente no hay un método estándar para definir la cantidad y tamaño de estas, por lo que es un proceso que se decide a base de “prueba y error”.
- III. **Capa de salida:** Esta capa entrega los resultados de la red y tendrá tantas neuronas como componentes tengan las salidas deseadas.

2.2.7.2. Neuronas y conexiones

La neurona es la unidad mínima de la red y es la encargada del procesamiento de la información. Esta recibe la información de las neuronas de la capa anterior, procesa la información y transmite el resultado a través de conexiones a las neuronas de la capa siguiente, siempre y cuando el resultado supere un umbral U dado.

En una red neuronal ya entrenada, cada una de las conexiones tiene un peso W_n que determina la interacción entre las neuronas.




Imagen 2.16: Neurona con X_n conexiones de entrada y pesos W_n .

De esta forma, cada neurona procesa la información recibida a través de una función f . Esta función utiliza los valores X_n recibidos desde las neuronas de la capa anterior y las pondera por su correspondiente peso W_n . Por esto, una neurona dará más importancia a la información que le llegue por una conexión de peso mayor que a otra con menor.

Un modelo simple de la función f sería:

$$f = X_1W_1 + X_2W_2 + \dots + X_nW_n \quad (2.13)$$

Si el resultado de la función f es mayor que el valor umbral U , la neurona se activa y emite una señal

hacia las neuronas de la capa siguiente. Pero, si por el contrario, el resultado es menor que el valor umbral, la neurona permanece inactiva.

De esta forma, definido un conjunto inicial de pesos y umbrales, al presentarse un estímulo en la capa de entrada, cada neurona en cada capa realiza la operación descrita anteriormente, activándose o no, de manera que al final del proceso las neuronas de la capa de salida generan un resultado, que puede coincidir o no con el que se desea asociar el estímulo.

En el entrenamiento de una red neuronal artificial, esta es alimentada con muchos datos etiquetados. Estos datos consisten en pares de información, compuestos por un vector de entrada y el valor de salida esperado para la entrada dada. En este proceso se modifican tanto el peso sináptico de las conexiones W_n como el valor umbral U_n , con el fin de que los resultados generados por la red coincidan o se aproximen lo más posible a los resultados esperados.

Finalmente, con este sistema se busca encontrar una función capaz de predecir el valor de salida (característica de personalidad) para cualquier vector de entrada válido. En el caso particular de esta investigación, se usarán sets de imágenes entregados por diseñadores y rotulados con las percepciones de personalidad que le dieron las personas al momento de ser encuestadas.

Esto es explicado más adelante en detalle en el **Capítulo 5**.

Capítulo 3

Discusión y propuesta de trabajo

Para maximizar la calidad de la representación de los objetos, la alternativa seleccionada es una combinación de distintos descriptores de forma para lograr una mejor relación con las percepciones de personalidad.

Preliminarmente, se prueban los siguientes descriptores.

Se seleccionan los siguientes tipos de descriptores directamente: **área, perímetro, circularidad, rectangularidad y excentricidad**. Además, se continúa con el descriptor **Firma de forma: Diferencia angular**.

Según lo visto en el estado del arte, se buscará potenciar este último y se complementará con el descriptor de **simetría**.

Los descriptores seleccionados trabajan a distintos niveles y de distintas formas, por lo que se probarán independientemente y luego se irán combinando en un meta-descriptor.

Además de esto, en este estudio se abarcan más pares de conceptos que los usados en la investigación de *Zuñiga et al.*, por lo que es necesario partir probando los nuevos conceptos para tenerlos como base y luego ir comprobando el comportamiento de los nuevos descriptores.

3.1. Trabajo previo

Las imágenes utilizadas para este trabajo serán previamente analizadas por personas de distintas nacionalidades, culturas y especialidades, con el fin de eliminar la influencia que puedan tener estos aspectos en

los resultados. Se les pedirá que identifiquen en ellas aspectos de personalidades previamente rotuladas y que cuantifiquen según su criterio qué tan presentes están estos conceptos en cada una de las imágenes.

3.2. Normalización

Las imágenes deberán pasar por un proceso de normalización, eliminando cualquier tipo de ruido presente. De esta forma se evita que algunas imágenes tomen relevancia equivocadamente sobre otras, previniendo que las representaciones posteriores posean errores.

3.3. Pruebas

Con las imágenes preparadas se procede a hacer las pruebas y estudios necesarios para tener las representaciones numéricas de las imágenes, que se usarán en el proceso de aprendizaje supervisado.

3.4. Aprendizaje

A través del aprendizaje supervisado se buscará encontrar de qué forma la suma de las representaciones de los descriptores se relaciona con las personalidades. Así se obtendrán meta-descriptores que no serán más que los descriptores anteriores ponderados de forma que representen alguna personalidad del objeto.

3.5. Análisis

Una vez finalizado el trabajo quedará a disposición una herramienta que permitirá revisar cualquier imagen, entregando en detalle una estimación cuantitativa de cada concepto estético estudiado en relación a la personalidad del objeto.

Capítulo 4

Desarrollo de la solución

En este capítulo se describe el proceso de investigación de los distintos descriptores anteriormente seleccionados. Tal como se menciona en el Estado del Arte, se inicia con lo desarrollado en "*Quantifying shape descriptors for aesthetic concepts*" [13] por *Zuñiga et al.* y se extiende esta investigación, incluyendo más conceptos de personalidad a analizar y métodos de descripción, con el fin de desarrollar un meta-descriptor.

Se detallarán las pruebas realizadas sean exitosas o no.

4.1. Punto de partida

En "*Quantifying shape descriptors for aesthetic concepts*", se analizaron únicamente los conceptos *Gentil - Agresivo*. En esta memoria se extiende la investigación, agregando los pares de conceptos *Amable - Agresivo*, *Dinámico - Estático* y *Elegante - Tosco*.

El desarrollo de este capítulo está ordenado de la siguiente forma:

1. Prueba del **descriptor de diferencia angular acumulada (A2D2)** con todos los conceptos. Este resultado sirve como parámetro de comparación con el resto de los descriptores.
2. Desarrollar, probar y combinar los descriptores anteriormente mencionados.
3. Comparación de resultados.

Los conceptos que fueron analizados están asociados a distintos sets de imágenes, que fueron parte de encuestas hechas a distintas personas. Gracias a estas encuestas se puede saber el grado de pertenencia a

un concepto o a otro (cada set se relaciona únicamente con un par de conceptos opuestos).

Sobre las encuestas se habla más adelante en el **Capítulo 5**.

4.2. Firma de contorno: Descriptor de diferencia angular acumulada “A2D2”.

Esta firma, utilizada en [13] recorre los puntos de la frontera de la figura calculando el ángulo entre cada punto contiguo, para luego obtener la diferencia entre ángulos consecutivos. Esta diferencia es acumulada en un histograma que permite ver fácilmente la agresividad o suavidad de cambio en la frontera de la forma.




Imagen 4.1: Proceso de extracción de los cambios de dirección de la frontera de la forma [13].

Este método es invariante a la traslación y a la rotación; y el escalamiento modifica la representación linealmente.

Específicamente, el proceso de descripción de A2D2 contempla los siguientes pasos:

1. Se obtiene el contorno de las imágenes a utilizar, representando cada contorno como un vector de puntos.
2. Se obtienen los ángulos entre pares de puntos contiguos (o separados por una distancia constante) para generar la *firma de ángulo del contorno*.
3. Se calcula la diferencia entre los ángulos contiguos y se obtiene la *firma de diferencia angular*.
4. Se realiza el *histograma de diferencia angular*, contabilizando la firma anterior en un set definido de bins.
5. Por último, cada uno de estos bins se toma como una característica del *descriptor de diferencia angular acumulada* y son utilizados como los datos de entrada a la red neuronal artificial.

4.2.1. Resultados

Siguiendo el esquema anteriormente detallado, se obtienen los siguientes resultados de la red neuronal artificial. Cabe recordar que los datos usados son el **promedio** de pertenencia según lo obtenido de las encuestas.

Real	-1.63	-2.6	1.14	2.26	-1.18	-0.11	-2.4	1.2	1.8	0.43
Predicción	-1.76083	-2.02862	1.45911	2.24776	-1.7551	0.0266338	-1.62226	-0.734712	2.70353	0.851154
Error	0.130825	0.571377	0.319111	0.012239	0.5751	0.136634	0.77774	1.93471	0.903533	0.421154

Tabla 4.1: Resultados Gentil - Agresivo.

Real	-2.04	-0.55	-0.91	-1.37	0.6	3.94	-1.36	-2.38	-0.36	2.32
Predicción	-0.40711	1.71063	2.71321	-0.063614	1.06375	-0.292169	5.72725	-0.39302	-4.21803	-0.03818
Error	1.63289	2.26063	3.62321	1.30639	0.463751	4.23217	7.08725	1.98698	3.85803	2.35818

Tabla 4.2: Resultados Amable - Agresivo.

Real	-3.43	3.09	0.85	-0.77	-1.73	0.31	1.85	0.07	-1.73	-1.57
Predicción	-0.0652987	-0.627419	-0.694473	1.03466	1.05307	-1.75428	-2.62618	1.91569	-0.360371	-0.910303
Error	3.3647	3.71742	1.54447	1.80466	2.78307	2.06428	4.47618	1.84569	1.36963	0.659697

Tabla 4.3: Resultados Dinámico - Estático.

Real	-2.83	2.98	-2.11	-1.71	3.12	3.05	-2.31	1.11	-1.83	1.57
Predicción	1.07208	2.08985	-1.25252	-1.22908	-1.53356	4.89253	3.43518	-0.433959	-1.23033	-4.71641
Error	3.90208	0.890146	0.857478	0.480924	4.65356	1.84253	5.74518	1.54396	0.599675	6.28641

Tabla 4.4: Resultados Elegante - Tosco.

	Error promedio
Gentil - Agresivo	0.578242
Amable - Agresivo	2.88095
Dinámico - Estático	2.36298
Elegante - Tosco	2.68019

Tabla 4.5: Resumen de errores.

En la **tabla 4.5** se muestra el error promedio de cada set de imagenes. Se puede ver fácilmente que este descriptor tiene un buen funcionamiento solo con los conceptos *Gentil - Agresivo*, pero con los nuevos pares no tiene tan buen rendimiento.

4.3. Ponderación: Puntos de interés

En una primera instancia, se contempla la obtención de los puntos de inflexión, puntos donde cambia la dirección del giro del contorno de sentido horario a anti-horario o viceversa (**ver imagen 4.2**), y puntos fuertes, puntos del contorno donde se presenta un gran cambio en la diferencia angular (**ver imagen 4.3**), para su posterior ponderación según la distancia a los puntos de interés (puntos de inflexión o puntos fuertes) siguiente y anterior.




Imagen 4.2: Puntos de inflexión.




Imagen 4.3: Figuras con el mismo ángulo a , pero con distinta notoriedad en la imagen.

Al observar la **imagen 4.3**, se puede notar que en ambos casos se tiene el mismo punto fuerte, pese a que es evidente que en la primera, la “punta” es mucho mayor que en la segunda. Esta consideración la debería tener el descriptor, pues están recibiendo la misma ponderación sin importar el perímetro que afectan.

Esto es corregido al ponderar por la distancia (perímetro) a los puntos de interés más cercanos, anterior y posterior, dando como resultado que en la **imagen 4.3** de la izquierda se potencie mucho más esa diferencia angular que en la derecha, aunque ambas tengan la misma.

Respecto a los puntos de inflexión, se piensa que la cantidad de cambios de dirección en el contorno puede tener relación con las percepciones de personalidad que le da la gente a los objetos.

El procedimiento fue el siguiente:

- I. Obtención de los puntos de interés (fuertes o de inflexión).
- II. Ponderación de puntos de interés según la distancia entre ellos.
- III. Análisis de los nuevos resultados.

4.3.1. Obtención de los puntos de interés

Cada punto de interés posee su propio criterio para la detección. Estos son:

4.3.1.1. Punto fuerte

La detección de los puntos fuertes es bastante simple, solo es necesario recorrer el contorno y marcar todo punto donde la diferencia angular sea mayor a α . A través de la experimentación se considera que el mejor valor para α es $\Pi/4$.

4.3.1.2. Punto de inflexión

Un punto será considerado de inflexión si es el lugar del perímetro donde cambia de dirección de giro (ver imagen4.2).

Para poder detectar los cambios de dirección, se analizan los puntos del contorno en grupos de tres, observando las pendientes de las rectas que los unen y de esta forma, obtener la orientación del giro.

Las posibilidades de giro son tres:

1. En sentido horario.
2. En sentido anti-horario.
3. Los puntos son colineales.

La imagen 4.4 muestra las distintas orientaciones posibles de los puntos a , b , c .




Imagen 4.4: (1) Giro anti-horario (2) Giro horario (3) Puntos colineales.

4.3. PONDERACIÓN: PUNTOS DE INTERÉS CAPÍTULO 4. DESARROLLO DE LA SOLUCIÓN

Para poder detectar el giro, se usa la pendiente formada por el primer par de puntos y la pendiente formada por el segundo par (segundo y tercer punto). Dependiendo del cambio de la pendiente se puede determinar la dirección de giro, tal como se muestra en la **imagen4.5**.




Imagen 4.5: Ejemplo pendientes.

Siguiendo el ejemplo mencionado, se calcula la pendiente de ambos segmentos.

Pendiente del segmento $(p1, p2)$:

$$\sigma = (y2 - y1) / (x2 - x1) \quad (4.1)$$

Pendiente del segmento $(p2, p3)$:

$$\tau = (y3 - y2) / (x3 - x2) \quad (4.2)$$

Si $\sigma < \tau$, la orientación es anti-horaria (giro a la izquierda).

Si $\sigma = \tau$, la orientación es colinial.

Si $\sigma > \tau$, la orientación es horaria (giro a la derecha).

Usando los valores de σ y τ , se concluye que la orientación depende del signo de la siguiente expresión:

$$(y2 - y1) * (x3 - x2) - (y3 - y2) * (x2 - x1) \quad (4.3)$$

Si es negativa, es anti-horaria.

Si es 0, es colinial.

Si es positiva, es horaria.

4.3.2. Ponderación de puntos

Una vez que han sido encontrados todos los puntos de interés, se hace la ponderación de ellos. Para esto se han identificado dos casos:

1. Si el punto a ponderar es un punto fuerte, se toma la diferencia angular que hay en él y se pondera por la longitud del perímetro a los puntos de interés más cercanos, anterior y siguiente (**ver imagen 4.6 derecha superior**) En el ejemplo el punto fuerte será ponderado con el valor $a + b$.
2. En el caso de ser un punto de inflexión, solo se pondera si el punto siguiente también es de inflexión. De ser así, se toma la diferencia angular mayor del tramo y se pondera por la distancia entre ellos (**ver imagen 4.6 derecha inferior**). Siguiendo esta lógica, los puntos de inflexión a , b , d y e serán ponderados, pero el punto c no lo será ya que el siguiente punto de interés es un punto fuerte.




Imagen 4.6: Ejemplo de ponderación de puntos fuertes (rojos) y de inflexión (azules). Imagen superior derecha: Ponderación punto fuerte. Imagen inferior derecha: Ponderación punto de inflexión.

4.3.3. Análisis de los nuevos resultados

La implementación de estas ponderaciones no arrojan grandes mejoras en los resultados obtenidos (ver **tabla 4.6**). Los sets *Gentil - Agresivo* y *Elegante - Tosco* empeoran bastante y solo el set *Amable - Agresivo* tiene una mejora considerable.

	A2D2	Puntos de interés
Gentil - Agresivo	0.578242	2.39999
Amable - Agresivo	2.88095	1.89913
Dinamico - Estatico	2.36298	2.27973
Elegante - Tosco	2.68019	3.42369

Tabla 4.6: Resumen de errores puntos de interés.

Se cree que es por la contaminación en los datos del contorno, producto del exceso de información considerada y la digitalización de la imagen.

Al tomar todos los puntos del contorno de una imagen digital, se están tomando también los cambios a nivel de pixel. Esta información, imperceptible por el ser humano, “es capturada y procesada por los algoritmos”, dando como resultado información equivocada (falsos positivos).

4.4. Ponderación: Puntos de interés 1.1

Tomando en consideración lo aprendido en el desarrollo de la propuesta anterior, se piensa que parte del problema del descriptor A2D2 es la consideración de puntos con diferencias angulares iguales o cercanas a cero, o puntos con cambios fuertes que solo existían a nivel de pixel, los cuales terminaban, “escondiendo” los cambios de interés en el contorno. Es por esto que se decide probar con la simplificación de los contornos, aproximándolos y reduciendo, por consiguiente, la cantidad de puntos que los conforman.

4.4.1. Aproximación del contorno

4.4.1.1. Mínimos cuadrados

La primera idea de aproximación de contorno fue la utilización del método de mínimos cuadrados. Esta técnica del análisis numérico, busca encontrar una función que se ajuste a los datos, manteniendo el error cuadrático al mínimo.

Al estar trabajando con imágenes, el problema solo tiene dos dimensiones (x, y) , por lo tanto la expresión que se busca reducir es:

$$R^2 = \sum_{i=1}^n [(a * x_i + b) - y_i]^2 \quad (4.4)$$

donde (x_i, y_i) son los i -ésimos puntos del perímetro (de tamaño n), que se desea ajustar con la recta de pendiente a e intercepto b .

Una solución clásica para encontrar el mínimo para R^2 , es derivar parcialmente R^2 con respecto a a y b , e igualando a 0.

$$\frac{\partial R^2}{\partial a} = -2 \sum_{i=1}^n [y_i - (a + b * x_i)] = 0 \quad (4.5)$$

$$\frac{\partial R^2}{\partial b} = -2 \sum_{i=1}^n [y_i - (a + b * x_i)] x_i = 0 \quad (4.6)$$

obteniendo las ecuaciones:

$$n * a + b \sum_{i=1}^n x_i = \sum_{i=1}^n y_i \quad (4.7)$$

$$a \sum_{i=1}^n x_i + b \sum_{i=1}^n x_i^2 = \sum_{i=1}^n x_i * y_i \quad (4.8)$$

finalmente resolviendo el sistema se obtiene:

$$b = \frac{\sum_{i=1}^n y_i * \sum_{i=1}^n x_i^2 - \sum_{i=1}^n x_i * \sum_{i=1}^n x_i * y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \quad (4.9)$$

$$a = \frac{n * \sum_{i=1}^n x_i * y_i - \sum_{i=1}^n x_i * \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \quad (4.10)$$

De esta forma, se va calculando en cada iteración el valor del error cuadrado, y si este es mayor del

deseado, se aproxima con la recta de valores a y b anteriormente obtenidos.

Luego, se comienza desde el último punto usado anteriormente. Esto se realiza hasta recorrer todo el contorno que se desea aproximar.




Imagen 4.7: Imágenes de copas aproximadas por mínimos cuadrados. Primera fila: originales, Segunda fila: aproximación por mínimos cuadrados.

La implementación de este método de aproximación no entrega los resultados esperados (ver imagen 4.7). Las aproximaciones se alejan mucho de las imágenes originales y se decide probar con otro método de aproximación.

4.4.1.2. Función approxPolyDP

Como los resultados obtenidos no eran lo suficientemente cercanos al contorno inicial, se prueba la función de aproximación `approxPolyDP` de OpenCV. Esta función aproxima una curva o un polígono con otra curva/polígono con menos vértices, donde la distancia entre ellos sea igual o menor a un valor dado, ϵ . Específicamente usa el algoritmo de Douglas-Peucker.

Algoritmo de Douglas-Peucker

Este algoritmo busca aproximar el contorno a través de rectas. Los pasos del algoritmo son los siguientes:




Imagen 4.8: *Funcionamiento algoritmo Douglas-Peucker.*

- 1.- Trazar una recta desde el punto a hasta el punto b . En caso de ser la primera iteración, el punto a es el primero y el punto b es el último del contorno.
- 2.- Ver cual es el punto que quedo más lejos de la recta trazada, si este punto está a una distancia superior a ε , se toma ese punto como el nuevo punto b y se vuelve a 1.
- 3.- Si no existe ningún punto sobre ε , el tramo queda aproximado por esa recta, y se vuelve a 1 considerando al último punto b ahora como a , y b como el último punto del contorno. En caso de no quedar más puntos (osea el punto a es el mismo de b), el contorno ya se ha aproximado completamente.




Imagen 4.9: Comparación del resultado de las aproximaciones. Primera fila: originales, Segunda fila: aproximación por mínimos cuadrados, Tercera fila: aproximación con approxPolyDP.

Este nuevo método de aproximación funciona mucho mejor. Se logra disminuir la cantidad de puntos que componen el contorno, sin perder la calidad original de la imagen.

Se procede a probar el descriptor A2D2 con las imágenes aproximadas, entregando los siguientes resultados.

	A2D2	A2D2 Aproximado
Gentil - Agresivo	0.578242	1.50214
Amable - Agresivo	2.88095	2.23075
Dinámico - Estático	2.36298	2.0680
Elegante - Tosco	2.68019	3.25654

Tabla 4.7: Comparación de resultados de A2D2.

Se pueden ver algunas mejoras para los conceptos *Amable - Agresivo* y *Dinámico - Estático*, pero nue-

vamente los otros pares de conceptos tienen resultados desfavorables.

Luego se prueba los resultados de ponderar por los puntos de interés a las imágenes aproximadas.

	A2D2	Puntos de interés aproximados
Gentil - Agresivo	0.578242	2.79861
Amable - Agresivo	2.88095	3.23623
Dinámico - Estático	2.36298	2.61834
Elegante - Tosco	2.68019	4.83188

Tabla 4.8: Comparación resultados de los puntos de interés aproximados.

Finalmente analizando los resultados obtenidos, se llega a la conclusión de que la obtención de los llamados puntos de interés y su posterior ponderación no representan una mejora sustancial del descriptor, por lo que sería preliminarmente desechada.

4.5. Ponderación: Min, max, sum, prom

Aunque la propuesta anterior no entregó los resultados esperados, el proceso de aproximación usado demostró que era una buena forma de eliminar datos que no eran de interés.

La nueva propuesta mantiene el uso de la aproximación *approxPolyDP*, pero modifica la forma en que se ponderan los puntos. En vez de encontrar los puntos de interés y usar solo esos puntos, ahora se usan todos los puntos que quedan luego del proceso de aproximación del contorno y se pondera de 4 formas distintas.

Se calcula la distancia a los puntos siguiente y anterior del contorno y se guardan las distancias: *mínima*, *máxima*, *promedio* y *suma*, que serán usadas para ponderar cada uno de los puntos del contorno.

Finalmente, se decide probar ponderar por estos métodos en ambas imágenes, sin y con aproximación. Los resultados de ponderar por cualquiera de estas cuatro formas generan los mismos resultados, los cuales se pueden ver en la siguiente tabla.

	A2D2	Min/Max/Sum/Prom	Min/Max/Sum/Prom aproximado
Gentil - Agresivo	0.578242	2.42058	0.67729
Amable - Agresivo	2.88095	2.1297	2.91966
Dinámico - Estático	2.36298	2.25661	2.91735
Elegante - Tosco	2.68019	3.39088	3.77659

Tabla 4.9: Comparación de los resultados de aproximar por distancia mínima, máxima, suma o promedio.

La columna del medio tiene los resultados de hacer la ponderación a la imagen normal y la de la derecha a la imagen aproximada por la función approxPolyDP. Contrario a lo esperado, el aproximar el contorno genera peores resultados que hacer los cálculos con todos los puntos.

4.6. Resumen de los resultados

Se presenta una tabla resumen con todos los resultados obtenidos con los distintos descriptores y sus combinaciones.

	A2D2	A2D2 aproximado	Puntos interes	Puntos de interes aproximados	Min/Max/ Sum/Prom	Min/Max/Sum/Prom aproximado
Gentil - Agresivo	0.578242	1.50214	2.39999	2.79861	2.42058	0.67729
Amable - Agresivo	2.88095	2.23075	1.89913	3.23623	2.1297	2.91966
Dinámico - Estático	2.36298	2.0680	2.27973	2.61834	2.25661	2.91735
Elegante - Tosco	2.68019	3.25654	3.42369	4.83188	3.39088	3.77659

Tabla 4.10: Resumen de resultados de los distintos descriptores.

4.7. Descriptor de simetría

Este descriptor es un desarrollo de este trabajo, no es algo que se haya encontrado en el proceso de investigación previo. La suposición es que objetos altamente simétricos deben relacionarse con las percepciones de personalidad que les da la gente. Específicamente, se espera que un objeto con alta simetría se considere más estático y uno menos simétrico se considere más dinámico.

La simetría puede calcularse de distintas formas, dependiendo del tipo que se esté hablando. En general, esta característica tiene relación con la invariancia que tenga el objeto bajo ciertas transformaciones,

movimientos o intercambios. Esto quiere decir que si aplicamos alguna operación matemática al objeto, el resultado sigue siendo el mismo objeto.

De todos los tipos de simetría existentes, en este descriptor se calcula la simetría reflectiva o bilateral. Esto quiere decir que existe un eje que divide el objeto en dos partes “exactamente” iguales.




Imagen 4.10: Mariposa dividida por un eje central. A ambos lados del eje la mariposa es “igual”.

La mayoría de los animales poseen este tipo de simetría. Si vemos la **imagen 4.10** podemos ver que la mariposa posee un alto grado de simetría respecto al eje central que la corta.

Debido a que los objetos a analizar no fueron diseñados buscando que sean simétricos, hay que decidir donde ubicar el eje de simetría. Se toma la decisión de que el eje de simetría debe pasar siempre por el centroide del objeto.

Teniendo esto en cuenta, el procedimiento de calculo del descriptor es el siguiente:

- 1.- Calcular el centroide del objeto.
- 2.- Trazar una recta que pasa por el centroide, la cual será usada como el eje de simetría (**ver imagen 4.11 a**).
- 3.- Dividir el objeto en dos partes usando el eje de simetría (**ver imagen 4.11 b**).
- 4.- Rotar una de las partes 180° respecto al eje de simetría (**ver imagen 4.11 c**).
- 5.- Restar una parte con la otra (**ver imagen 4.11 d**).
- 6.- Calcular el área del resultado de la resta.
- 7.- Dividir el resultado anterior por el área total del objeto y guardar este valor.
- 8.- Rotar la imagen con respecto al centroide α° y volver al punto 2. Hacer esto hasta que se haya rotado el objeto 180° . (**ver imágenes 4.11 (1) a (2)**)
- 9.- De todos los valores obtenidos en el paso 7, el valor menor es el índice de simetría de la imagen




Imagen 4.11: *Funcionamiento del descriptor de simetría.*

Como se puede ver en las imágenes el área resultante de las restas va cambiando dependiendo del ángulo de giro. En la **imagen 4.11** se puede ver que el **caso (1) d** dará un valor de simetría mucho mayor que lo que se muestra en el **caso (3) d**.

Luego de varias pruebas el valor α de rotación quedó en 5° . Este valor es suficientemente pequeño para poder hacer una correcta exploración de la imagen.

A continuación, se presentan los resultados del descriptor.

Imagen	Gentil - Agresivo	Amable - Agresivo	Dinámico – Estático	Elegante - Tosco
1	 0.00323658	 0.00755774	 0.148942	 0.0076524
2	 0.00443789	 0.0207268	 0.00191695	 0.000376896
3	 0.00171352	 0.000546998	 0.00380864	 0.0247624
4	 0.00339827	 0.00429204	 0.0151582	 0.0362556
5	 0.00405149	 0.00679945	 0.00527402	 0.00192262
6	 0.0079367	 0.00964276	 1.0988e-05	 0.000266626
7	 0.00684025	 0.00178862	 0.00071049	 0.00115927
8	 0.0261757	 0.00239019	 0.00250703	 0.0207268
9	 0.0000000	 2.67591e-05	 0.0362556	 0.00661664
10	 0.0261757	 0.000791036	 0.0680093	 0.00155712

Tabla 4.11: Tabla de resultados de simetría para cada imagen de los sets.

Este descriptor, al entregar un único valor de salida, no puede ser usado por si solo en la red neuronal artificial, tal como los descriptores simples, poniéndose a prueba más adelante junto con otros en el meta-descriptor de forma.

4.8. Meta-Descriptor

En esta sección se probará el resultado de combinar distintos descriptores, incluyendo los descriptores simples: **Circularidad 2.2.3.3**, **Rectangularidad 2.2.3.4** y **Excentricidad 2.2.3.5**, junto con el **Descriptor de Simetría 4.7**.

Para ello se partirá probando el resultado de usar únicamente estos cuatro descriptores con los distintos sets de imágenes.

Gentil - Agresivo	1.98502
Amable - Agresivo	2.45829
Dinámico - Estático	1.35291
Elegante - Tosco	1.65244

Tabla 4.12: Resultado de los descriptores simples junto con el descriptor de simetría.

Se puede observar una mejora importante en los conceptos *Dinámico - Estático* y *Elegante - Tosco* desde lo cual se puede suponer que ambos pares de conceptos no están reflejados en los cambios angulares del contorno y es por esto que ahora la red mejora su comportamiento.

En la siguiente tabla, se muestran todos los descriptores anteriormente evaluados y se combinan con los descriptores simples y de simetría, es decir, los meta-descriptores.

	A2D2	A2D2 aproximado	Puntos interés	Puntos de interés aproximados	Min/Max/ Sum/Prom	Min/Max/Sum/Prom aproximado
Gentil - Agresivo	0.767693	0.746098	2.0345	2.20858	2.08753	0.969825
Amable - Agresivo	3.11947	1.87984	2.36946	3.36019	2.72212	2.9885
Dinámico - Estático	2.44094	1.09721	1.70039	2.96893	2.53366	2.83812
Elegante - Tosco	1.82978	1.9051	1.78059	3.71891	1.53543	3.37635

Tabla 4.13: Resumen de los meta-descriptores.

Finalmente se puede apreciar como la combinación de distintos métodos de representación de los objetos mejora notoriamente los resultados obtenidos. Estas conclusiones serán detalladas en el **Capítulo 6**. Los descriptores simples, **área** y **perímetro** no fueron usados como descriptores en sí, pero se usaron como base durante el desarrollo de algunos de los descriptores implementados.

Capítulo 5

Aprendizaje

Como se ha mencionado anteriormente, para poder aprender la relación entre las características de personalidad y el contorno, fue necesaria la implementación de un sistema de aprendizaje. En este capítulo se detallan las características de la solución usada junto con los problemas enfrentados y las posibles soluciones.

5.1. Datos de aprendizaje

Como se explicó en el **Estado del arte 2.2.7** el sistema de aprendizaje utilizado son redes neuronales artificiales del tipo supervisadas. Para esto fue necesario realizar encuestas preguntando el grado de pertenencia a los distintos conceptos que se deseaban estudiar para, con el resultado, entrenar la red.

Se hizo una encuesta por par de conceptos. En cada una de ellas habían 10 tipos diferentes de modelos en 2D de copas. El rango de pertenencia iba desde -5, máxima asociación a un concepto, a +5, máxima asociación al concepto opuesto. En el caso de la encuesta de la **imagen 5.1** las asociaciones van de -5, para la máxima asociación al concepto *Amable*, a +5 que corresponde a la máxima asociación al concepto *Agresivo*.

Estudiante ☐	Especialidad	Genero ☐	☐	Edad
Profesional ☐		M	F	

	Amable ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ Agresivo
	Amable ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ Agresivo
	Amable ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ Agresivo
	Amable ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ Agresivo
	Amable ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ Agresivo
	Amable ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ Agresivo
	Amable ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ Agresivo
	Amable ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ Agresivo
	Amable ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ Agresivo
	Amable ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ Agresivo

Imagen 5.1: Ejemplo de encuesta. Encuesta: Amable - Agresivo.

A continuación se muestran los sets de imágenes y las tablas de resumen con los datos obtenidos de las encuestas realizadas. Cabe destacar que tanto las imágenes como las encuestas fueron realizadas por terceros y se usan como un dato no cuestionado.

5.1.1. Gentil - Agresivo**Imagen 5.2:** Set de imágenes usadas en el análisis de los conceptos: Gentil - Agresivo.

Imagen	Promedio	Desviación estandar	Confiabilidad
1	-1.63	1.83	0.98
2	-2.60	1.79	1.00
3	1.14	2.88	0.36
4	2.26	2.11	0.81
5	-1.18	2.67	0.49
6	-0.11	2.92	0.34
7	-2.4	2.21	0.75
8	1.2	2.27	0.72
9	1.8	1.99	0.89
10	0.43	3.07	0.25

Tabla 5.1: Tabla resumen de los datos de las encuestas: Gentil - Agresivo.

5.1.2. Amable - Agresivo**Imagen 5.3:** Set de imágenes usadas en el análisis de los conceptos: Amable - Agresivo.

Imagen	Promedio	Desviación estandar	Confiabilidad
1	-2.04	2.07	0.79
2	-0.55	2.42	0.60
3	-0.91	2.15	0.75
4	-1.37	2.06	0.80
5	0.60	3.08	0.25
6	3.94	2.02	0.82
7	-1.36	2.31	0.66
8	-2.38	1.69	1.00
9	-0.36	2.16	0.75
10	2.32	2.20	0.73

Tabla 5.2: Tabla resumen de los datos de las encuestas: Amable - Agresivo.

5.1.3. Dinámico - Estático**Imagen 5.4:** Set de imágenes usadas en el análisis de los conceptos: Dinámico - Estático.

Imagen	Promedio	Desviación estandar	Confiabilidad
1	-3.43	2.16	0.96
2	3.09	2.11	0.99
3	0.85	2.65	0.62
4	-0.77	2.75	0.55
5	-1.73	2.09	1.00
6	0.31	2.86	0.48
7	1.85	2.76	0.54
8	0.07	2.28	0.87
9	-1.73	2.33	0.84
10	-1.57	3.19	0.25

Tabla 5.3: Tabla resumen de los datos de las encuestas: Dinámico - Estático.

5.1.4. Elegante - Tosco



Imagen 5.5: Set de imágenes usadas en el análisis de los conceptos: Elegante - Tosco.

Imagen	Promedio	Desviación estandar	Confiabilidad
1	-2.83	2.06	0.63
2	2.98	2.01	0.69
3	-2.11	2.24	0.39
4	-1.71	2.35	0.25
5	3.12	1.77	1.00
6	3.05	2.07	0.61
7	-2.31	2.14	0.52
8	1.11	2.04	0.65
9	-1.83	2.24	0.40
10	1.57	1.97	0.74

Tabla 5.4: Tabla resumen de los datos de las encuestas: Elegante - Tosco.

5.2. Diseño de la red neuronal artificial - OpenCV

Como se explicó en el estado del arte, el diseño de la estructura de una red neuronal artificial es un tema de mucha discusión, no existe un manual o norma que permita determinar cual debe ser la topología. Todo va a depender del uso que se le vaya a dar. Solo existen consejos y experiencias de otros investigadores que poseen el *know-how* del diseño.

Además, la biblioteca OpenCV, también posee métodos de “Machine Learning”, dentro de los cuales se encuentran algoritmos de redes neuronales artificiales, los cuales serán utilizados.

Lo anterior, más consejos que se lograron investigar y las pruebas realizadas permitieron llegar a la siguiente topología (**ver imagen 5.6**).




Imagen 5.6: Topología de la RNA usada.

Donde la capa de entrada son los descriptores o el meta-descriptor de tamaño N , la capa oculta de tamaño $N/2$ y la capa de salida con un solo valor, que corresponde al grado de pertenencia al concepto.

5.3. Problemas - Leave One Out Cross Validation

Al momento de poner a prueba los distintos descriptores nos topamos con un problema (no menor). La cantidad de datos de aprendizaje no es suficiente como para realizar los métodos de aprendizaje necesarios.

Es por este motivo que se utiliza la metodología “Leave One Out Cross Validation”, que es un tipo de validación cruzada que ya fue implementada en el trabajo de Zuñiga *et al.* [13].

La validación cruzada, es usada en los casos donde no hay suficientes datos para hacer el aprendizaje y la validación con sets de datos separados. Tradicionalmente, lo que se hace es separar el set de datos en dos. El primer set, con el 70 % de los datos, es usado en el proceso de aprendizaje y el segundo set con el 30 % es usado como un set de validación y revisión del correcto aprendizaje. De esta forma, si al correr el set de prueba el error aún se mantiene pequeño, se considera que el modelo es correcto y ha logrado aprender la generalidad y no la respuesta particular para el set de aprendizaje.

En los casos que no hay suficientes datos para hacer lo anteriormente descrito, se usa la validación cruzada, en donde los datos de aprendizaje y prueba van rotando o “cruzándose” siendo en algún momento parte del set de aprendizaje y en otro momento parte del set de prueba (**ver imagen 5.7**).




Imagen 5.7: Ejemplo de validación cruzada.

En los casos más extremos puede llegar a implementarse la validación cruzada "leave one out", que es la que se usa en este trabajo. Donde en un set de K datos se deja fuera un solo dato por ronda para ser usado como prueba. Esto quiere decir que el entrenamiento se realiza K veces, siendo entrenada por todos los datos, excepto por uno solo que es el que se usa para hacer la predicción. Luego se calcula el error promedio con cada uno de esos puntos y ese valor es usado para evaluar el modelo y evitar el problema de sobre entrenamiento y nos entrega una idea de como se va a comportar cuando sea usado con otros datos independientes.

Capítulo 6

Conclusiones y Trabajo a Futuro

6.1. Análisis de objetivos

Respecto a los objetivos propuestos para este trabajo, se lograron implementar satisfactoriamente algoritmos para extraer características geométricas de los objetos y luego, se relacionaron estas no solo con los conceptos *Gentil - Agresivo* ya estudiados por Zuñiga *et al.* [13], sino que también con los conceptos *Amable - Agresivo*, *Dinámico - Estático* y *Elegante - Tosco*.

Se concluye que los mejores meta-descriptores por pares de conceptos son:

- I. **Gentil - Agresivo:** Mantener el uso del *descriptor de forma: Firma basada en la diferencia angular*. De todas las pruebas que se hicieron, no se logró mejorar el resultado original de este descriptor, debido a que ya obtenía una caracterización y resultados de aprendizaje con un error muy bajo. Por lo que se corrobora su buen rendimiento y se recomienda seguir usándolo para estos conceptos.
- II. **Amable - Agresivo:** Este par de conceptos, a pesar del pensamiento inicial, de que se comportarían como los anteriores, resultaron ser bastante complejos de representar. Con la implementación del meta-descriptor se pudo encontrar una combinación que mejorara lo entregado por el *descriptor de forma: Firma basada en la diferencia angular*. En consecuencia, se recomienda hacer uso del descriptor original, pero haciendo previamente una aproximación al contorno de los objetos y sumándole los descriptores simples, *circularidad*, *rectangularidad* y *excentricidad*, junto con el *descriptor de simetría*.
- III. **Dinámico - Estático:** Estos conceptos no mostraban prácticamente ninguna mejoría durante el desarrollo de las caracterizaciones, pero al momento de probar los descriptores *circularidad*, *rectangu-*

laridad, excentricidad y de simetría se obtuvieron inmediatamente disminuciones en los errores de los resultados. Luego, al sumar el *descriptor de forma: Firma basada en la diferencia angular* se mejoró aun más, pero se cree que la representación de estos conceptos esta más lejos de las características del contorno y tiene que ver más con la globalidad de la forma que con detalles específicos de él.

- IV. **Elegante - Tosco:** Por último, para este par de conceptos se tenían muy malas representaciones iniciales, las que al igual que en el caso anterior, mejoraron con la incorporación de los descriptores *circularidad, rectangularidad, excentricidad y de simetría*. Finalmente, la incorporación del descriptor de ponderación *min/max/sum/prom*, enriquece la representación.

De todas formas, analizando la última tabla comparativa, se logró identificar un comportamiento común: todos los métodos que no incorporaban la aproximación del contorno, se comportaban mejor que sus contra-partes aproximadas. Es por esto, que se concluye que en estos pares de conceptos hay una combinación del lugar desde donde se obtiene la información, en otras palabras, no sólo se deben usar datos generales, obtenidos con los descriptores simples, sino que también se necesita información de los detalles específicos que están en los cambios pequeños de los contornos.

6.2. Trabajo a Futuro

Son varias las mejoras que se le pueden hacer a este trabajo. Queda pendiente el análisis de nuevos objetos para corroborar el correcto aprendizaje de la identificación de las personalidades. Para esto, es necesaria la recopilación de nuevas imágenes y la realización de nuevas encuestas con los mismos conceptos del presente trabajo. Con esta información adicional, se podría eliminar el uso de la metodología “leave one out” y pasar a otro tipo de validación cruzada o -en caso de tener los datos suficientes- hacer una separación tradicional de los datos, en sets de aprendizaje, validación y test.

Incorporar nuevos pares de conceptos. Como se hizo en este trabajo, sería posible ir agregando nuevos conceptos y potenciar aun más esta herramienta en el análisis de percepciones de personalidad.

Incorporar nuevos tipos de descriptores de forma. Por la consideración inicial de que aún no se tiene claridad de qué es importante al momento de describir un objeto, cabe la posibilidad de que los descriptores basados en región podrían entregar información relevante.

Utilización de nuevas características de los objetos. En este trabajo, se concentró la investigación solamente en el análisis de la forma de objetos de imágenes 2D, por lo cual han quedado fuera -a pesar de que la forma es lo más importante- otras características que pudiesen entregar más información de

interés. Por ejemplo, se podría considerar el color de las cosas o su brillo, e incorporar en el futuro el análisis de imágenes 3D. Como ya se mencionó, el representar los objetos en 2D, hace que se pierda capacidad de caracterización, lo cual con la incorporación del 3D, no pasaría.

Referencias

- [1] D. Norman, “Emotional Design: Why we love (or hate) everyday things”.
- [2] H. Schifferstein, E. Zwartkuis-Pelgrim, 2008. “Consumer-product attachment: Measurement and design implications” *International Journal of Design*, 2(3), 1-13.
- [3] M. Csikszentmihalyi, E. Rochberg-Halton, 1981. “The meaning of things: Domestic symbols and the self”. *Cambridge, UK: Cambridge University Press*.
- [4] M. Nagamachi, 1995. “Kansei Engineering: A new ergonomic consumer-oriented technology for product development”
- [5] P. Govers, R. Mugge, 2004. “‘I love my Jeep, because it’s tough like me’, The effect of product-personality congruence on product attachment” *Proceedings of the Fourth International Conference on Design and Emotion*, ed. Aren Kurtgözü, Ankara, Turkey.
- [6] P. Jordan, 1997. “Product as Personalities”, *Contemporary Ergonomics, Taylor & Francis*.
- [7] M. Nagamachi, I. Senuma, and R. Iwashige, 1974. “A study of image technology”. *Japanese Journal of Ergonomics*, 10(2):121-130.
- [8] M. Nagamachi, I. Senuma, and R. Iwashige, 1977. “An analysis of feeling on room atmosphere.”. *Japanese Journal of Ergonomics*, 13(1): 7-14.
- [9] M. Nagamachi, I. Senuma, and R. Iwashige, 1995. “Kansei Engineering: A new ergonomic consumer-oriented technology for product development”. *International Journal of Industrial Ergonomics*, 15 (1995) 3-11.
- [10] E. Janlert, E. Stolterman, 1997. “The character of things”, *Design Studies*, Vol. 18, No 3., 1997, pp. 297-314.
- [11] K.A. Hsiao, L.L. Chen, 2006. “Fundamental dimensions of affective responses to product shapes”. *International Journal of Industrial Ergonomics*. Vol. 36, pp. 553–564.

- [12] P. Prieto, 2013, "On products shapes and personalities", *19th International Conference on Engineering Design ICED2013, Seul*.
- [13] M. Zuniga, P. P., 2014. "Quantifying shape descriptors for aesthetic concepts". *INTERNATIONAL DESIGN CONFERENCE - DESIGN 2014*.
- [14] T. Acharya, Ray, A. K, 2005. "Image processing: principles and applications". *John Wiley & Sons*.
- [15] A. Cardone, S. G., 2003. A Survey of Shape Similarity Assessment Algorithms for Product Design and Manufacturing Applications. *Journal of Computing and Information Science in Engineering*, 109-118.
- [16] Repositorio Video Analysis Tool <https://git.elo.utfsm.cl/VAT-group/vat-3-0>.
- [17] S. Belongie, J. M., 2001. "Matching Shapes". *IEEE* , 454-461.
- [18] A. El-ghazal, O. B., 2009. "Farthest point distance: A new shape signature for Fourier descriptors". *Signal Processing:Image Communication* , 572-586.
- [19] D. Zhang, G. L., 2002. "Shape-based image retrieval using generic Fourier descriptor".
- [20] D. Zhang, G. L., 2005. "Study and evaluation of different Fourier methods for image retrieval". *Image and Vision Computing* , 33-49.
- [21] H. Chen, Y. C., 2009. "Extraction of product form features critical to determining consumers perceptions of product imageusing a numerical definition-based systematic approach". *International Journal of Industrial Ergonomics* , 133-145.
- [22] R. Mugge, P. G., 2009. "The development and testing of a product personality scale". *Design Studies* , 287-302.
- [23] D. Zhang, G. L., 2004. "Review of shape representation and description techniques". *Pattern Recognition* , 1-19.
- [24] D. Huttenlocher, G. K., 1993. "Comparing images using the Hausdorff distance". *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE* , 850-863.
- [25] S. Belongie, J. M., J. P., 2001. "Matching shapes", *Proceedings of Eighth IEEE International Conference on Computer Vision (ICCV2001), Vol. I, Vancouver, Canada, July, 2001, pp. 454 – 461*.
- [26] D. Zhang, G. L., 2002. "A Comparative Study of Fourier Descriptors for Shape Representation and Retrieval".

- [27] F. Mokhtarian, A. M., 1986. "Scale-Based Description and Recognition of Planar Curves and Two-Dimensional Shapes". *IEEE 'TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE* , 34-43.
- [28] D. Zhang, G. L., 2005. "Study and evaluation of different Fourier methods for image retrieval". *Image and Vision Computing* , 33-49.
- [29] Wang, B., 2011. "Shape retrieval using combined fourier features". *Optics Communications*, 3504-3508.
- [30] H. Kauppinen, T. S., 1995. "An experimental comparison of autoregressive and Fourier-based". *IEEE Transactions on Pattern Analysis and Machine Intelligence* , 201-207.
- [31] Freeman, H., 1961. "On the encoding of arbitrary geometric". *IRE Transactions on Electronic Computers* , 260-268.
- [32] Hu, M., 1962. "Visual pattern recognition by moment invariants". *IRE TRANSACTIONS ON INFORMATION THEORY* , 179-187.
- [33] G. Taubin, D. C., 1991. "Recognition and positioning of rigid objects using algebraic moment invariants". *SPIE Conference on Geometric Methods in Computer Vision* , 175 –186.
- [34] Teague, M., 1980. "Image analysis via the general theory of moments". *J. Opt. Soc. Am* , 920–930.
- [35] D. Zhang, G. L., 2002. "Generic Fourier descriptor for shape-based image retrieval". *Proceedings of IEEE International Conference on Multimedia and Expo* , 425 – 428.