BENEMÉRITA UNIVERSIDAD AUTÓNOMA DE PUEBLA

FACULTAD DE CIENCIAS DE LA ELECTRÓNICA

MAESTRÍA EN INGENIERÍA ELECTRÓNICA, OPCIÓN INSTRUMENTACIÓN ELECTRÓNICA

BUAP

Tesis para obtener el grado de:
MAESTRO EN INGENIERÍA ELECTRÓNICA

"Sistema automático de aprendizaje incremental supervisado para reconocimiento de la edad ósea"

Presenta:
José Luis Tonatiúh Banda Escobar

Directores de tesis:
Dr. Salvador Eugenio Ayala Raggi
Dr. Aldrin Barreto Flores

***Becario CONACYT**

Puebla, Pue., Diciembre 2018

Título: “Sistema automático de aprendizaje incremental supervisado para reconocimiento de la edad ósea"
Estudiante: José Luis Tonatiúh Banda Escobar

COMITÉ

M.C. Rodrigo L. Maya Ramírez
Presidente

Dra. M. Monserrat Morín Castillo
Secretario

M.C. J. Francisco Portillo Robledo
Vocal

DIRECTORES DE TESIS

Dr. Salvador E. Ayala Raggi

Dr. Aldrin Barreto Flores

Agradecimientos

Al Concejo Nacional de Ciencia y Tecnología (CONACYT) por la beca de manutención que me otorgó y proporcionó durante los estudios de maestría.

A la Benemérita Universidad Autónoma de Puebla, Facultad de Ciencias de la Electrónica y en especial a la Maestría en Ingeniería Electrónica, Opción Instrumentación Electrónica, por la oportunidad brindada para realizar los estudios de Maestría y el apoyo económico proporcionado para realizar actividades de investigación y divulgación del conocimiento.

A mi director de tesis el Dr. Salvador E. Ayala Raggi por todo el apoyo brindado, los conocimientos compartidos, la motivación y guía para desarrollar el tema de tesis.

A mi director de tesis el Dr. Aldrin Barreto Flores y a mis revisores: el M.C. Rodrigo Lucio Maya Ramírez, la Dra. María Monserrat Morín Castillo y el M.C. José Francisco Portillo Robledo por que gracias a sus observaciones puntuales y comentarios expuestos se mejoró el trabajo de tesis.

A todos los profesores que forman parte del posgrado; por sus enseñanzas, conocimientos y consejos que me ayudaron para crecer profesionalmente.

En especial a mi abuelita por todo el amor, cuidado y confianza que siempre me dio.

A mi mamá Martha Escobar y mi hermana Ixchel Banda por todo ya que sin ellas no hubiera podido lograr ninguna de mis metas.

A toda mi familia por la motivación, la confianza, el apoyo y por darme las bases que me permiten cumplir con mis metas en la vida.

A mi novia Mariana Díaz por darme la motivación de seguir adelante, por la alegría que me da día tras día para superar cualquier dificultad.

A todos mis compañeros de la maestría que se convirtieron en mis amigos, porque gracias a ustedes esto fue una gran experiencia.

Índice general

Agradecimientos III

Lista de acrónimos XV

Introducción XVII

Objetivos XIX

Organización del trabajo XXI

1. Estimación automática de madurez esquelética **1**
1.1. Radiografía . . . 1
1.2. Edad ósea de un individuo . . . 1
1.3. Método Greulich & Pyle . . . 3
1.4. Método Tanner & Whitehouse . . . 3
1.5. Métodos automáticos basados en visión por computadora para estimar el desarrollo esquelético . . . 4
1.5.1. Thodberg y otros . . . 5
1.5.2. Gertych y otros . . . 5
1.5.3. Kashif y otros . . . 5
1.5.4. Giordano y otros . . . 5
1.5.5. Spampinato y otros . . . 6
1.6. Comparación de los métodos para estimar la edad ósea . . . 6
1.7. Conclusiones . . . 6

2. Sistema general para estimación de la edad ósea **9**
2.1. Sistema general . . . 9
2.2. Imagen digital . . . 10
2.2.1. Propiedades de una imagen digital . . . 10
2.2.2. Histograma . . . 11
2.3. Segmentación de imagen . . . 12
2.3.1. Métodos basados en el histograma . . . 13
2.3.2. Métodos basados en el crecimiento de regiones . . . 13
2.3.3. Método del valor umbral . . . 13
2.4. Extracción de características . . . 14

2.4.1. Análisis por componentes principales 14
2.4.2. Parámetros geométricos 14
2.5. k-vecinos más cercanos 14

3. Desarrollo del sistema automático para reconocimiento de la edad ósea 17
3.1. Disposición de puntos para delimitar regiones de interés 17
3.1.1. Disposición de puntos propuesta 17
3.1.2. Sistema manual para estimación de la edad ósea 19
3.1.3. Pre-procesamiento de la imagen 20
3.1.3.1. Segmentación de la mano 20
3.1.3.2. Ajuste de contraste 21
3.1.4. Colocación manual de puntos estratégicos 22
3.1.5. Segmentación de regiones de interés 22
3.1.6. Formación del vector de características 23
3.1.7. Regresión con el algoritmo *k-NN* 24
3.2. Detección automática de *landmarks* 25
3.2.1. Propuesta de detección automática de *landmarks* 25
3.2.1.1. Algoritmo de ángulo dominante 26
3.2.1.2. Algoritmo de PCA 28
3.2.1.3. Método para detectar *landmarks* automáticamente 30
3.3. Aprendizaje automático incremental 33
3.3.1. Condiciones de funcionamiento del algoritmo 34
3.3.2. Desarrollo del algoritmo 35
3.3.2.1. Error de estimación 35
3.3.2.2. Estimación de etiqueta 35
3.3.2.3. Modificación de prototipos 35
3.3.3. Pseudocódigo de aprendizaje incremental 36
3.4. Desarrollo de la interfaz de usuario 38
3.4.1. Casos de uso 38

4. Resultados 43
4.1. Resultados de la disposición de puntos estratégicos 43
4.1.1. Re-dimensionado de las imágenes originales 43
4.1.2. Estimación de la edad ósea 44
4.1.3. Discusión de resultados 47
4.2. Resultados de la detección automática de puntos 47
4.2.1. Discusión de resultados 52
4.3. Resultados del algoritmo de aprendizaje automático incremental 53
4.3.1. Bases de datos para validación del algoritmo 53
4.3.2. Resultados 55
4.3.3. Discusión de resultados 65
4.4. Interfaz de usuario desarrollada 66

5. Conclusiones y trabajo futuro **69**
5.1. Conclusiones 69
5.2. Trabajo futuro 71

Índice de figuras

1.1. Representación de los huesos de la mano y su identificación. 2
1.2. Ejemplo de las etiquetas utilizadas en el método TW2 para determinar la etapa de madurez esquelética en el radio [1]. 4

2.1. Sistema general para estimación automática de la edad ósea. 10
2.2. Ejemplo de imagen digital del tipo RGB y tamaño LxM. 10
2.3. Se muestra la imagen digital de la figura 2.2, en escala de grises. 11
2.4. Ejemplo del histograma de una imagen en escala de grises. 12
2.5. Ejemplo de la transformación de valores de una imagen con un rango inicial de $[r_{min}, r_{max}]$ a un rango de [0, 255]. 12
2.6. Ejemplo de una radiografía utilizando una figura rectangular para delimitar las regiones de interés. 15

3.1. Ejemplo de una imagen radiográfica con la propuesta de *layout* de *landmarks*. . 18
3.2. Ejemplo de *landmarks* colocadas en las regiones intermedias que no presentan osificación. 18
3.3. Etapa de entrenamiento. 19
3.4. Etapa de evaluación. 19
3.5. Ejemplo de máscara binaria usada para ajuste de contraste local. 21
3.6. Ajuste de contraste en la región de la mano. 21
3.7. Regiones de interés utilizadas. Ángulo θ es calculado usando el punto ubicado entre las falanges proximal e intermedia en el mismo dedo. El tamaño de la región de interés es calculado usando la distancia entre ambos puntos en el mismo dedo multiplicado por un factor constante. 22
3.8. Proceso de alineación y normalización de cada ROI. (a)ROI inicial. (b)ROI rotada. (c)ROI re-dimensionada. (d)ROI con máscara aplicada. 23
3.9. Histograma ponderado usado para obtener el ángulo dominante del parche. . . . 26
3.10. Orientación de parches en rotación usando el ángulo dominante. 27
3.11. Ejemplo del algoritmo para la detección inicial de *landmarks* en una imagen radiográfica. 30
3.12. Ejemplo de utilizar el algoritmo para la detección inicial de *landmarks* en una imagen radiográfica. 32
3.13. Se muestra un esquema de un prototipo, el cual tiene un conjunto de características, una etiqueta y un conjunto de elementos que representan su memoria. 36

3.14. Diagrama de los casos de uso referente a la estimación de edad ósea de una imagen radiográfica. 38
3.15. Diagrama de los casos de uso referente al algoritmo de aprendizaje incremental para la estimación de la edad ósea. 38

4.1. Histograma de la edad ósea actual del conjunto de 100 imágenes usadas para evaluación del grupo femenino. 44
4.2. Histograma de la edad ósea actual del conjunto de 100 imágenes usadas para evaluación del grupo masculino. 44
4.3. Error de estimación con 300 imágenes de entrenamiento para el conjunto femenino con 100 imágenes de evaluación, variando el parámetro k del algoritmo *k-NN*. 45
4.4. Error de estimación con 300 imágenes de entrenamiento para el conjunto masculino con 100 imágenes de evaluación, variando el parámetro k del algoritmo *k-NN*. 45
4.5. Edad ósea actual vs edad ósea estimada del grupo femenino, usando 300 prototipos de entrenamiento y 100 imágenes de evaluación donde la edad ósea actual fue ordenada de menor a mayor. 46
4.6. Edad ósea actual vs edad ósea estimada del grupo masculino, usando 300 prototipos de entrenamiento y 100 imágenes de evaluación donde la edad ósea actual fue ordenada de menor a mayor. 46
4.7. Diagrama de general del sistema con la detección automática de *landmarks*. . . . 48
4.8. Comparación de la colocación manual y la detección automática de *landmarks* en una imagen radiográfica. 48
4.9. Histogramas de la edad ósea actual de cada conjunto de 100 imágenes usadas para evaluación. 49
4.10. Error MAE calculado en función del parámetro k del algoritmo *k-NN* comparando la estimación con la colocación manual y la detección automática de *landmarks*. 50
4.11. Error MAE calculado en función del parámetro k del algoritmo *k-NN* comparando la estimación con la colocación manual y la detección automática de *landmarks*. 51
4.12. Puntos sintéticos con dos coordenadas para simular muestras. 53
4.13. Puntos sintéticos en donde su etiqueta se obtiene calculando la distancia que existe entre el origen (0,0) y la ubicación del prototipo. 54
4.14. Puntos sintéticos en donde su etiqueta se obtiene sumando los valores de las coordenadas de cada punto. 54
4.15. Puntos sintéticos en donde su etiqueta se obtiene usando una función para generar una superficie simétrica. 55
4.16. Prototipos utilizados para evaluar las muestras en la primera base de datos. . . . 56
4.17. Comparación de las etiquetas en la base de datos y las etiquetas estimadas por los algoritmos en la primera base de datos. 57
4.18. Prototipos utilizados para evaluar las muestras en la segunda base de datos. . . 58

4.19. Comparación de las etiquetas en la base de datos y las etiquetas estimadas por los algoritmos en la segunda base de datos. 59
4.20. Comparación de las etiquetas en la base de datos y las etiquetas estimadas por los algoritmos en la tercera base de datos. 60
4.21. Evaluación de MAE vs k en las muestras de estimación de edad ósea en el grupo masculino. 61
4.22. Evaluación de MAE vs k en las muestras de estimación de edad ósea en el grupo femenino. 62
4.23. Comparación de la edad ósea actual vs la edad estimada usando las *landmarks* en su posición adecuada. 63
4.24. Comparación de la edad ósea actual vs la edad estimada usando las *landmarks* detectadas automáticamente. 64
4.25. Interfaz de usuario desarrollada en MATLAB para estimar la edad ósea. 66
4.26. Interfaz de usuario desarrollada en MATLAB para estimar la edad ósea. 67

Índice de tablas

1.1. Comparación de algunos métodos revisados en la literatura. 6

3.1. Caso de uso: Seleccionar imagen 39
3.2. Caso de uso: Recortar imagen 39
3.3. Caso de uso: Selección de género 40
3.4. Caso de uso: Calcular edad ósea 40
3.5. Caso de uso: Seleccionar neuronas iniciales 41
3.6. Caso de uso: Seleccionar neuronas originales 41
3.7. Caso de uso: Ingresar edad ósea 41
3.8. Caso de uso: Modificar la red de neuronas 42
3.9. Caso de uso: Guardar la red de neuronas 42

4.1. Comparación de algunos métodos revisados en la literatura. 47
4.2. Distancia euclidiana media en píxeles, entre las *landmarks* ubicadas por el algoritmo y las colocadas manualmente, en las imágenes de evaluación. Se muestran los datos por cada *landmark* para este grupo de imágenes. 49
4.3. Comparación del método propuesto con algunos otros métodos revisados en la literatura. 52
4.4. Comparación del error medio absoluto y la desviación estándar obtenidos usando el algoritmo *k-NN* para regresión y el algoritmo propuesto con diferentes conjuntos de entrenamiento y evaluación en las muestras para estimar la edad ósea. 65

Lista de acrónimos

k-NN: k-Nearest neighbors (k-vecinos más cercanos)

ROI: Region of interest (Región de interés)

PCA: Principal component analysis (Análisis de componentes principales)

RBF: Radial basis function (Función de base radial)

MAE: Mean absolute error (Error medio absoluto)

RMSE: Root mean square error (Error medio cuadrático)

SVM: Support vector machines (Máquinas de vectores de soporte)

CNN: Convolutional Neural Networks (Redes neurales convolucionales)

FIFO: First in, first out (Primero en entrar, primero en salir)

Introducción

La estimación de madurez esquelética, también conocida como edad ósea es un procedimiento clínico el cual es usado para determinar la edad o desarrollo esquelético tanto en niños como en adultos jóvenes. Esta estimación, normalmente hecha por un médico radiólogo, es de extrema utilidad para médicos en otras especialidades que requieren saber el estado de desarrollo óseo en los niños.

La determinación es hecha usualmente observando cambios en la forma y densidad de diferentes articulaciones y huesos que aparecen en una radiografía de la mano no dominante (comúnmente la mano izquierda) y la muñeca de los niños [5, 7].

La edad ósea de un individuo no es necesariamente la misma que su edad cronológica. La razón de esto es que los niños se desarrollan de manera diferente. Cuando existen desviaciones grandes de la media usual, éstas son indicativos de un posible desorden. Los huesos de la mano y muñeca proporcionan más de 20 secuencias de eventos sobre los cuales pueden basarse las mediciones de madurez [1].

Esta determinación de la edad ósea es utilizada frecuentemente en el diagnóstico y tratamiento del crecimiento y desórdenes endócrinos en niños y adultos jóvenes [2].

Los dos métodos más conocidos utilizados por los radiólogos (Greulich y Pyle ó GP [3], y Tanner y Whitehouse ó TW2/3 [4]) en la determinación de la edad ósea están basados en la observación de la forma ósea en la radiografía. El método GP, por ejemplo, involucra una comparación compleja de 28 huesos de la radiografía con un conjunto de radiografías de referencia en un atlas (atlas GP) [3]. Esto supone un problema de comparación muy subjetiva que depende mucho de la experiencia del radiólogo que realice el estudio [11]. Por tanto, la variabilidad en los diagnósticos de diferentes médicos puede resultar importante.

Debido a que la estimación de la edad ósea, es de extrema utilidad para médicos en otras especialidades que requieren saber el estado de desarrollo óseo de los niños y que los métodos habituales son subjetivos, se puede intuir que contar con un sistema automático de soporte que proporcione información no subjetiva, en el que un médico radiólogo pueda co-validar su diagnóstico, es de suma importancia.

Con el objetivo de eliminar la subjetividad mencionada se propone diseñar un sistema basado en aprendizaje máquina (machine learning) capaz de determinar automáticamente la edad ósea. Además se propone que el sistema diseñado, a diferencia de los encontrados en la literatura, sea incremental en su aprendizaje, es decir, vaya mejorando, y además, sea capaz de encontrar automáticamente y sin la intervención de un experto las diferencias visuales que estén co-relacionadas con las edades óseas, todo esto en un enfoque de aprendizaje incremental supervisado.

Objetivos

Objetivo general:

- Diseñar un sistema de aprendizaje incremental que determine automáticamente la edad ósea en una imagen radiográfica y sea capaz de mejorar gradualmente su desempeño al incrementar su conocimiento durante la fase de evaluación.

Objetivos específicos:

- Obtener un conjunto adecuado de imágenes radiográficas de ejemplo de la mano izquierda de pacientes en el rango de 1 a 18 años.
- Diseñar una disposición (*layout*) de puntos (*landmarks*) sobre la imagen radiográfica que delimite poligonalmente las regiones de interés (ROIs).
- Diseñar un algoritmo basado en aprendizaje automático (*machine learning*) para la detección automática de puntos clave (*landmarks*) en posiciones estratégicas sobre una imagen radiográfica.
- Diseñar un método para alineación de imagen adecuado para la alienación de las características visuales en los huesos de la mano.
- Diseñar una técnica de regresión capaz de interpolar la edad ósea en base a las etiquetas de edades conocidas en los ejemplos de entrenamiento.
- Diseñar un método de aprendizaje incremental capaz de aumentar su base de conocimiento al presentar al sistema nuevas muestras sin sacrificar el tiempo de reconocimiento.
- Integrar los métodos propuestos para diseñar una interfaz básica de software que permita tener un sistema automático de reconocimiento para la edad ósea.

Organización del trabajo

En el capítulo 1 se aborda el tema de edad ósea, así como de los principales métodos manuales y automáticos que existen para estimar este indicador.

En el capítulo 2 se describe el sistema general para estimar la edad ósea y se describen conceptos básicos relacionados con el procesamiento digital de imágenes y visión artificial que serán las bases para el desarrollo de este trabajo de tesis.

El capítulo 3 contiene el desarrollo del sistema propuesto que involucra la disposición (*layout*) de puntos estratégicos (*landmarks*) para la estimación de edad ósea. Después, el algoritmo desarrollado para la detección automática de *landmarks* en las imágenes. Posteriormente, el algoritmo de aprendizaje automático supervisado incremental para regresión. Y finalmente se describe la interfaz gráfica de usuario.

El capítulo 4 contiene las gráficas y los resultados experimentales de cada uno los algoritmos desarrollados en el capítulo 3 así como también muestra el resultado de la interfaz gráfica.

En el capítulo 5 se encuentran las conclusiones del trabajo desarrollado y se describe el trabajo futuro.

Capítulo 1

Estimación automática de madurez esquelética

En este capítulo se presenta el tema de madurez esquelética, como se suele determinar la madurez esquelética usando el atlas y cuáles son los métodos manuales y automáticos que se han desarrollado para obtener este parámetro.

1.1. Radiografía

La radiografía es una técnica que consiste en colocar un objeto entre una fuente de rayos X y un medio receptor. Obteniendo así una imagen radiográfica con diferentes niveles de gris en las partes más densas del objeto colocado debido a la absorción de los rayos X. La radiología es una especialidad médica que utiliza la radiografía para hacer diagnóstico médico normalmente en temas relacionados con el esqueleto, aunque también es posible hacer diagnósticos de tejidos blandos. La aplicación principal comprende colocar al paciente y obtener por medio de esta técnica una imagen de los huesos. Un aplicación muy particular es obtener la imagen con los huesos de la mano, con el fin de determinar el desarrollo esquelético del paciente. La posición de la mano durante el procedimiento es importante para evitar deformaciones en la forma de los huesos. Además se debe de considerar la estructura de los huesos es tridimensional y la imagen obtenida es bidimensional. Las imágenes radiográficas pueden obtenerse de forma física y/o digital.

1.2. Edad ósea de un individuo

La madurez esquelética o edad ósea muestra la relación de los factores ambientales y genéticos de una persona, siendo esto el principal componente de la diferencia de la edad ósea entre diferentes razas con las mismas características. El desarrollo esquelético de una persona no siempre resulta ser el equivalente de su edad cronológica, esto por los factores mencionados anteriormente, sin embargo, cuando existen diferencias grandes, aproximadamente mayores al 10 por ciento de la edad cronológica [6], esta podría ser evidencia de algún desorden de crecimiento. Las principales aplicaciones que se tienen al determinar la edad ósea son varias, de entre las cuales destacan:

- Apoyo para evaluar el desarrollo de niños
- Apoyo para el diagnóstico de desordenes de crecimiento
- Estimación de la altura final de una persona
- Apoyo para el seguimiento de pacientes en tratamiento con corrección de deformidades en los huesos.

La estimación de la madurez ósea de un individuo se puede realizar con diferentes partes del cuerpo como las manos y los dientes [7]. Los métodos más comunes para estimar la edad ósea se basan en observaciones de las radiografías de los huesos de la mano no dominante en rango de edad de 0 a 18 años aproximadamente. Los métodos de Greulich and Pyle (GP) [3] y Tanner and Whitehouse (TW2/3) [4] son los más usados para la estimación de la madurez ósea en radiología. Los huesos presentes en la mano y muñeca tienen formas y apariencia compleja. El método GP utiliza 28 huesos de la mano para determinar la edad ósea, mientras que el método TW2 considera sólo 20 huesos. La figura (1.1), muestra la clasificación general de los huesos de la mano, los cuales son utilizados para la estimación de los dos métodos mencionadas anteriormente GP y TW2/3.

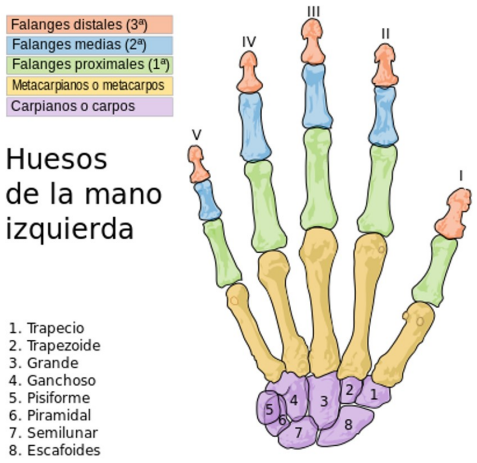

Figura 1.1: Representación de los huesos de la mano y su identificación.

En los métodos manuales la estimación es realizada al comparar la radiografía con un atlas de radiografías previamente etiquetadas. En las uniones de los huesos se presentan los núcleos de crecimiento que son los principales indicadores de desarrollo óseo del paciente, éstos cambios que se presentan en edades cercanas a los 18 años se vuelven difíciles de detectar por medio de imágenes. Existe diversas clasificaciones para la madurez esquelética, estas etapas comprenden ciertas características que proporcionan información útil en un cierto rango de edad, para el caso de individuos menores de 6 y 7 años los huesos carpianos aportan más información [8], para edades mayores de 10 años las falanges contienen información más relevante [9]. En [5], dividen el desarrollo esquelético en seis etapas generales, es importante mencionar que el desarrollo esquelético difiere dependiendo del sexo, es decir, una imagen con unas características dadas tendrá cierta edad ósea dependiendo si trata de un varón o una mujer. Las etapas mencionadas se explican a continuación:

1. Infancia (No hay epífisis en los huesos)
   Femenino: Desde el nacimiento hasta los 10 meses de edad
   Masculino: Desde el nacimiento hasta los 14 meses de edad

2. Niños pequeños (Aparece epífisis en los huesos falanges, metacarpos y carpos de la mano)
   Femenino: Desde los 10 meses hasta los 2 años de edad
   Masculino: Desde los 14 meses hasta los 3 años de edad

3. Pre-pubertad (Esta etapa la define el crecimiento de epífisis en los falanges)
   Femenino: Desde los 2 años hasta los 7 años de edad
   Masculino: Desde los 3 años hasta los 9 años de edad

4. Pubertad (Esta etapa también se basa en la anchura de la epífisis de los falanges)
   Femenino: Desde los 7 años hasta los 13 años de edad
   Masculino: Desde los 9 años hasta los 14 años de edad

5. Pubertad avanzada (Se define por el grado de fusión de las epífisis)
   Femenino: Desde los 13 años hasta los 15 años de edad
   Masculino: Desde los 14 años hasta los 16 años de edad

6. Post-pubertad (Se define por el grado de fusión de la epífisis en el radio y cúbito)
   Femenino: Desde los 15 años hasta los 17 años de edad
   Masculino: Desde los 16 años hasta los 19 años de edad

1.3. Método Greulich & Pyle

En 1937 se publicó un atlas de madurez esquelética [10], podría decirse que el método GP es el producto de esa publicación. Está hecho con el análisis de radiografías pertenecientes de aproximadamente 1000 niños nacidos en Estados Unidos. La primer edición del atlas fue publicada en 1950, a partir de este se desarrollo el método manual que consiste en comparar 28 huesos de la mano y seleccionar la radiografía más cercana del atlas para asignarle la edad ósea correspondiente. Es un método simple, debido a esto es muy utilizado, pero presenta un alto grado de subjetividad. Actualmente se cuenta con un atlas digital [5], es el equivalente del atlas GP. En [11] se realiza un estudio para comparar las estimaciones realizadas de estos dos atlas, obteniendo resultados similares, pero con la ventaja de tener el atlas en formato digital.

1.4. Método Tanner & Whitehouse

El método TW [4] es otro de de los métodos manuales más utilizados para estimar la edad ósea en radiología. El método TW1 se publicó en 1962, posteriormente en 1975 se presento la segunda versión TW2 [4], éste presenta estándares diferentes para el sexo masculino y femenino. Finalmente el método TW3 fue publicado en 2002 con la diferencia de incluir datos recientes recopilados de Estados Unidos y Europa.

El método TW2/3 consiste en etiquetar cada uno de los 20 huesos considerados en ocho etapas de desarrollo esquelético. Un ejemplo de esta clasificación se muestra en la figura (1.2), en donde a cada etapa le corresponde una puntuación. Posteriormente estas puntuaciones se

suman para estimar la edad ósea. El método TW2 fue desarrollado usando 3000 radiografías de niños Británicos. Existen tres variantes de este método:

- **TW-RUS 13**, esta variante del método considera el radio, el cúbito y las falanges.
- **CARPAL**, se enfoca en los ocho huesos carpianos.
- **TW 20**, considera el radio, el cúbito, los huesos falanges y los carpianos.

Se considera que este método es más objetivo que el de GP y proporciona mejores estimaciones, sin embargo resulta complejo y consume mucho tiempo. En [12] se muestra un estudio que reporta errores atribuidos a la persona que realiza el estudio en un rango de 0.25 a 0.5 años, es decir, también presenta subjetividad por parte del médico que realiza el estudio. El método funciona adecuadamente para niños en un rango de 5 a 17 años y en niñas de 5 a 15 años.

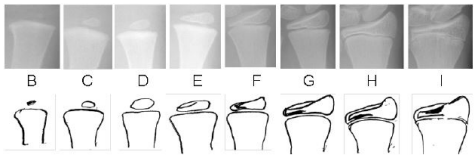

Figura 1.2: Ejemplo de las etiquetas utilizadas en el método TW2 para determinar la etapa de madurez esquelética en el radio [1].

1.5. Métodos automáticos basados en visión por computadora para estimar el desarrollo esquelético

El área de procesamiento de imágenes ha tenido avances que resultan ser de interés para el área médica en particular para el diagnóstico, tratamiento y administración de enfermedades. Las imágenes médicas proporcionan muchas modalidades de estructuras internas que son muy utilizadas para hacer diagnóstico mediante observaciones clínicas. Como es el caso para determinar la edad ósea. Se han propuesto diferentes modelos para realizar esta tarea, basado en los dos métodos manuales más comunes GP y TW2/3. Los sistemas propuestos normalmente están limitados por diferentes factores como:

- Los huesos tienen una forma compleja
- La orientación de la mano y los dedos no es igual en todos los casos
- La distinción de los huesos puede resultar confusa en las imágenes
- Los niveles de gris varían en la radiografía por la diferencia de absorción de los huesos con los rayos X.
- La cantidad de partes que deben analizarse para obtener una estimación resulta ser grande

Se analizan algunos de los modelos propuestos encontrados en la literatura.

1.5.1. Thodberg y otros

Es un método publicado en 2009 [13], que utiliza modelos activos de apariencia para ubicar los huesos y en conjunto con las características de los mismos para estimar la edad ósea, mediante algoritmos basados en el método GP o TW. Utiliza 15 huesos para hacer la estimación y puede hacerlo con radiografías de 2 años de edad en adelante hasta los 17 años. Fue entrenado con 1500 imágenes de niños y 1500 de niñas. Reporta un error medio cuadrático de 0.8 años comparado con el método TW2. Sin embargo, la base de imágenes utilizadas es privada, y para que pueda realizar la evaluación de una imagen esta debe presentar una calidad lo suficientemente buena para asegurar que la estimación de edad ósea es correcta, de lo contrario la imagen es rechazada por el sistema.

1.5.2. Gertych y otros

En [14] se propone un método automático para determinar la edad ósea usando un atlas digital de radiografías, el cuál consiste de dos partes. La primera consiste en almacenar las radiografías de una base de datos pública y la otra parte es un modulo de diagnóstico asistido por computadora el cual fue desarrollado a partir de siete regiones de interés consideradas en este trabajo, los huesos carpianos y las falanges. Con estos componentes se entrenaron 11 categorías de clasificadores difusos relacionadas con la base de imágenes. Reportan un error medio absoluto de 2.15 años. A pesar de que el error es relativamente grande comparado con otros modelos, ofrece la ventaja de utilizar una base de datos pública [6], considerando un rango de edades de 0 a 18 años.

1.5.3. Kashif y otros

En [15] se presenta un trabajo que compara cinco descriptores de características (SIFT, SURF, BRIEF, BRISK FREAK), para estimar la edad ósea. En cada caso se extrajo la sección donde se presentan los núcleos de crecimiento, siendo esta zona la región de interés. La clasificación fue realiza usando una máquina de vectores de soporte (SVM). Para realizar las pruebas utilizaran aproximadamente 1100 imágenes con un rango de edad de 0 a 18 años. Obteniendo un error medio absoluto de 0.605 años, un resultado notable. La desventaja que presenta este trabajo es que la base de datos utilizada es privada y no es posible comparar los resultados con algún otro algoritmo.

1.5.4. Giordano y otros

El trabajo reportado en [16], presenta un modelo para estimación de la edad ósea basado en el método TW2, se enfoca en técnicas de procesamiento de imágenes para obtener los núcleos de crecimiento, que posteriormente se usan con modelos ocultos de Markov para clasificar y estimar la edad ósea. Se reporta un error medio absoluto de 0.41 años. En la prueba sólo se utilizaron 180 imágenes para varones y 180 para mujeres, en un rango de 0 a 6 años de edad.

1.5.5. Spampinato y otros

En [17] se propone un sistema automático basado en aprendizaje profundo (deep learning). El sistema recibe la imagen, después se utiliza un red convolucional (Overfeat, GoogLeNet y OxfordNet) para extraer las características, pasarlas a una red de regresión y obtener la edad estimada. Además se comparan las características obtenidas por el algoritmo y las propuestas manualmente. Reporta un error de 0.8 años, menciona que utilizó una base de datos pública y que el código está disponible en una página web.

1.6. Comparación de los métodos para estimar la edad ósea

En la tabla 1.1 se muestra una comparación de algunos métodos automáticos encontrados en el estado del arte. Se observa el método y el conjunto de imágenes utilizado, también se muestra el error medio absoluto (MAE) que reportaron los autores en su trabajo en dónde varios se presentan alrededor de un año, es importante mencionar que cada de los métodos tiene condiciones diferentes y variadas.

Tabla 1.1: Comparación de algunos métodos revisados en la literatura.

Autor	**Método**	**Banco de imágenes**	**MAE**
Kashif et al [15]	SIFT	Digital Hand Atlas Database System(1101 imágenes) [6]	0.617 años
Giordano et al [16]	Hidden Markov Model	Conjunto de imágenes privadas (360 imágenes)	0.41 años
Spampinato et al [17]	BoNet (Deep learning)	Digital Hand Atlas Database System [6]	0.8 años
Ayala-Raggi et al [18]	Active Appearance Models	Imagen Exakta laboratories (165 imágenes)	1.8 años
Harmsen et al [21]	SVM	Digital Hand Atlas Database System(1097 imágenes) [6]	0.83 años
Fischer et al [22]	Content-based image retrieval	Digital Hand Atlas Database System(1097 imágenes) [6]	0.97 años
Cunha et al [23]	Ensemble learning: bagging	FMUP-HSJ(887 imágenes)	0.85 años

1.7. Conclusiones

Los métodos manuales utilizados para la estimación de la edad ósea resultan ser muy subjetivos, es decir, dependen mucho del criterio del médico radiólogo que este realizando la evaluación. Y los métodos automáticos encontrados en la literatura presentan diferentes situaciones que no los hacen óptimos, algunos tienen rangos de edad limitados, otros requieren imágenes radiográficas de alta calidad para realizar las evaluaciones. La mayoría presenta bases de datos privadas y el código no está disponible (con excepción de uno [17]), esto causa que no se puedan comparar los resultados obtenidos de diferentes propuestas.

Hay poco trabajo que implica características de bajo nivel como píxeles, esto sucede porque los píxeles de una imagen no siempre representan el mismo lugar de un objeto que se va a

reconocer. Sin embargo, pueden usarse como características de clasificación siempre y cuando las imágenes estén correctamente alineadas antes de realizar la comparación.

La estimación del desarrollo esquelético resulta importante para médicos de otras áreas, por lo que se propone desarrollar un sistema que además de estimar la edad ósea de forma automática, integre una etapa de aprendizaje incremental, que producirá mejoras en la estimación con el uso del mismo. Se planea que el sistema se base en métodos de procesamiento de imágenes y algoritmos de aprendizaje automático que puedan extraer las características usando el valor de los píxeles.

Capítulo 2

Sistema general para estimación de la edad ósea

En este capítulo se describe el sistema general propuesto para estimar la edad ósea automáticamente y se describen algunos conceptos básicos relacionados con el procesamiento digital de imágenes y de visión artificial.

2.1. Sistema general

Existen métodos propuestos que utilizan toda la imagen para realizar la estimación de la edad ósea como en [3] y [17]. De acuerdo con [5], es posible estimar el desarrollo esquelético de una persona observando algunas regiones en una radiografía de la mano, debido a que aparecen centros de osificación que van creciendo y son precisamente éstos los indicadores de la edad ósea. Los centros de osificación se encuentran en las uniones de los huesos y en la muñeca, pero no existe un consenso acerca de que regiones deben utilizarse para estimar la edad. Por lo que se han desarrollado trabajos [4], [13], [14], [15] que consideran diferentes regiones de la mano, sin embargo en algunos casos comparten varias zonas, además la cantidad de regiones utilizadas para hacer la estimación también depende de cada propuesta.

Se propone un sistema automático para estimar la edad ósea el cual se representa en la figura 2.1. La primera parte consiste en un procesamiento de la imagen para estandarizar todas las radiografías que entran al sistema, el siguiente paso es la detección automática de puntos ubicados estratégicamente para extraer regiones de interés, después se procede a formar los prototipos con base en ejemplos de entrenamiento y finalmente el último paso es la estimación de la edad ósea usando un algoritmo de aprendizaje automático para regresión. Como parte adicional también contiene una etapa de aprendizaje incremental que permite aumentar el conocimiento del sistema con nuevos ejemplos sin la necesidad de entrenar el algoritmo con todos los ejemplos de entrenamiento iniciales.

Las imágenes que son adquiridas del mundo físico normalmente tienen mucho ruido. Este es el caso de las imágenes radiográficas. Por lo que es común aplicar un pre-procesamiento [14], [16] con el fin de simplificar el trabajo con las radiografías. Este pre-procesamiento consiste primero en segmentar las imágenes, después es deseable cambiar el histograma de cada una

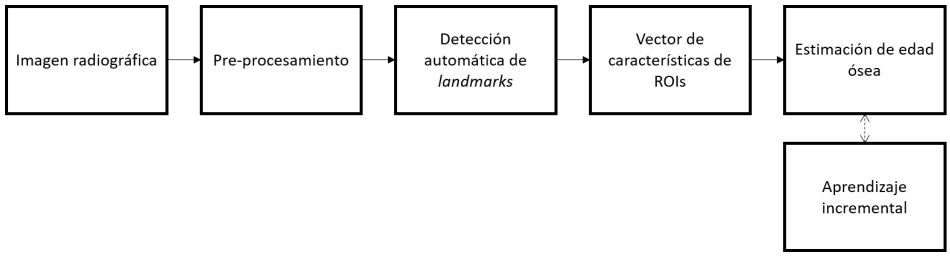

Figura 2.1: Sistema general para estimación automática de la edad ósea.

para obtener mayor contraste en la imagen. Debido a que en este trabajo se utilizarán imágenes digitales primero se define lo que es una imagen digital.

2.2. Imagen digital

Una imagen digital es una representación numérica que describe gráficamente algo. Para obtenerla de un objeto real generalmente se utilizan dos medios: la cámara digital o el escáner. También es posible obtener una imagen, realizada por computadora, que no necesariamente se encuentra físicamente.
Es posible definir dos tipos de imágenes digitales:

- Una imagen en mapa de bits es un arreglo de pixeles con forma rectangular, que se define por altura, anchura y profundidad de color.
- Una imagen vectorial se encuentra formada por representaciones geométricas que están definidas por propiedades matemáticas.

En el desarrollo de este trabajo de tesis es utilizada la representación de imágenes en mapa de bits por lo que de aquí en adelante se hace referencia a este tipo de imagen.

Figura 2.2: Ejemplo de imagen digital del tipo RGB y tamaño LxM.

2.2.1. Propiedades de una imagen digital

Pixel: unidad básica de la imagen digital, el cual es representado como un punto de color.

Profundidad de color: cantidad de bits(n) que representan el color de un pixel. Está definido como 2^n valores posibles. Por lo que, tener 8 bits da como resultado tener entre 0 y 255 colores.

Tamaño: Es el número de pixeles que conforma la imagen, teniendo de largo L y ancho M, con lo cual el tamaño es LxM.

Canal: Es el arreglo numérico de la imagen con un color primario.

Modo de color: Es el sistema utilizado para determinar la cantidad de canales y su profundidad, con el cuál se representa la imagen. Están definidos tres modos de color más utilizados.

- Escala de grises: usa diferentes niveles de gris(dependiendo del número de bits) entre el negro y blanco total.
- RGB: se basa en los colores primarios rojo, verde y azul, por lo que necesita de tres canales para representar una imagen como en la figura (2.2).
- CMYK: utiliza cuatro colores el cian, magenta, amarillo y negro, es decir, cuatro canales.

De acuerdo con los conceptos anteriores una imagen (I) en escala de grises sólo cuenta con un canal como la figura (2.3), esta puede representarse como:

$$I = \begin{pmatrix} x_1, y_1 & x_1, y_2 & \cdots & x_1, y_L \\ x_2, y_1 & x_2, y_2 & \cdots & x_2, y_L \\ \vdots & \vdots & \cdots & \vdots \\ x_M, y_1 & x_M, y_2 & \cdots & x_M, y_L \end{pmatrix} \tag{2.2.1}$$

Figura 2.3: Se muestra la imagen digital de la figura 2.2, en escala de grises.

2.2.2. Histograma

Es la distribución de la frecuencia que tienen los valores de intensidad en cada uno de los pixeles presentes en una imagen. El histograma de la figura (2.3) se muestra en la figura (2.4).

- Expansión del histograma: Es normal que las imágenes digitales obtenidas de un objeto físico no utilicen toda la profundidad de color. Es posible cambiar esta situación usando todo el rango disponible, lo que permite que los objetos en la imagen puedan ser distinguidos con mayor facilidad.

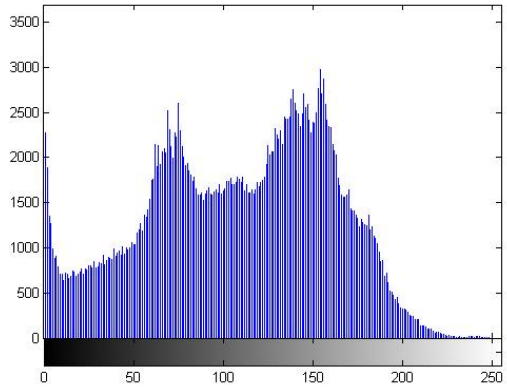

Figura 2.4: Ejemplo del histograma de una imagen en escala de grises.

Una forma de lograr esto es transformar el rango actual mediante una ecuación lineal en el rango deseado, gráficamente se muestra en la figura (2.5), y se obtiene mediante la expresión:

$$y_n = \frac{255}{r_{max} - r_{min}}(x_n - r_{min}) \tag{2.2.2}$$

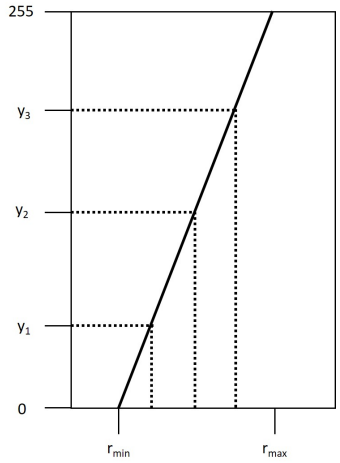

Figura 2.5: Ejemplo de la transformación de valores de una imagen con un rango inicial de $[r_{min}, r_{max}]$ a un rango de [0, 255].

2.3. Segmentación de imagen

Las imágenes radiográficas que se pretenden utilizar en este trabajo presentan una variedad de condiciones, es decir, tienen tamaños diferentes, contienen marcas, puntos grises y negros (ruido), brillo en direcciones diferentes y el contraste en la mano es diferente por lo que se planea crear una etapa de procesamiento de la imagen para estandarizar cada imagen que entre al sistema, para hacerlo se inicia con una segmentación de la mano, es decir conservar sólo la

sección que representa la mano y todo lo demás (fondo de la imagen) hacerlo negro.

La segmentación es el proceso de separar una imagen en partes. Con el objetivo de simplificar el análisis, conservando únicamente las secciones de interés. Es necesario utilizar un método de segmentación debido a que al momento de digitalizar una imagen este proceso se complica por el ruido que se presenta y principalmente por un contraste inconveniente en la imagen resultante.

2.3.1. Métodos basados en el histograma

Este proceso obtiene el histograma de la imagen, posteriormente se utilizan los picos y valles del mismo para identificar los objetos en la imagen, una variante de este método es aplicar el mismo proceso las veces que sea necesario o permitido con el fin de obtener conjuntos más pequeños y así determinar el valor umbral requerido.

2.3.2. Métodos basados en el crecimiento de regiones

Se orienta a colocar puntos en la imagen, en donde cada uno de estos delimitan un objeto que será segmentado, es un proceso repetitivo que provoca el aumento de la región con los pixeles vecinos que no han sido adjudicados a otra, comparando con la media de esa región o con un valor umbral predefinido. Una vez que todos los pixeles pertenecen a una región el proceso termina.
Es un método que depende del punto inicial dado, además de que se ve afectado por el ruido de la imagen.

2.3.3. Método del valor umbral

Se basa en establecer umbrales (límites) de tal modo que los pixeles con un valor definido formen un objeto.
Para la selección del umbral en este tipo de método se presentan dos opciones:

- **Umbral simple:** Se utiliza un sólo valor de umbral, es el caso cuando sólo existen dos conjuntos de pixeles. En dónde los pixeles que cumplen con la condición formaran una nueva imagen $I'(x, y)$.

$$I'(x,y) = \begin{cases} 1 & si \quad I(x,y) > Um \\ 0 & si \quad I(x,y) \leq Um \end{cases} \tag{2.3.1}$$

- **Umbral múltiple:** Este caso se utilizan diferentes umbrales y se presenta cuando es necesario separar varios objetos en una imagen.

$$I'(x,y) = \begin{cases} 0 & si \quad I(x,y) < Um_1 \\ 1 & si \quad Um_1 \leq I(x,y) < Um_2 \\ \vdots & \\ n & si \quad I(x,y) \geq Um_n \end{cases} \tag{2.3.2}$$

2.4. Extracción de características

Una vez que se tiene la imagen modificada el siguiente paso es extraer las áreas de interés, las cuales contienen características con similitudes o diferencias que permiten identificar o clasificar la imagen. El área de visión artificial utiliza métodos para obtener, procesar y analizar imágenes digitales con el objetivo de proporcionar información que sea de interés.

Las características de un objeto representan la información que lo describe y diferencia de otros, es posible que este conjunto de datos sea igual, parcialmente similar o diferente de otros objetos. Estas características pueden ser formas, texturas, tamaños, intensidades, entre otros.

Algunos métodos para obtener las características de un imagen son:

2.4.1. Análisis por componentes principales

Cuando se analiza un conjunto de datos con múltiples variables, es deseado reducir la dimensionalidad, con la condición de que la información pérdida sea relativamente pequeña. El análisis por componentes principales (PCA) analiza si la información puede ser descrita con una cantidad menor de variables, compuestas como combinaciones lineales, de las iniciales. Estas componentes describen a la imágenes (número de datos menor a procesar) que se están analizando. Se fundamenta en calcular la matriz de covarianza del conjunto de imágenes, con lo cual es posible obtener el conjunto de componentes conocido como eigen-imágenes, estos son los eigen-vectores de la matriz.

2.4.2. Parámetros geométricos

Este procedimiento se basa en proponer formas geométricas iguales para obtener las regiones de interés (ROIs), usualmente figuras rectangulares, estas regiones contienen las características de la imagen. Las figuras pueden ser círculos, rectángulos, triángulos, etc. Además es posible utilizar combinaciones de figuras.

En la figura (2.6) se muestra la radiografía de una mano, en la cual se han señalado regiones de interés con figuras rectangulares.

2.5. k-vecinos más cercanos

Finalmente una vez que se ha formado el prototipo de cada imagen el cual cuenta con las características de la imagen el siguiente paso es utilizar un algoritmo que permita clasificar las imágenes de forma automática. El método de los k-vecinos más cercanos (k-NN) es un algoritmo de aprendizaje automático que puede ser utilizado para resolver problemas de clasificación o regresión. Se comparan las distancias de un objeto sin clasificar, con otros ya etiquetados, mediante una función de distancia como la que se presenta a continuación.

$$D_E = \sqrt{\sum_{i=1}^{k}(x_i - y_i)^2} \quad \text{Distancia euclidiana} \tag{2.5.1}$$

Se selecciona el parámetro k, que representa los k objetos con menor distancia del objeto nuevo. Estos "vecinos más cercanos" determinan la clasificación o valor que tiene el objeto nuevo.

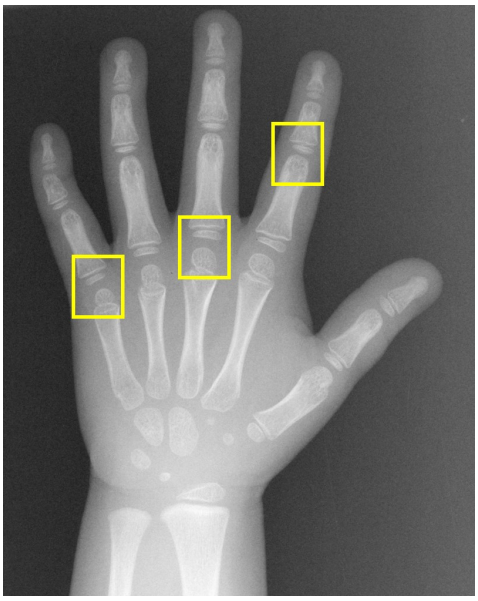

Figura 2.6: Ejemplo de una radiografía utilizando una figura rectangular para delimitar las regiones de interés.

Para el caso específico regresión, en el algoritmo *k-NN* clásico todos los objeto seleccionados tienen el mismo peso de votación para realizar la estimación.

$$\widehat{y} = \frac{\Sigma y_i}{k} \quad \text{k-NN clásico} \tag{2.5.2}$$

En donde cada y_i representa la etiqueta correspondiente a cada uno de los k objetos más cercanos, resultando $\widehat{y}$ es el valor estimado.

Resulta práctico otorgar mayor peso a los k objetos seleccionados en relación con la distancia al objeto nuevo. Significa que mientras más cercano se encuentre un prototipo, mayor contribución tendrá en la estimación.

$$\widehat{y} = \frac{\Sigma(w_i \cdot y_i)}{\Sigma w_i} \tag{2.5.3}$$

En donde cada w_i representa la contribución de cada elemento, es común utilizar una función de base radial (RBF) para calcular este valor como la que se muestra a continuación:

$$w_i = e^{-\frac{d^2}{2\sigma^2}} \tag{2.5.4}$$

Donde d es la distancia entre dos elementos y σ es un parámetro que deberá elegirse.

Capítulo 3

Desarrollo del sistema automático para reconocimiento de la edad ósea

Se describe la validación de la propuesta realizada para ubicar puntos estratégicos sobre una imagen radiográfica para delimitar regiones de interés. También se describe el algoritmo desarrollado para detectar automáticamente las *landmarks* en una imagen radiográfica de la mano de una persona. Además, se describe el algoritmo desarrollado para orientar imágenes similares en la misma posición, el cual es utilizado en la detección automática de *landmarks*. Después se describe la propuesta de un algoritmo que combina las ventajas que ofrece el algoritmo *k-NN* para regresión y el algoritmo *k-means* para formar conjuntos, de tal forma que se obtenga un conjunto reducido de elementos para poder estimar la etiqueta de una muestra desconocida. Finalmente se describen los requerimientos para desarrollar una interfaz de usuario.

3.1. Disposición de puntos para delimitar regiones de interés

En esta sección se describe la validación de la propuesta realizada para ubicar puntos estratégicos sobre una imagen radiográfica para delimitar regiones de interés, se muestra el algoritmo del sistema utilizado para la validación y los resultados obtenidos.

3.1.1. Disposición de puntos propuesta

Se propone utilizar sólo cinco pequeñas regiones de interés para estimar la edad ósea. Éstas se localizan entre los huesos metacarpianos y falanges, fueron seleccionadas de acuerdo con [5] y además porque los cambios en la apariencia observada de 0 a 18 años es mayor que en otras regiones. Es posible utilizar los píxeles de estas zonas como características de bajo nivel siempre y cuando se tengan la alineación de éstas pequeñas regiones de interés.

De acuerdo con el sistema general para estimar la edad ósea planteado en el capítulo 2, el primer paso consiste es determinar una disposición de puntos colocados estratégicamente, la propuesta se presenta en la figura (3.1) con el fin de delimitar las regiones de interés en la radiografía que caracterizan y permiten estimar la edad ósea. Cada uno de los puntos será utilizado como el centro de un círculo a partir de donde se extrae una sección de la imagen, que

representa cada región de interés. Con esta propuesta se consideran 10 *landmarks* que deberán ser ubicadas en cada imagen.

Se parte de la idea de que con la propuesta de *layout*, es decir, utilizando unas pocas y pequeñas regiones de interés, es posible alcanzar una estimación de la edad ósea cercana a los métodos automáticos revisados en el estado del arte, siempre y cuando las regiones se encuentren correctamente alineadas en escala y rotación.

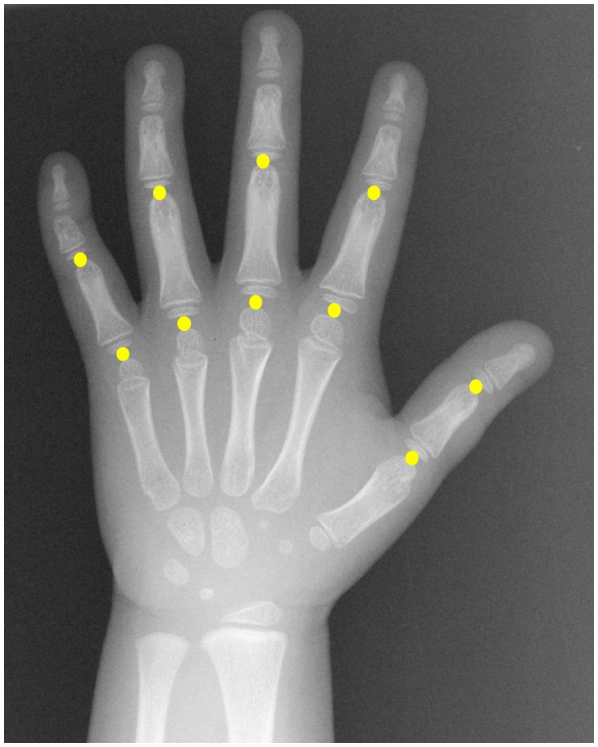

Figura 3.1: Ejemplo de una imagen radiográfica con la propuesta de *layout* de *landmarks*.

Como los centros de osificación crecen con la edad, se especifica que la ubicación exacta de cada *landmark* deberá estar en la posición intermedia entre los huesos, en donde no se presente osificación, cómo se muestra en la figura (3.2).

Figura 3.2: Ejemplo de *landmarks* colocadas en las regiones intermedias que no presentan osificación.

Con el fin de validar la propuesta de *layout* para estimar la edad ósea, se plantea un método manual que utiliza las regiones de interés obtenidas a partir de las *landmarks* para estimar la edad ósea y posteriormente comparar algunos métodos revisados en la literatura con los resultados obtenidos, para finalmente determinar si la propuesta es adecuada.

3.1.2. Sistema manual para estimación de la edad ósea

El método propuesto para la estimación de la edad ósea consiste en dos etapas principales: entrenamiento y evaluación, como se muestra en las figuras (3.3) y (3.4). Se lleva a cabo un pre-procesamiento tanto en la etapa de entrenamiento como en la de evaluación como un primer paso antes de la extracción de características. Este proceso segmenta la mano en la imagen, elimina posibles etiquetas de la radiografía así como objetos no deseados en el fondo, finalmente con el objetivo de estandarizar la imagen se ajusta el contraste.

El segundo paso en las etapas de entrenamiento y evaluación es la colocación manual de los puntos de referencia (puntos de interés) en ubicaciones estratégicas dentro de la imagen radiográfica. El tercer paso, también presente en ambas etapas, corresponde a la segmentación y normalización en escala y rotación de cinco regiones de interés utilizadas para formar un vector de características.

Por último, el cuarto paso es diferente para cada etapa. En el entrenamiento, se almacena el vector de características como un prototipo etiquetado por edad dentro de una base de datos. En la evaluación, se utiliza el vector de características como un prototipo para ser clasificado por el algoritmo de regresión *k-NN* basado en funciones de base radial. Este clasificador de regresión estima la edad ósea por regresión a partir de los prototipos de entrenamiento etiquetados por edad ósea almacenados durante la etapa de entrenamiento.

Figura 3.3: Etapa de entrenamiento.

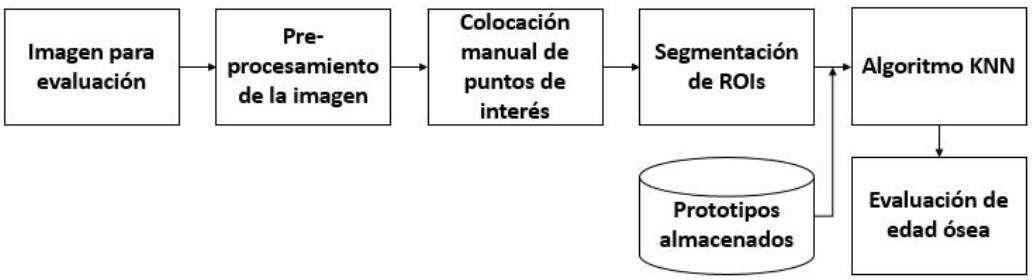

Figura 3.4: Etapa de evaluación.

3.1.3. Pre-procesamiento de la imagen

Las imágenes radiográficas podrían ser diferentes entre sí, ya sea por tener un contraste diferente, por contener objetos no deseados o marcadores radiológicos presentes en el fondo que rodea la mano. En esta sección, se describen las dos fases utilizadas para el pre-procesamiento de las imágenes radiológicas.

3.1.3.1. Segmentación de la mano

El contraste en las regiones de interés utilizadas en este método debe ajustarse de tal manera que la intensidad de gris debe ser similar en todas las imágenes del sistema, con lo cuál se podrá hacer comparaciones entre ellas.

Aunque la cantidad de osificación presente cambia para imagen con diferente edad ósea, esta diferencia es mucho más pequeña y menos perceptible que la presente en las pequeñas regiones de interés seleccionadas. Como consecuencia, en lugar de llevar a cabo el ajuste de contraste en cada región de interés por separado, se decide ajustar el contraste a las imágenes radiográficas completas. Sin embargo, el fondo que rodea la mano no es parte de ella, por lo que es necesario segmentar la región perteneciente a la mano con el fin de ajustar el contraste sólo a esta zona de la imagen. En consecuencia, se necesita una fase de segmentación para la mano antes de modificar el contraste. Se utiliza una variación del algoritmo *floodingfill* de [15] para segmentar la región perteneciente a la mano, como se describe en el pseudocódigo 3.1, obteniendo así una máscara binaria que contiene pixeles con valor de uno en el área perteneciente a la mano y pixeles con valor de cero en todo lo demás.

Pseudocódigo 3.1: Segmentación de la mano

1. Aplicar un umbral a la imagen.
2. Calcular el baricentro.
3. Conservar los píxeles tomando como inicio el baricentro (con conectividad 8), obteniendo BW (máscara binaria).
4. Calcular los bordes usando el algoritmo de Canny.
5. Unir los bordes y BW.
6. Aplicar una operación morfológica de cerrado.
7. Rellenar la segmentación con el algoritmo *floodingfill*.
8. Conservar los píxeles tomando como inicio el baricentro (con conectividad 8).

Una vez que la mano está segmentada, se utiliza la máscara binaria como se muestra en la figura (3.5) con el fin de hacer el ajuste de contraste en esa región.

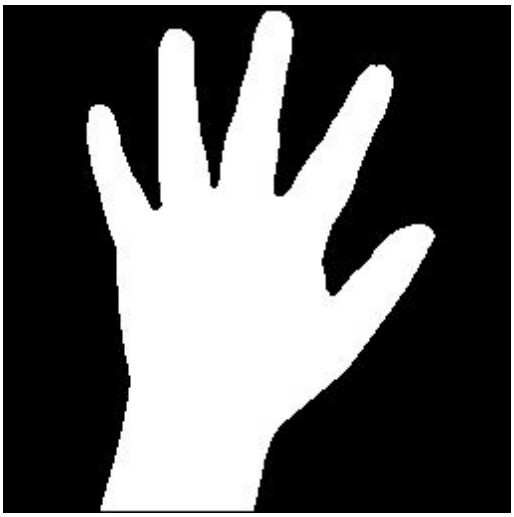

Figura 3.5: Ejemplo de máscara binaria usada para ajuste de contraste local.

3.1.3.2. Ajuste de contraste

La imagen binaria de la mano obtenida en la última sección se utiliza para ajustar el contraste sólo dentro de la región de la mano. Se propone realizar este ajuste de contraste mediante un mapeo lineal simple basado en una media máxima y una media mínima de los valores de las intensidades de nivel de gris en la imagen. Para obtener estos valores, primero se calcula la media μ y la desviación estándar σ de las intensidades de los píxeles. Entonces, la media máxima se puede calcular como MeanMax = μ + 1.5σ y la media mínima como MeanMin = μ - 1.5σ. A partir de estos dos valores es posible hacer un mapeo lineal de todos los valores de gris a un nuevo rango de 0 a 255.

La figura (3.6) ilustra este proceso, en dónde se muestra la imagen antes y después de modificar el contraste.

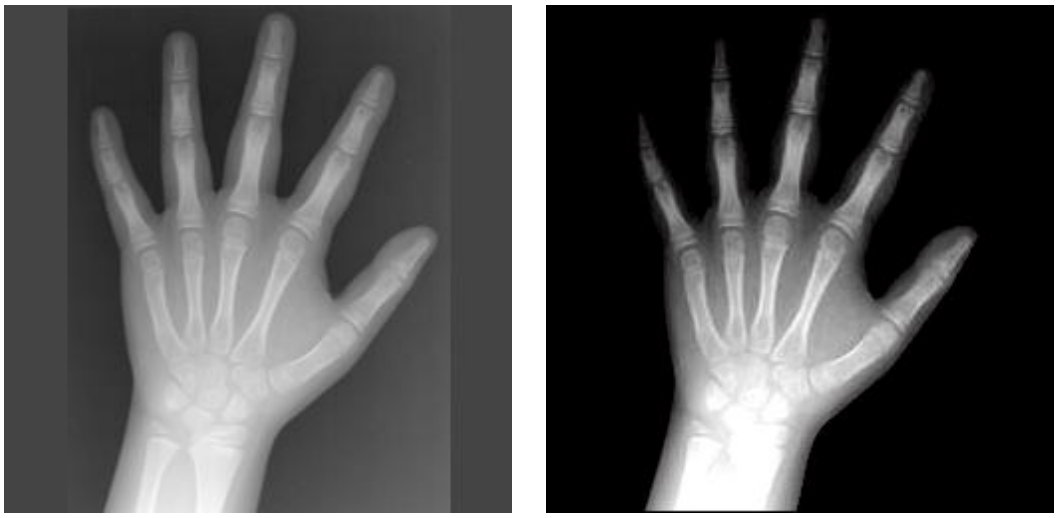

(a) Imagen radiográfica con contraste original. (b) Imagen radiográfica con contraste corregido.

Figura 3.6: Ajuste de contraste en la región de la mano.

3.1.4. Colocación manual de puntos estratégicos

Para delimitar las cinco regiones de interés que caracterizan la edad ósea de una imagen radiográfica, se hace la colocación manual de 10 puntos en la imagen de acuerdo con la propuesta de *layout* como se muestra en la figura (3.1), cinco de ellos situados entre los falanges proximal e intermedia y los demás entre los metacarpianos y falanges proximales. Es importante mencionar que la colocación de *landmarks* se realiza de forma manual para aprovechar cualquiera de los resultados que se podría obtener al validar el *layout*. Si se supone que la propuesta de *layout* no es adecuada, entonces se debe realizar otra propuesta; pero no se perdió tiempo en el desarrollo de un algoritmo que detecte automáticamente las *landmarks*. Si la propuesta es adecuada, entonces se podrían aprovechar las imágenes con *landmarks* para desarrollar el algoritmo de detección automática y/o usarlas para validar este mismo posteriormente. Por lo que resulta conveniente primero colocar los puntos de interés manualmente.

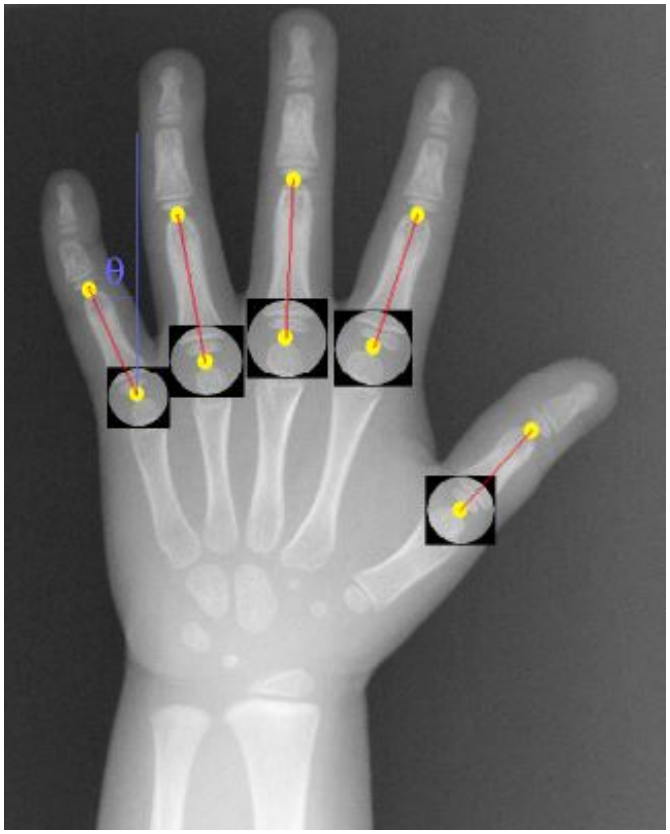

Figura 3.7: Regiones de interés utilizadas. Ángulo θ es calculado usando el punto ubicado entre las falanges proximal e intermedia en el mismo dedo. El tamaño de la región de interés es calculado usando la distancia entre ambos puntos en el mismo dedo multiplicado por un factor constante.

3.1.5. Segmentación de regiones de interés

Después de colocar las *landmarks*, el siguiente paso es extraer las regiones de interés. Los cinco puntos situados entre las falanges proximal e intermedia se utilizan como una referencia geométrica para calcular el ángulo de inclinación θ de cada región de interés con respecto de una línea vertical imaginaria, como se muestra en la figura (3.7).

El tamaño de cada región de interés se calcula con base en la distancia entre los dos puntos del mismo dedo, multiplicado por un factor constante. Se resume el proceso para extraer cada región de interés alineada en tamaño y orientación en el pseudocódigo 3.2.

La figura (3.8) muestra el proceso de extracción de una región de interés. Una vez segmentadas las cinco regiones de interés en una imagen, el siguiente paso es formar un vector de características o prototipo que se almacenará en una base de datos y/o se utilizará como un prototipo de evaluación para estimar la edad ósea.

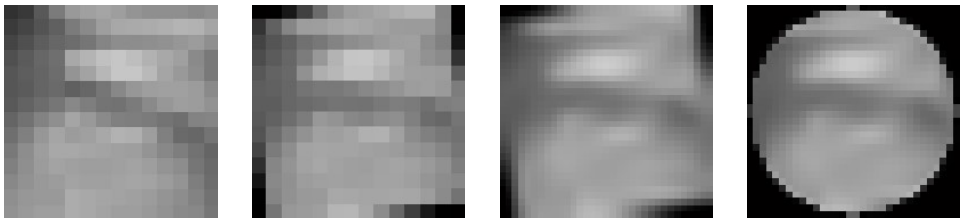

(a) (b) (c) (d)

Figura 3.8: Proceso de alineación y normalización de cada ROI. (a)ROI inicial. (b)ROI rotada. (c)ROI re-dimensionada. (d)ROI con máscara aplicada.

Pseudocódigo 3.2: Extracción de la región de interés

1. Calcular la distancia euclidiana entre los puntos de interés de cada dedo.
2. Multiplicar la distancia por un parámetro D, obteniendo así el tamaño de la región de interés.
3. Segmentar la región de interés cuadrada para cada dedo.
4. Calcular el ángulo θ entre la vertical y la línea imaginaria entre los dos puntos de interés para cada dedo.
5. Rotar cada región de interés para que el nuevo ángulo θ sea igual a cero.
6. Re-dimensionar cada región de interés, obteniendo un tamaño final de 32x32 píxeles.
7. Aplicar una máscara binaria circular a cada imagen región de interés con diámetro de 32 píxeles.

3.1.6. Formación del vector de características

El prototipo es un vector columna que se forma ordenando cada una de las cinco regiones de interés, para que su nuevo tamaño sea 1024x1 (renglones por columnas) en lugar de 32x32. Los cinco vectores de cada región se concatenan para obtener el vector de características de la imagen que tiene un tamaño de 5120x1. En la etapa de entrenamiento, los prototipos se almacenan, y cada uno es asociado con la edad ósea correspondiente de la base de datos. Durante la etapa de evaluación, el vector de características será analizado por un algoritmo de regresión *k-NN* para estimar su edad ósea.

Pseudocódigo 3.3: Regresión usando *k-NN*

1. Calcular la distancia euclidiana entre los prototipos y el vector característico de la muestra.
2. Conservar los k prototipos con menor distancia.
3. Calcular el factor W_i de cada prototipo:

$$W_i = exp\frac{-d_i^2}{2\alpha^2}$$

   Donde α es la distancia más pequeña de los k prototipos más cercanos.

4. Calcular la edad ósea de la muestra:

$$Edad = \frac{\sum_{i=1}^{k} W_i BA_i}{\sum_{i=1}^{k} W_i}$$

   Donde (BA_i) representa la edad ósea respectiva de cada prototipo.

3.1.7. Regresión con el algoritmo *k-NN*

La edad ósea se estima por el algoritmo de regresión *k-NN* que se muestra en el pseudocódigo 3.3 similar a la clasificación utilizada en [13], donde las edades de los k vecinos más cercanos se ponderan por un factor W_i, que depende de la distancia euclidiana d entre el vector de características de evaluación (denominado muestra) y los vectores de características los k prototipos más cercanos.

Con el sistema propuesto es posible evaluar las imágenes radiográficas para estimar la edad ósea utilizando el *layout* propuesto, para así poder calcular el error medio absoluto y con este error tener una medida que permita determinar si el *layout* resulta adecuado para el sistema de estimación automática propuesto en el capítulo 2. De tal forma que una vez que se ha determinado que el *layout* es correcto entonces se procede a desarrollar un algoritmo para detectar automáticamente las *landmarks* en esa posición. De lo contrario es posible que el algoritmo propuesto para ubicar las *landmarks* tenga que rehacerse y eso provocaría retrasos en el desarrollo de la tesis.

3.2. Detección automática de *landmarks*

En la sección anterior se realizó la propuesta de layout demostrando que es posible obtener una estimación de la edad ósea cercana a los trabajos revisado en la literatura, usando pocas regiones de interés. Con el objetivo de obtener un sistema automático para estimar la edad ósea, el siguiente paso es detectar automáticamente las *landmarks* en las imágenes radiográficas.

Para desarrollar el algoritmo de detección automática se considera la región alrededor de cada *landmark* y también la posición relativa que existe entre todas las *landmarks* de cada imagen.

Se propone un algoritmo que esta constituido de tres etapas principales: entrenamiento, detección inicial y refinamiento. El sistema tiene una orientación de comparación de parches (*template matching*), es decir, se toma una región de la imagen denominada parche y se compara con ejemplos para determinar si la región pertenece a una zona que contiene una *landmark* y además se considera que la posición de las *landmarks* no se encuentra muy alejada con respecto del promedio.

En el entrenamiento se usan las imágenes de ejemplo etiquetadas con las *landmarks* para generar conjuntos de parches que serán utilizados para determinar la posición de las *landmarks* en las imágenes de evaluación. También se generan arreglos de los conjuntos de *landmarks* denominados formas que sirven para considerar la posición relativa de cada *landmark* con todo el conjunto de ellas. En la detección inicial se reduce la dimensión de la imagen y se busca cada *landmark* de forma independiente, se extraen regiones y se van comparando con los conjuntos de entrenamiento para determinar si en el parche se encuentra una *landmark*. En la etapa de refinamiento además de la comparación de los parches se considera la posición de las *landmarks*, es decir, a partir del conjunto de *landmarks* se obtiene una región reducida para buscar cada *landmark*. Posteriormente se incrementa la dimensión de la imagen y se repite el proceso de refinamiento hasta llegar a la dimensión inicial de la imagen.

3.2.1. Propuesta de detección automática de *landmarks*

Para encontrar automáticamente las *landmarks* se propone extraer regiones alrededor de cada *landmark* de un conjunto de imágenes de entrenamiento previamente etiquetadas con las *landmarks*. Las regiones son denominadas parches y se agrupan de acuerdo a la *landmark* de donde se obtuvo, en este caso se formaran 10 conjuntos debido a que se propuso una disposición de puntos con 10 *landmarks*, estos parches serán utilizados para identificar si algún parche desconocido corresponde a uno de estos grupos y por lo tanto determinar si existe una *landmark* en la región.

Para poder determinar si el parche corresponde a un grupo de *landmarks* se utiliza el algoritmo descrito en [19] el cual esta basado en el análisis de componentes principales (PCA). Para poder usar este algoritmo las imágenes (parches) tienen que estar alineados y las radiografías presentan manos con diferente orientación por lo que previamente es requerido desarrollar un algoritmo que oriente los parches en la misma posición sin importar cual era su orientación inicial.

3.2.1.1. Algoritmo de ángulo dominante

Se propone un algoritmo para orientar parches en la misma posición sin importar su orientación en función de lo que es llamado su dirección(ángulo) dominante. Para encontrar el ángulo dominante de un parche P con dimensión $w\ x\ w$ se propone construir un histograma de direcciones ponderado que resulta de calcular el gradiente del parche como se describe en el pseudocódigo 4.1. A partir de este histograma se obtienen vectores con dirección dominante de donde se elige uno de ellos para definir el ángulo de ese vector como dirección dominante.

Pseudocódigo 4.1: Histograma ponderado

1. Construir una máscara circular binaria $C(\mathbf{x})$ de diámetro w con valores unitarios dentro del círculo y valores de cero fuera de éste.
2. Calcular el vector gradiente en cada pixel $\mathbf{x}$ de $P(\mathbf{x})$ y hallar la magnitud de cada uno de estos vectores formando con éstas un mapa de magnitudes de gradiente $Gmag(\mathbf{x})$. De forma similar formar un mapa de direcciones de gradiente $Gdir(\mathbf{x})$ (ángulos).
3. Construir un histograma $H(i)$ de 360 bins, donde cada bin i $(i = 1, 2, ..., 360)$ contiene la suma de los valores $Gmag(\mathbf{x}_i)$ donde $\mathbf{x}_i$ son pixeles tales que $C(\mathbf{x}_i) = 1$ e $(i-1)^\circ \leq Gdir(\mathbf{x}_i) \leq i^\circ$.
4. Por cada bin $H(i)$ crear un vector $\mathbf{h}_i$ cuya magnitud sea $H(i)$ y ángulo i. Es decir, crearemos un conjunto M que contiene 360 vectores.

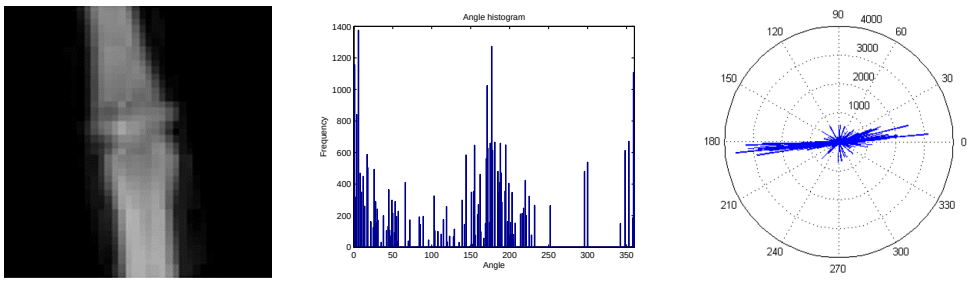

(a) Parche de una radiográfia.

(b) Histograma ponderado del parche centrado en una *landmark*.

(c) Representación circular del histograma ponderado.

Figura 3.9: Histograma ponderado usado para obtener el ángulo dominante del parche.

En la figura 3.9 se muestra el parche de una radiografía, su histograma de direcciones y el conjunto M con los 360 vectores ordenado de forma circular. Se observó que los histogramas presentan dos regiones separadas por más de 90 grados con acumulación de vectores, entonces, se propone construir un conjunto R de vectores $\mathbf{r}$. Cada vector $\mathbf{r}$ es el resultado de la suma vectorial de un conjunto de 90 vectores formado a partir del conjunto M. Después, se obtienen los vectores $\mathbf{v}$ con mayor magnitud de cada región, se propuso inicialmente que se eligiera la dirección del vector con mayor magnitud pero se observó que al rotar un parche es posible que su magnitud cambie un poco obteniendo como consecuencia la dirección del otro vector, para elegir siempre el mismo vector sin importar la rotación se propone utilizar el baricentro de la imagen para construir un tercer vector $\mathbf{v}$, el cual se utiliza para elegir un sólo vector.

Pseudocódigo 4.2: Ángulo dominante del histograma ponderado

1. Posteriormente y a partir del conjunto M construir 360 conjuntos con 90 vectores cada uno:

$$\begin{aligned} H_1 &= \{\mathbf{h}_1, \quad \mathbf{h}_2, \quad \cdots, \quad \mathbf{h}_{90}\} \\ H_2 &= \{\mathbf{h}_2, \quad \mathbf{h}_3, \quad \cdots, \quad \mathbf{h}_{91}\} \\ &\vdots \\ H_{271} &= \{\mathbf{h}_{271}, \quad \mathbf{h}_{272}, \quad \cdots, \quad \mathbf{h}_{360}\} \\ H_{272} &= \{\mathbf{h}_{272}, \quad \mathbf{h}_{273}, \quad \cdots, \quad \mathbf{h}_1\} \\ &\vdots \\ H_{360} &= \{\mathbf{h}_{360}, \quad \mathbf{h}_1, \quad \cdots, \quad \mathbf{h}_{89}\} \end{aligned} \tag{3.2.1}$$

2. Si definimos $\mathbf{r}_i$ como el vector resultante resultado de la suma vectorial de los vectores $\mathbf{h}$ de cada conjunto H_i construido en el paso anterior ($\mathbf{r}_i = \sum_j \mathbf{h}_j$), entonces podemos construir un conjunto R que contiene 360 vectores $\mathbf{r}_i$.

3. Hallar el vector $\mathbf{v}_1$ del conjunto R tal que su magnitud se la máxima del conjunto, es decir $\mathbf{v}_1 = max(\|\mathbf{r}_i\|)$.

4. Del conjunto R hallar el vector de máxima magnitud $\mathbf{v}_2$ cuyo ángulo se encuentra entre $\measuredangle v_1 - 90°$ y $\measuredangle v_1 + 90°$ si comenzamos a buscarlo desde $\measuredangle v_1 - 90°$ en sentido de las manecillas del reloj.

5. Calcular el baricentro de P y usar sus coordendas como componentes para construir el vector $\mathbf{v}_3$.

6. Hacer que el ángulo dominante ϕ sea igual al ángulo $\measuredangle v_i$ con $i = \{1, 2\}$ con el cual se obtiene el mayor resultado al proyectar $\mathbf{v}_3$ en $\mathbf{v}_1$ y $\mathbf{v}_2$.

Para orientar todos los parches en la misma dirección, cada parche se rota menos ϕ grados, en dónde ϕ es el ángulo dominante del parche que se obtiene usando el pseudocódigo 4.2, la figura (3.10) muestra los resultados de aplicar el algoritmo de alineación en función del ángulo dominante a un parche.

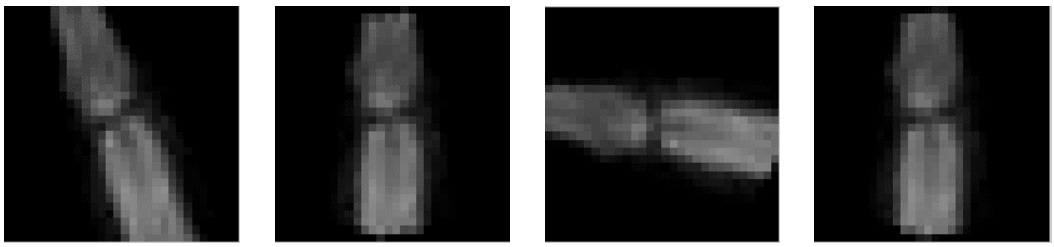

(a) Parche inicial extraído alrededor de una *landmark*.

(b) Parche orientado en rotación con base en su ángulo dominante.

(c) Parche inicial rotado 60 grados.

(d) Parche (c) orietado en rotación con base en su ángulo dominante.

Figura 3.10: Orientación de parches en rotación usando el ángulo dominante.

Una vez que se pueden alinear los parches es posible implementar la etapa de entrenamiento en donde se utiliza el PCA para generar eigen-espacios de los parches y de las *landmarks*.

3.2.1.2. Algoritmo de PCA

La etapa de entrenamiento implementada en la detección automática de *landmarks* fue desarrollada usando la reconstrucción de una imagen con un eigen-espacio que se obtiene a partir del algoritmo de análisis de componentes principales [19], el cuál se describe en el pseudocódigo 4.3, en dónde cada imagen se encuentra en escala de grises, es representada como $I(\mathbf{x})$ y se continúa con la representación de las coordenadas de cada pixel con $\mathbf{x}$.

Pseudocódigo 4.3: Proyección de un vector en un eigenespacio [19]

1. Obtener M imágenes para entrenamiento con la misma resolución.
2. Representar cada imagen $I_n(\mathbf{x})$ como un vector columna $\boldsymbol{\gamma}_n$.
3. Calcular la imagen promedio $\overline{\boldsymbol{\gamma}} = \frac{1}{M}\sum_{n=1}^{M}(\boldsymbol{\gamma}_n)$.
4. Restar la imagen promedio de cada imagen $\mathbf{y}_i = \boldsymbol{\gamma}_i - \overline{\boldsymbol{\gamma}}$.
5. Calcular la matriz de covarianza $\mathbf{C} = \frac{1}{M}\sum_{n=1}^{M}(\mathbf{y}_n \cdot \mathbf{y}_n^T) = \mathbf{A}\cdot\mathbf{A}^T$, dónde $\mathbf{y}_n^T$ y $\mathbf{A}^T$ representan el vector y la matriz transpuesta correspondiente.
6. Calcular los eigenvectores $\mathbf{v}_i$ de $\mathbf{A}^T \cdot \mathbf{A}$.
7. Calcular los eigenvectores $\mathbf{q}_i$ y eigenvalores de $\mathbf{A} \cdot \mathbf{A}^T$: $\mathbf{q}_i = \mathbf{A} \cdot \mathbf{v}_i$.
8. Normalizar los eigenvectores $\mathbf{q}_i$ para que su magnitud sea igual a uno: $\|\mathbf{q}_i\| = 1$.
9. Formar el eigenespacio $\mathbf{Q}$ con K eigenvectores, correspondientes a los K eigenvalores más grandes.

Proyección

10. Representar la imagen $I_u(\mathbf{x})$ como un vector $\boldsymbol{\gamma}_u$.
11. Restar la media al vector de la imagen: $\mathbf{y}_u = \boldsymbol{\gamma}_u - \overline{\boldsymbol{\gamma}}$.
12. Calcular las proyecciones: $w_i = \mathbf{q}_i^T \cdot \mathbf{y}_u$.

Reconstrucción

13. Obtener la reconstrucción de la imagen $\widehat{\mathbf{y}}_u$ usando las proyecciones w_i: $\widehat{\mathbf{y}}_u = \sum_{i=1}^{K}(w_i \cdot \mathbf{q}_i)$.

El algoritmo PCA es utilizado en un conjunto de imágenes de entrenamiento que han sido previamente etiquetadas con las *landmarks* para obtener eigenparches y eigenformas.

Implementación de PCA en los parches de las imágenes

La etapa de entrenamiento en la detección automática de *landmarks* se desarrolla con el algoritmo de PCA, la implementación utilizada en los parches se describe en el siguiente proceso:

1. Crear 10 conjuntos, cada uno corresponde a los parches asociados con las *landmarks*.
2. Para cada imagen de entrenamiento hacer:
   a) Extraer los parches alrededor de cada *landmark*.
   b) Orientar cada parche usando su ángulo dominante y almacenarlo en el conjunto correspondiente a la *landmark* de donde fue originado.
3. Aplicar el algoritmo PCA a los 10 conjuntos para obtener de cada uno el *parche medio* y los eigenespacios que serán denominados *eigenparches* Q_P.

Implementación de PCA en las formas (conjunto de *landmarks*)

La implementación del algoritmo PCA en las formas será utilizada con el objetivo relacionar la posición de cada *landmark* con todas las demás. Se crea un conjunto que contenga las 10 *landmarks*, además, se crean conjuntos que contengan 9 de las 10 *landmarks*, en dónde el primer conjunto contiene todas las formas sin la primera *landmark*, el segundo conjunto contiene todas las formas sin la segunda *landmark* y así sucesivamente hasta llegar a la última, los pasos para realizar este proceso son los siguientes:

1. Colocar las *landmarks* en cada imagen de entrenamiento.
2. Crear 10 conjuntos, cada uno corresponde a las formas sin una *landmark*.
3. Hacer $l = 1$.
4. Eliminar la *landmark* l de cada forma y almacenar el resultado en el conjunto l.
5. Tomar la primera forma del conjunto como referencia $\mathbf{R}_l^{-1}$ y alinear todas formas restantes a la referencia con el análisis de procrustes, dónde $\mathbf{R}_l^{-1}$ es la forma de referencia sin la *landmark* l.
6. Aplicar el algoritmo PCA al conjunto alineado para obtener la *forma media*, los eigenespacios que serán denominados *eigenformas* y las proyecciones ${}_i\mathbf{w}_l^{-1}$.
7. Si $l \leq 10$, hacer $l = l + 1$ y regresar al paso 4.
8. Crear otro conjunto con todas las *landmarks*.
9. Tomar la primera forma como referencia $\mathbf{R}$ y alinear las formas restantes a la referencia con el análisis de procrustes.
10. Aplicar el algoritmo PCA al conjunto alineado para obtener la *forma media*, las *eigenformas*.

3.2.1.3. Método para detectar *landmarks* automáticamente

Para colocar automáticamente las *landmarks* en las imágenes radiográficas se utilizan los eigenparches y las eigenformas, en el pseudocódigo 4.4 se describe el algoritmo propuesto para la detección inicial de *landmarks*, cada imagen $I(\mathbf{x})$ se encuentra en escala de grises con una dimensión de 256x256 pixeles, dónde $\mathbf{x} = (x, y)$ son las coordenadas de cada pixel.

Pseudocódigo 4.4: Detección inicial de *landmarks*

1. De la imagen radiográfica $I(\mathbf{x})$ segmentar la mano para obtener el mapa binario $B(\mathbf{x})$ dónde los pixeles $\mathbf{x}$ con valor igual a uno pertenecen a la mano y todo lo demás tiene pixeles con valor igual a cero.
2. Reducir la dimensión de $I(\mathbf{x})$ y $B(\mathbf{x})$ a 1/16 de su tamaño inicial.
3. Hacer $l = 1$.
4. Para cada pixel $\mathbf{x}$ con valor igual a 1 de $B(\mathbf{x})$ hacer:
   A. De $I(\mathbf{x})$ extraer un parche $P(\mathbf{x})$ con centro en $\mathbf{x}$ y dimensión w x w.
   B. Alinear $P(\mathbf{x})$ usando su ángulo dominante para obtener $P_A(\mathbf{x})$.
   C. Construir un vector columna $\mathbf{p}$ usando cada valor de $P_A(\mathbf{x})$.
   D. Calcular $\widehat{\mathbf{p}}$ al reconstruir $\mathbf{p}$ con PCA usando los eigenparches Q_P correspondientes a la *landmark* l.
   E. Calcular el error de reconstrucción $e = \|\widehat{\mathbf{p}} - \mathbf{p}\|$.
   F. Almacenar e en el mapa de errores $E_l(\mathbf{x})$, dónde $\mathbf{x}$ es la posición del pixel utilizado para obtener $P(\mathbf{x})$.
5. Colocar la *landmark* l en las coordenadas del pixel con menor error e_p obtenido de $E_l(\mathbf{x})$ y almacenarlas en ${}_T\mathbf{S}_l$.
6. Hacer $l = l + 1$.
7. Si $l =< 10$ regresar al paso 4.

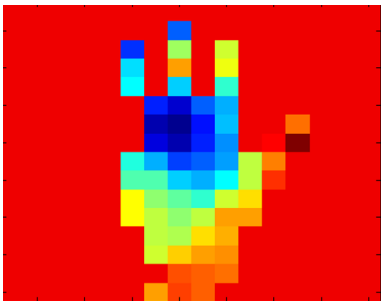

(a) Mapa de errores de reconstrucción de parches escalado en color de una *landmark*.

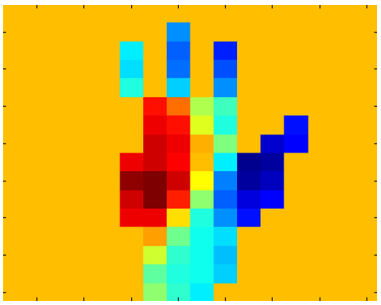

(b) Mapa de errores de reconstrucción de parches escalado en color de una *landmark*.

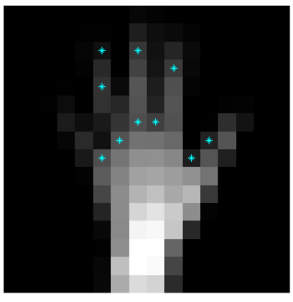

(c) Detección inicial de *landmarks* en una radiográfia.

Figura 3.11: Ejemplo del algoritmo para la detección inicial de *landmarks* en una imagen radiográfica.

Al terminar la etapa anterior, se obtienen las *landmarks* en una resolución pequeña. En la figura (3.11), se muestra el mapa de errores obtenido en dos *landmarks* y el resultado de la detección inicial de *landmarks* en una imagen de ejemplo con resolución reducida. El siguiente paso consiste en aumentar la dimensión de la imagen y volver a localizar cada *landmark* pero ahora tomando como referencia la posición de las *landmarks* encontradas, de tal forma que la búsqueda será en una zona reducida y considerando la posición relativa de las *landmarks*.

Pseudocódigo 4.5: Refinamiento de *landmarks*

1. Para cada *landmark* l de ${}_T\mathbf{S}_l$ de hacer:
   - A. Construir ${}_T\mathbf{S}_l^{-1}$ que resulta de eliminar la *landmark* l de ${}_T\mathbf{S}$.
   - B. Obtener ${}_T\mathbf{S}_l^a$ al alinear la forma ${}_T\mathbf{S}_l^{-1}$ a la forma de referencia $\mathbf{R}_l^{-1}$.
   - C. Formar un vector columna $\mathbf{s}$ con ${}_T\mathbf{S}_l^a$.
   - D. Calcular $\mathbf{w}_l^{-1}$ al proyectar $\mathbf{s}$ en las eigenformas Q_l^{-1}.
   - E. Obtener la forma de entrenamiento ${}_E\mathbf{S}_l^{-1}$ más similar a la forma de la imagen actual ${}_T\mathbf{S}_l^{-1}$ al comparar la proyección $\mathbf{w}_l^{-1}$ con las proyecciones del entrenamiento ${}_i\mathbf{w}_l^{-1}$.
   - F. Alinear ${}_E\mathbf{S}_l^{-1}$ a ${}_T\mathbf{S}_l^{-1}$ usando el análisis de procrustes.
   - G. Aplicar la misma alineación a la *landmark* l de ${}_E\mathbf{S}_l$ para obtener $\mathbf{x}'$, dónde ${}_E\mathbf{S}_l$ es la forma de entrenamiento ${}_E\mathbf{S}_l^{-1}$ con todas sus *landmarks*.
   - H. Hacer $v = abs(||\mathbf{x}' - \mathbf{x}||)$.
   - I. Construir un mapa binario $W(\mathbf{x})$ a partir de $B(\mathbf{x})$, conservar los píxeles de $B(\mathbf{x})$ con valor de uno que se encuentren dentro de una ventana con dimensión v x v centrada en $\mathbf{x}'$, a todo lo demás se le asigna el valor de cero.
   - J. Calcular el error de reconstrucción el parche cambiando $B(\mathbf{x})$ por $W(\mathbf{x})$.
   - K. Construir una nueva forma ${}_T\mathbf{S}_l^{'}$ usando al colocar la *landmark* l en las coordenadas $\mathbf{x}$ con el menor error de reconstrucción de parches obtenido $e_p^{'}$.
   - L. Calcular el error de reconstrucción e_s de forma de ${}_T\mathbf{S}_l$ y el error $e_s^{'}$ de ${}_T\mathbf{S}_l^{'}$.
   - M. Si $(e_s^{'} \cdot k_1 < e_s)$ y $(e_p^{'} \cdot k_2 < e_p)$, entonces ${}_T\mathbf{S}_l =_T \mathbf{S}_l^{'}$.
2. Mientras dimensión actual de $I(\mathbf{x}) < 256x256$ píxeles hacer:
   Aumentar la escala al doble de $I(\mathbf{x})$, $B(\mathbf{x})$ y ${}_T\mathbf{S}_l$ y regresar al paso 1.

En la figura (3.12) se muestra un ejemplo del algoritmo de refinamiento en dónde se observa un cuadro rojo que representa la zona de búsqueda reducida que se obtiene a partir de la posición relativa de las *landmarks*. En la imagen b se muestra el resultado final del algoritmo en dónde se observa la imagen radiográfica con una dimensión de 256x256 pixeles con las *landmarks* encontradas.

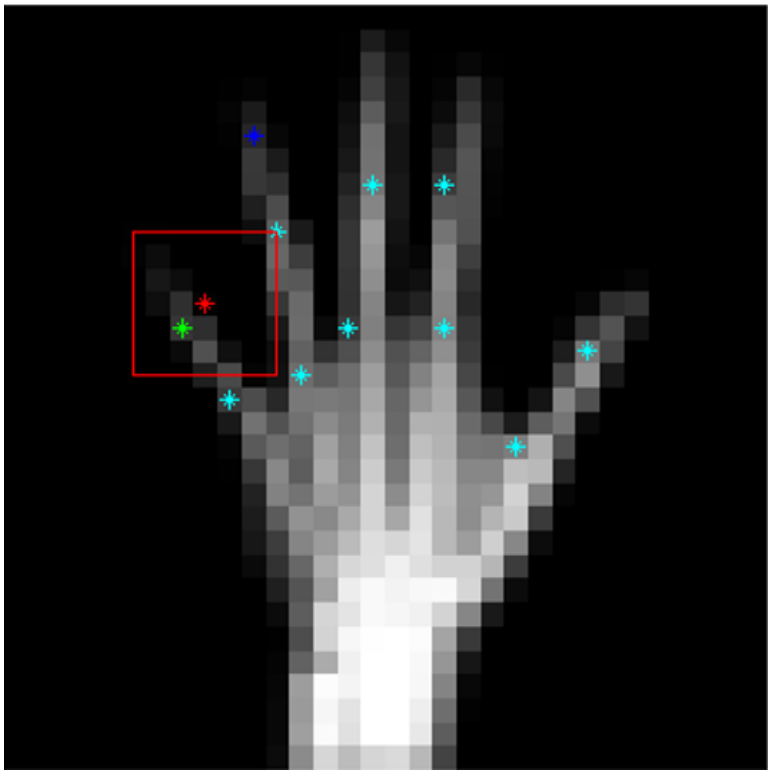

(a) Región de búsqueda reducida de una *landmark*.

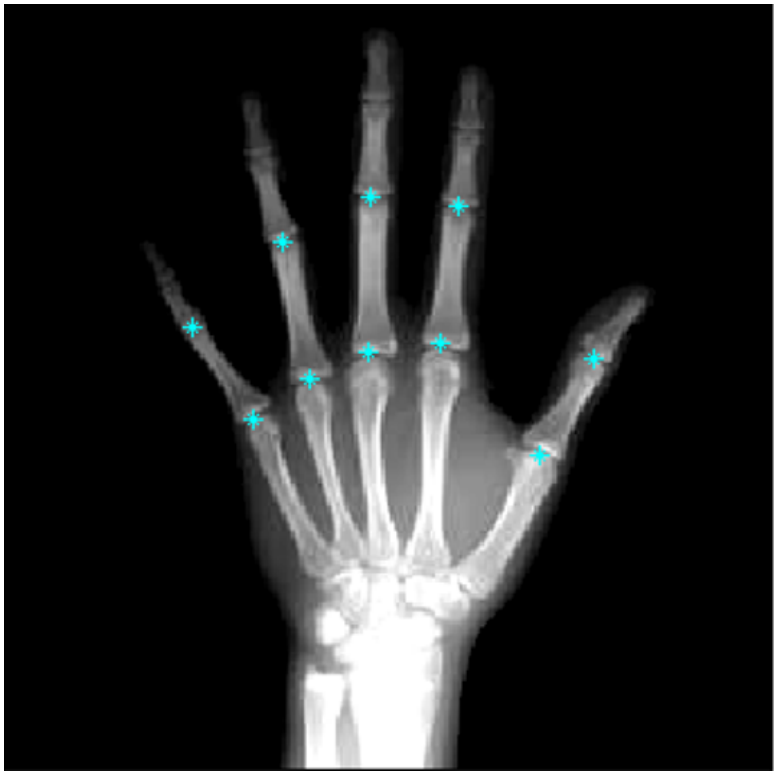

(b) Ejemplo del algoritmo de refinamiento de *landmarks* en una imagen radiográfica.

Figura 3.12: Ejemplo de utilizar el algoritmo para la detección inicial de *landmarks* en una imagen radiográfica.

3.3. Aprendizaje automático incremental

Se desarrolló un algoritmo automático para detección de *landmarks*, también es posible colocar manualmente las *landmarks*. En cualquiera de los dos casos, las *landmarks* se encuentran colocadas en regiones estratégicas que permiten extraer regiones de interés (ROIs) de las imágenes, estás regiones se encuentran asociadas con la edad ósea de la persona, es decir, se cuenta con una agrupación de características y una etiqueta (edad) por imagen. Es posible estimar la etiqueta de una imagen nueva, usando los ejemplos de una base de datos como se realizó en el capítulo 2 con el algoritmo *k-NN* o también se puede utilizar algún otro algoritmo de aprendizaje automático supervisado que permita hacer regresión.

El algoritmo *k-NN* es un método para clasificación supervisada que puede ser adaptado para hacer regresión, la estimación se basa en un conjunto de muestras etiquetadas las cuales son llamadas prototipos, es decir, las características de una muestra asociadas con una etiqueta conforman un prototipo.

Como en la mayoría de los algoritmos de aprendizaje automático existe una etapa de entrenamiento y una etapa de evaluación. En la etapa de entrenamiento este algoritmo guarda los prototipos sin crear ningún tipo de modelo, posteriormente en la etapa de evaluación cuando se busca estimar la etiqueta de una muestra nueva se calcula la distancia entre la muestra y todos los prototipos que contenga el sistema, después se conservan sólo los k prototipos con menor distancia, finalmente se calcula la etiqueta de la muestra con una función que depende de la etiqueta de los k prototipos y su distancia con la muestra.

Una ventaja que ofrece este algoritmo es que si se presenta información no considerada anteriormente al sistema sólo se tienen que almacenar los nuevos prototipos para poder realizar una estimación adecuada, es decir, no se necesita volver a entrenar el sistema con toda la información anterior y nueva como en otros algoritmos. La característica de poder agregar nueva información al sistema es valiosa pero la forma en que lo hace no lo es, porque con cada prototipo que se agrega el tiempo y la cantidad de memoria necesaria para evaluar una muestra crece de forma lineal.

Para evitar que los prototipos en el entrenamiento sean demasiados una opción es seleccionar algunos de ellos, pero el hacer esto implica una pregunta necesaria ¿Cómo seleccionar los prototipos? La forma más sencilla es elegir una cierta cantidad de prototipos aleatoriamente, pero es posible que el conjunto de muestras utilizado para el entrenamiento no muestre una distribución adecuada, esto quiere decir, que los resultados en la etapa de evaluación dependen del conjunto de entrenamiento utilizado.

Entonces, se busca una forma de reducir los prototipos, pero haciendo que la estimación realizada por el sistema sea correcta. El algoritmo *k-means* es un método de clasificación no supervisado, que sirve para hacer agrupaciones el cual podría usarse para reducir la cantidad de prototipos, el algoritmo consiste en crear k prototipos en donde cada uno representa una agrupación. Se calcula la distancia entre cada muestra con cada prototipo, después

cada muestra se agrupa con el prototipo con el cual se haya obtenido la menor distancia, posteriormente se calcula el promedio de las muestras de cada agrupación y el resultado obtenido se convierte en el prototipo de esa agrupación.

Usando este algoritmo es posible representar una cantidad de muestras similares con un número limitado de prototipos lo que supone una solución parcial al problema presentado con el algoritmo *k-NN*, por lo tanto se realizará una propuesta de algoritmo que combine las características de ambos algoritmos (*k-NN* y *k-means*) pero cuidando que la reducción de prototipos no afecte la estimación realizada por el sistema para lo cual se definen condiciones de funcionamiento que deberá cumplir la propuesta.

3.3.1. Condiciones de funcionamiento del algoritmo

Se busca que el algoritmo cuente con algunas condiciones de funcionamiento que permitan asegurar la correcta estimación del sistema pero que también se utilicen los prototipos de una forma más eficiente, para lograr este objetivo se propusieron las siguientes condiciones:

- La estimación del sistema debe ser adecuada.
- La estructura del sistema deber ser adaptable, es decir, permite modificar la posición y etiqueta de cada prototipo.
- Cuando se presente alguna modificación en la red, este cambio no debe perder la información previamente aprendida.
- La red permite el incremento de prototipos, pero sólo cuando sea necesario.
- Debe existir un parámetro que permita tener un control en la cantidad de prototipos que van a ser agregados al sistema.
- No debe ser necesario repetir la etapa de entrenamiento con todas las muestras usadas iniciales para agregar más prototipos al sistema.

El siguiente paso es proponer y desarrollar un método que combina los algoritmos de *k-NN* y *k-means* que además incluya estas características.

3.3.2. Desarrollo del algoritmo

La propuesta del algoritmo de aprendizaje incremental es iniciar con pocos prototipos, estimar la etiqueta de las muestras que van llegando al sistema y si la estimación no es correcta entonces modificar un poco los prototipos o agregar más para mejorar la estimación.

3.3.2.1. Error de estimación

Para definir si una estimación es correcta o no se define una variable llamada umbral de error, que es el límite permitido de error en la estimación. Además del umbral se utiliza una variable llamada error de estimación que es la diferencia entre la etiqueta estimada por el algoritmo y la etiqueta reportada en la base de datos de las muestras.

$Errordeestimación = Etiqueta_{algoritmo} - Etiqueta_{basededatos}$

Entonces, si el error de estimación es superior al umbral de error se establece que la estimación no es correcta, en otro caso se considera una estimación correcta.

3.3.2.2. Estimación de etiqueta

Para poder obtener la estimación de las etiquetas se utiliza al algoritmo *k-NN* con la diferencia de que en este caso los prototipos se van modificando dependiendo de la red y no necesariamente son directamente las muestras. Por lo tanto, la estimación es función de la distancia entre la muestra y los k prototipos más cercanos y las etiquetas de esos prototipos.

$$Etiqueta_{algoritmo} = f(k, distancia_{muestra-prototipos}, etiquetas_{prototipos})$$

Se mencionó la posibilidad de que los prototipos puedan sufrir una modificación, eso significa que se pueden cambiar las características de un prototipo, pero al existir este cambio entonces también debe de cambiar la etiqueta del mismo.

3.3.2.3. Modificación de prototipos

Se platean dos opciones para que un prototipo sea modificado, la primera consiste en crear una memoria de N elementos para cada prototipo, después de evaluar una muestra, está se agrega como un elemento a la memoria del prototipo más cercano al cual se encuentre, posteriormente, se promedia la posición de todos los elementos de memoria y el resultado es la nueva posición del prototipo, la etiqueta se estima usan-do los prototipos restantes para obtener la etiqueta de la nueva posición del prototipo. Se consideró utiliza una memoria tipo *FIFO* en caso de que se encuentre totalmente llena de elementos. La figura 3.13 muestra un esquema simple de un prototipo.

La segunda opción para modificar un prototipo se relaciona cuando se acercan algunos prototipos a una muestra para mejorar la estimación de está. Para realizar esto cada prototipo se acerca individualmente, se calcula la distancia entre el prototipo y la muestra, después, está distancia se divide en L segmentos iguales, entonces el prototipo se acerca una distancia L a la muestra, al tener una nueva posición es necesario calcular la etiqueta usando los prototipos restantes, posteriormente se estiman las etiquetas de las muestran que se encuentran en la

memoria de todos los prototipos y si existe alguna con la condición de etiqueta errónea entonces el prototipo que acaba de ser modificado regresa a su posición inicial y termina de moverse, en caso contrario se sigue moviendo una distancia L hasta que la muestra sea estimada correctamente o el prototipo se encuentre en la posición de la muestra.

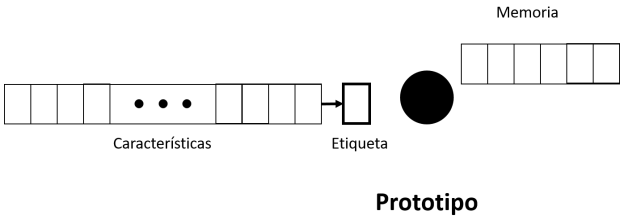

Figura 3.13: Se muestra un esquema de un prototipo, el cual tiene un conjunto de características, una etiqueta y un conjunto de elementos que representan su memoria.

3.3.3. Pseudocódigo de aprendizaje incremental

El pseudocódigo se describe en tres partes, la primera corresponde al caso cuando la etiqueta de una muestra es estimada correctamente por el algoritmo, la segunda cuando se presenta un acercamiento de los prototipos a la muestra para estimarla correctamente y la tercera parte describe el proceso que se sigue cuando no se cumplieron los dos casos anteriores. Siempre que se va a iniciar el algoritmo el primer paso consiste en tomar las primeras dos muestras y convertirlas en prototipos, es decir, las características de la muestra pasan a ser las del prototipo y las etiquetas de las muestras pasan a ser las de los prototipos también.

Pseudocódigo 5.1: Estimación correcta de etiqueta con los prototipos actuales

1. Usar la siguiente muestra y calcular la distancia entre la muestra y todos los prototipos para estimar su etiqueta con el conjunto de prototipos actual.
2. Calcular el error de estimación.
3. Comparar el error de estimación con el umbral permitido, si la estimación es considerada correcta entonces hacer lo siguiente:
   - *a*) Agregar la muestra a la memoria del prototipo más cercano.
   - *b*) Actualizar la posición y etiqueta del prototipo que resulto más cercano.
   - *c*) Usar la nueva configuración de prototipos para calcular la etiqueta de las muestras en la memoria de los prototipos y calcular el error de estimación.
   - *d*) Comparar el error de estimación con el umbral permitido, si la estimación es correcta entonces hacer lo siguiente:
     1) Calcular la distancia entre las muestras y cada uno de los prototipos.
     2) Almacenar las muestras en el prototipo más cercano actual.
   - *e*) Si la estimación en el paso anterior no es correcta entonces, conservar la posición y etiqueta inicial del prototipo modificado.

Aquí se parte del hecho de que la estimación con los prototipos actuales no fue correcta, entonces el siguiente paso es acercar los prototipos a la muestra para mejorar la estimación.

Pseudocódigo 5.2: Estimación correcta cuando se modifican los prototipos actuales

1. Acercar el prototipo más cercano a la muestra hasta que las estimaciones de etiqueta de las muestras de su memoria sigan siendo correctas.
2. Volver a calcular la etiqueta de la muestra actual con la nueva posición del prototipo y calcular el error de estimación.
3. Comparar el error de estimación con el umbral permitido, si la estimación es considerada correcta entonces hacer lo siguiente:
   a) Calcular la distancia entre las muestras que se encuentran en la memoria de los prototipos y cada uno de los prototipos.
   b) Almacenar las muestras en el prototipo más cercano.
4. Si la estimación en el paso anterior no es correcta entonces, repetir los pasos desde 1 hasta 3 con el siguiente prototipo más cercano hasta utilizar los k prototipos más cercanos.
5. Usar los prototipos con su nueva posición para calcular la etiqueta de la muestra y calcular el error de estimación.
6. Comparar el error de estimación con el umbral permitido, si la estimación es correcta entonces hacer lo siguiente:
   a) Almacenar la muestra en la memoria del prototipo más cercano.
   b) Calcular la distancia entre las muestras de la memoria de los prototipos y cada uno de los prototipos.
   c) Almacenar las muestras en el prototipo más cercano actual.

En este caso se parte del hecho de que la estimación es incorrecta con los prototipos actuales y sigue incorrecta después de acercar los prototipos.

Pseudocódigo 5.3: Estimación incorrecta de la muestra

1. Hacer que los prototipos recuperen sus características y etiquetas que tenían antes de tomar la última muestra.
2. Hacer que la muestra junto con su etiqueta se convierta en un prototipo.
3. Calcular la distancia entre las muestras de la memoria de los prototipos y cada uno de los prototipos.
4. Almacenar las muestras en el prototipo más cercano actual.

Con esta parte el algoritmo de aprendizaje incremental se encuentra descrito completamente y sólo falta validarlo con diferentes bases de datos para comprobar su funcionamiento.

3.4. Desarrollo de la interfaz de usuario

Después de desarrollar los algoritmos el siguiente objetivo planteado en este trabajo es integrar todo el desarrollo en una interfaz de usuario que permita usar el sistema de reconocimiento de la edad ósea. Resulta conveniente utilizar una metodología que permita obtener las especificaciones de los requerimientos funcionales, es decir, establecer la comunicación que deberá tener el sistema para que las personas que van a utilizar puedan hacerlo eficientemente, por lo tanto se eligen los casos de uso [24] para cumplir con esta función.

3.4.1. Casos de uso

Los casos de uso describen una serie de acciones que realiza el sistema para obtener un resultado específico deseado.

El modelo de casos de uso se compone de dos partes, un diagrama y un escrito. El diagrama sirve para mostrar las relaciones entre los actores y los casos de uso y viceversa. El escrito muestra la descripción que explica las características de los caso de uso. Los actores representan una entidad fuera del sistema que interactúa con el sistema. Los casos de uso representan lo que el actor espera que haga el sistema.

Por lo tanto para el sistema automático de reconocimiento de la edad ósea se tienen los diagramas mostrados en las figuras 3.14 y 3.15. El escrito correspondiente a cada caso de uso se describe en las tablas 3.1 a 3.9.

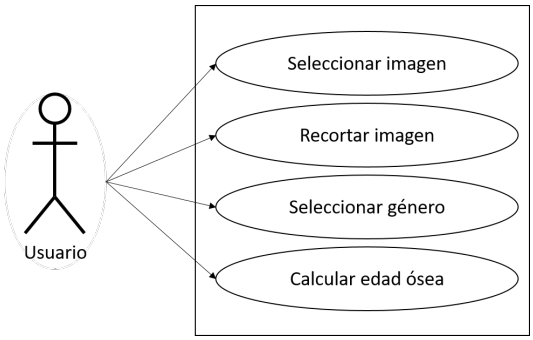

Figura 3.14: Diagrama de los casos de uso referente a la estimación de edad ósea de una imagen radiográfica.

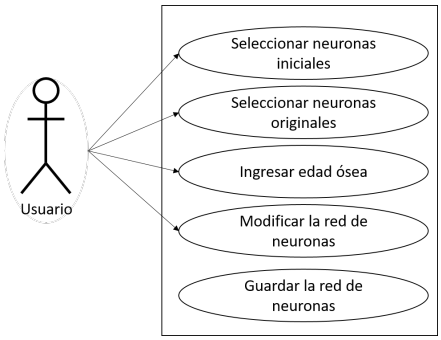

Figura 3.15: Diagrama de los casos de uso referente al algoritmo de aprendizaje incremental para la estimación de la edad ósea.

CU-01	**Seleccionar imagen**
Descripción	Seleccionar imagen para estimación de edad ósea
Secuencia normal	1. El sistema muestra una ventana para seleccionar una imagen de cualquier parte del almacenamiento de la computadora. 2. El usuario selecciona la imagen y presiona el botón de abrir de la ventana. 3. Se muestra la imagen y su nombre en la interfaz gráfica.

Tabla 3.1: Caso de uso: Seleccionar imagen

CU-02	**Seleccionar imagen**
Descripción	Recortar la imagen para estimación de edad ósea
Secuencia normal	1. El sistema cambia el cursor del *mouse*. 2. El usuario dibuja un rectángulo con ayuda del *mouse* en la imagen y lo va ajustando para conservar sólo el área de interés. 3. El usuario hace doble clic en la imagen para confirmar la selección del área. 4. El sistema muestra la imagen recortada en la interfaz gráfica.

Tabla 3.2: Caso de uso: Recortar imagen

CU-03	**Selección de género**
Descripción	Seleccionar el género femenino o masculino de la imagen para estimación de edad ósea
Secuencia normal	1. El sistema muestra las opciones de género femenino y masculino en la interfaz gráfica y sólo permite seleccionar una opción. 2. El usuario selecciona el género correspondiente a la imagen radiográfica. 3. El sistema actualiza el valor del parámetro para seleccionar la red de neuronas entrenadas para ese género.

Tabla 3.3: Caso de uso: Selección de género

CU-04	**Calcular edad ósea**
Descripción	Calcular la edad ósea de la imagen radiográfica seleccionada
Secuencia normal	1. El sistema toma la imagen seleccionada o recortada que se encuentre en ese instante. 2. El sistema toma el género que se encuentre seleccionado en ese instante. 3. El sistema utiliza la red neuronal almacenada para este tipo de género, detecta las *landmarks*, calcula la región de interés y estima la edad ósea. 4. El sistema muestra la imagen con la corrección de contraste, las *landmarks*, las región de interés y la edad ósea estimada.

Tabla 3.4: Caso de uso: Calcular edad ósea

CU-05	**Seleccionar neuronas iniciales**
Descripción	Seleccionar las neuronas iniciales antes de ser modificadas con la imagen presente
Secuencia normal	1. El sistema regresa las neuronas a como se encontraban antes de modificar la red sin haber elegido la opción de guardar red.

Tabla 3.5: Caso de uso: Seleccionar neuronas iniciales

CU-06	**Seleccionar neuronas originales**
Descripción	Seleccionar las neuronas originales sin alteraciones realizadas por cualquier usuario en cualquier momento
Secuencia normal	1. El sistema regresa las neuronas a como se encontraban antes de ser modificadas por cualquier usuario.

Tabla 3.6: Caso de uso: Seleccionar neuronas originales

CU-07	**Ingresar edad ósea de la imagen radiográfica**
Descripción	Ingresar edad ósea de la imagen radiográfica presente
Secuencia normal	1. El usuario ingresa en el sistema la edad ósea de la imagen radiográfica evaluada por un experto.

Tabla 3.7: Caso de uso: Ingresar edad ósea

CU-08	**Modificar la red de neuronas**
Descripción	Modificar la red de neuronas usando la edad ósea evaluada por un experto y la imagen radiográfica presente
Secuencia normal	1. El sistema toma la edad ósea ingresada, el género seleccionado y la imagen o recorte presente. 2. El sistema forma el prototipo de la imagen y lo ingresa al algoritmo de aprendizaje incremental para modificar la red de neuronas. 3. El sistema utiliza la red neuronal modificada, detecta las *landmarks*, calcula la región de interés y estima la edad ósea. 4. El sistema muestra la imagen con la corrección de contraste, las *landmarks*, las región de interés y la edad ósea estimada.

Tabla 3.8: Caso de uso: Modificar la red de neuronas

CU-09	**Guardar la red de neuronas**
Descripción	Guardar la red de neuronas modificada
Secuencia normal	1. El sistema guarda la red de neuronas modificada correspondiente al género seleccionado.

Tabla 3.9: Caso de uso: Guardar la red de neuronas

Capítulo 4

Resultados

En este capítulo se presentan los resultados obtenidos a partir de los algoritmos desarrollados en el capítulo 3. Primero se presentan los resultados para determinar la disposición de puntos en la imagen radiográfica, después se presentan los resultados de implementar la detección automática de puntos de interés, luego se muestran los resultados del algoritmo de aprendizaje automático supervisado incremental y finalmente se presenta la interfaz gráfica.

4.1. Resultados de la disposición de puntos estratégicos

La primer parte del sistema propuesto para estimar la edad ósea automáticamente consiste en seleccionar que regiones de interés son las adecuadas para este trabajo, por lo que se realizó la propuesta de una disposición (*layout*) de puntos en la imagen radiográfica.

Para validar que la disposición de puntos fuera adecuada se implemento el sistema mostrado en las figuras (3.3) y (3.4) en dónde se estima la edad ósea de un conjunto de imágenes radiográficas usando el *layout* propuesto y posteriormente se calcula el error obtenido entre la edad ósea estimada y la edad real reportada en la base de datos.

Se evaluó el sistema usando un conjunto de imágenes públicas tomadas de [12], esta conformado por radiografías de manos en un rango de 0 a 18 años de edad ósea que fueron evaluadas por dos expertos diferentes. Las radiografías se encuentran dividas por género (femenino y masculino), por raza (asiático, afroamericano,hispano y caucásico). En la validación realizada, las imágenes se separaron únicamente por género y fueron mezcladas aleatoriamente en cuánto a raza y edad.

4.1.1. Re-dimensionado de las imágenes originales

Las imágenes de la base datos tienen diferentes tamaños de resolución. Normalmente, la dimensión vertical (columna) es 256 y la horizontal (renglón) es menor de 256 píxeles. Entonces, se agregaron dos bandas laterales a la cuales el color se calculó a partir de los píxeles en cada borde lateral de la imagen, obteniendo una dimensión final de 256x256 píxeles en cada imagen.

4.1.2. Estimación de la edad ósea

El sistema fue probado para el grupo femenino y el masculino por separado usando 100 imágenes de prueba con edades y razas mezcladas al azar. Las figuras (4.1) y (4.2) muestran los histogramas de edad ósea para ambos grupos de evaluación (femenino y masculino), mostrando un equilibrio de edad adecuado con el fin de demostrar la capacidad del algoritmo para estimar la edad ósea en todas las edades y grupos étnicos.

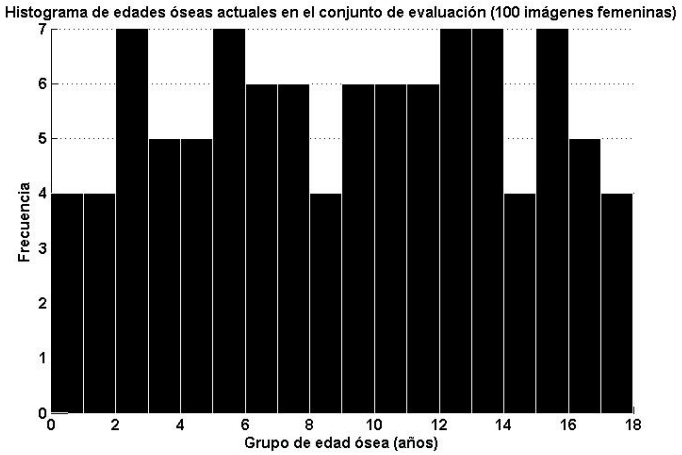

Figura 4.1: Histograma de la edad ósea actual del conjunto de 100 imágenes usadas para evaluación del grupo femenino.

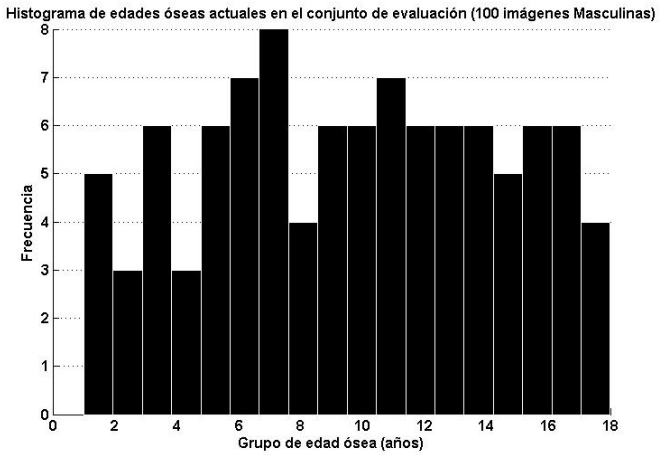

Figura 4.2: Histograma de la edad ósea actual del conjunto de 100 imágenes usadas para evaluación del grupo masculino.

Se usaron 300 imágenes de todos los grupos étnicos y edades para la etapa de entrenamiento. Cada imagen fue etiquetada manualmente con las 10 *landmarks* para obtener un vector de características. Se evaluó el sistema calculando el error medio absoluto (MAE) y el error medio cuadrático (RMSE) entre las 100 edades óseas actuales (edad ósea reportada en la base de datos) y las 100 edades óseas estimadas por el sistema.

La evaluación con el algoritmo *k-NN* se realizó variando k de $k = 2$ a $k = 26$, obteniendo mejores resultados con $k = 7$ y $k = 10$ para las imágenes femeninas y masculinas respectivamente, como se muestra en las figuras (4.3) y (4.4).

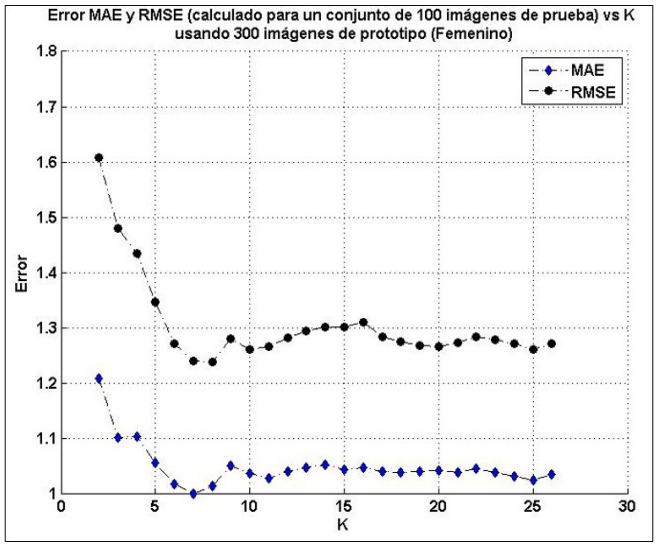

Figura 4.3: Error de estimación con 300 imágenes de entrenamiento para el conjunto femenino con 100 imágenes de evaluación, variando el parámetro k del algoritmo *k-NN*.

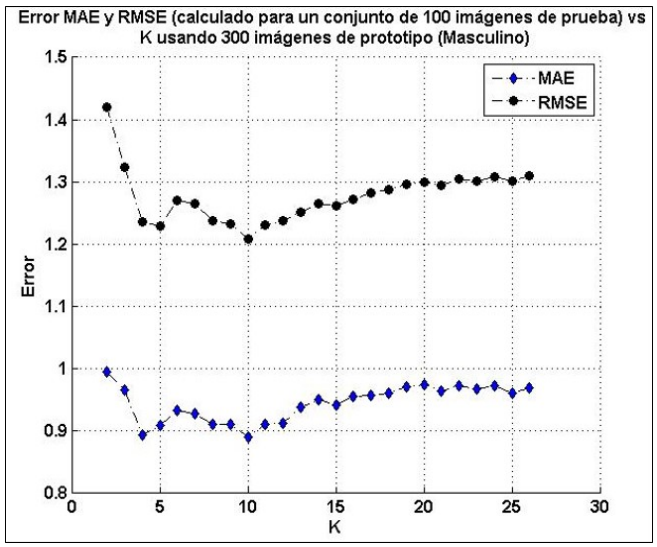

Figura 4.4: Error de estimación con 300 imágenes de entrenamiento para el conjunto masculino con 100 imágenes de evaluación, variando el parámetro k del algoritmo *k-NN*.

Finalmente, las figuras (4.5) y (4.6) muestran una comparación entre las edades óseas actuales y las estimadas, ordenadas de menor a mayor usando el valor óptimo de k para cada grupo. Se observa en ambas gráficas una mayor separación de los valores actuales y estimados de la edad en los límites del rango de edad, 0 y 18 años.

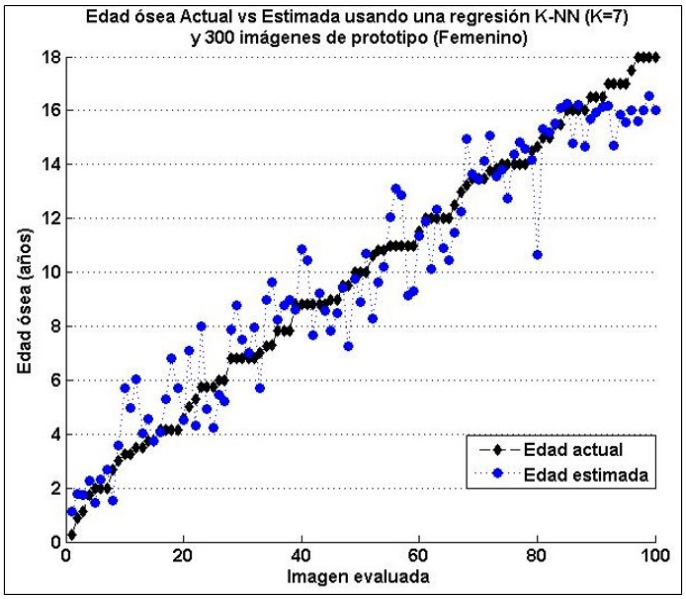

Figura 4.5: Edad ósea actual vs edad ósea estimada del grupo femenino, usando 300 prototipos de entrenamiento y 100 imágenes de evaluación donde la edad ósea actual fue ordenada de menor a mayor.

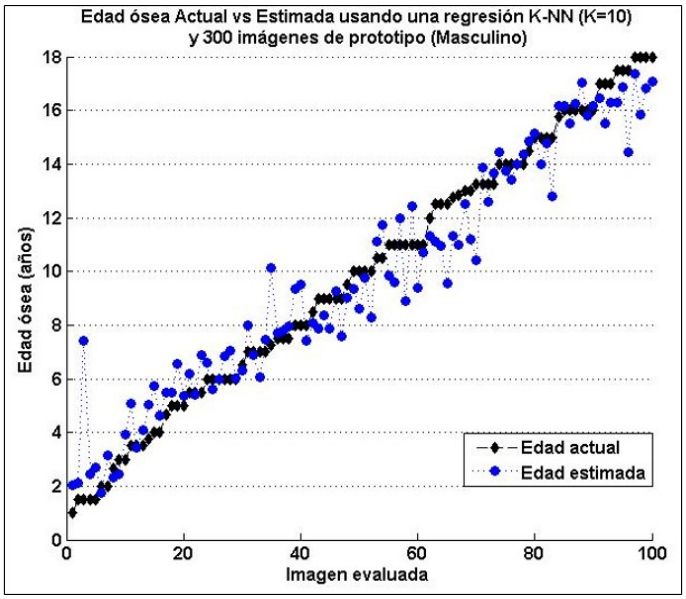

Figura 4.6: Edad ósea actual vs edad ósea estimada del grupo masculino, usando 300 prototipos de entrenamiento y 100 imágenes de evaluación donde la edad ósea actual fue ordenada de menor a mayor.

La tabla 4.1 muestra los errores reportados para diferentes métodos revisados en la literatura. En el método propuesto se obtiene un MAE de 0.95 años, al promediar el MAE del grupo femenino y del masculino.

Tabla 4.1: Comparación de algunos métodos revisados en la literatura.

Método	**Banco de imágenes**	**MAE(años)**
Propuesta	Digital Hand Atlas Database System [6]	* 0.95 años
Ayala-Raggi et al [18]	Imagen Exakta laboratories (165 imágenes)	1.8 años
Spampinato et al [17]	Digital Hand Atlas Database System [6]	0.8 años
Giordano et al [16]	Conjunto de imágenes privadas (360 imágenes)	0.41 años

4.1.3. Discusión de resultados

Los resultados muestran que los errores de estimación son muy cercanos a los reportados en los trabajos revisados en la literatura, obteniendo un MAE de 1.0 y RMSE de 1.24 años para el grupo femenino y un MAE de 0.89 y RMSE de 1.21 años para el grupo masculino.

A diferencia de otros métodos de aprendizaje automático, este método necesita relativamente pocas imágenes de entrenamiento para alcanzar prácticamente el mismo error de edad que los otros métodos reportan. Sin embargo, este sistema presenta un error considerable en los límites de las edad ósea como se muestra en las figuras (4.5) y (4.6), que se deba posiblemente a la interpolación por el método *k-NN*. Finalmente, revisando los errores reportados en la literatura y el obtenido, se considera que el *layout* propuesto es adecuado para utilizarse en la estimación de la edad ósea.

4.2. Resultados de la detección automática de puntos

Después de determinar la disposición de puntos en la imagen, de acuerdo con el sistema propuesto en el capítulo 2, el siguiente paso consiste en ubicar estos puntos en la radiografía de forma automática, por lo que se propuso un algoritmo para detección automática de *landmarks*.

Para evaluar el funcionamiento del algoritmo, se utilizó el algoritmo para detectar las *landmarks* y se calculó la distancia euclidiana en pixeles entre la colocación manual y la automática de cada *landmark*. Además, se usó el sistema desarrollado en el capítulo 3 pero utilizando el algoritmo para detección automática de *landmarks* como se muestra en la figura (4.7) para estimar la edad ósea, calcular el error de estimación y comparar el resultado obtenido en dónde se usa la colocación manual de *landmarks*. Al igual que el caso anterior también se utilizaron 300 imágenes de entrenamiento y 100 para evaluación con cada género de la base de datos de [12].

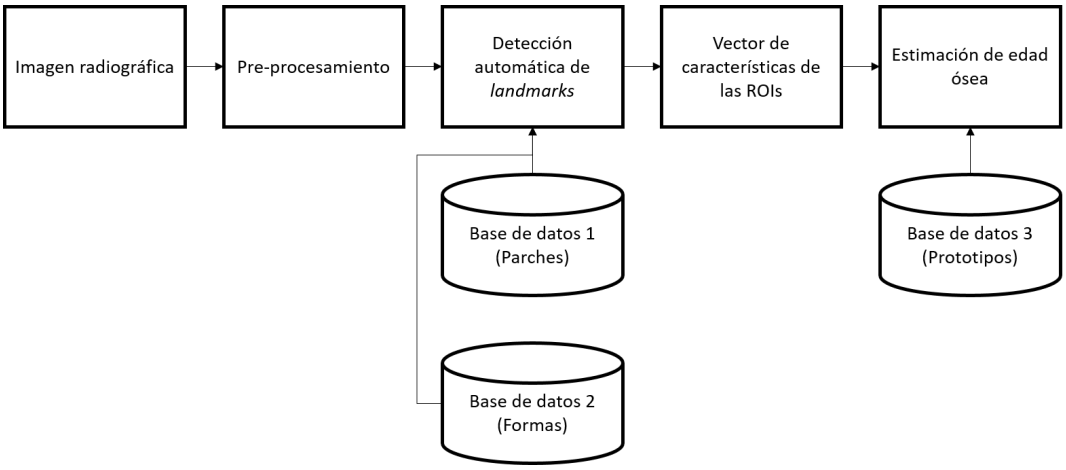

Figura 4.7: Diagrama de general del sistema con la detección automática de *landmarks*.

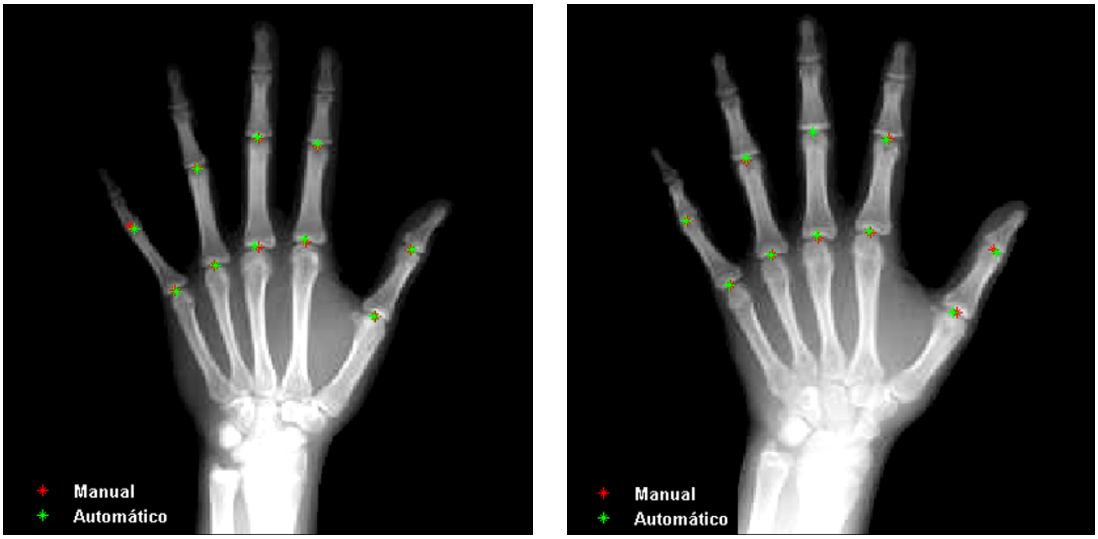

(a) (b)

Figura 4.8: Comparación de la colocación manual y la detección automática de *landmarks* en una imagen radiográfica.

En la tabla (4.2) se muestran los resultados obtenidos al calcular la distancia euclidiana en pixeles de la colocación de *landmarks*, la distancia media se encuentra alrededor de 2 píxeles, considerando que las imágenes son de 256x256 píxeles puede considerarse un resultado aceptable. En la figura (4.8) se muestran dos imágenes de ejemplo para comparar las *landmarks* colocadas manualmente y las obtenidas por el algoritmo automático.

Tabla 4.2: Distancia euclidiana media en píxeles, entre las *landmarks* ubicadas por el algoritmo y las colocadas manualmente, en las imágenes de evaluación. Se muestran los datos por cada *landmark* para este grupo de imágenes.

Distancia ***Landmark***	**media** **Femenino**	**(píxeles)** **Masculino**
1	2.348	2.275
2	1.389	1.520
3	2.010	1.959
4	1.070	1.023
5	1.983	1.847
6	1.129	1.104
7	1.742	2.003
8	1.149	1.220
9	2.042	2.851
10	1.724	1.952

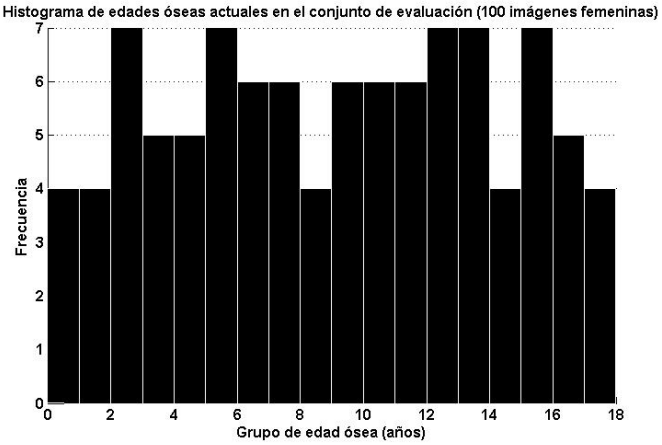

(a) Grupo femenino

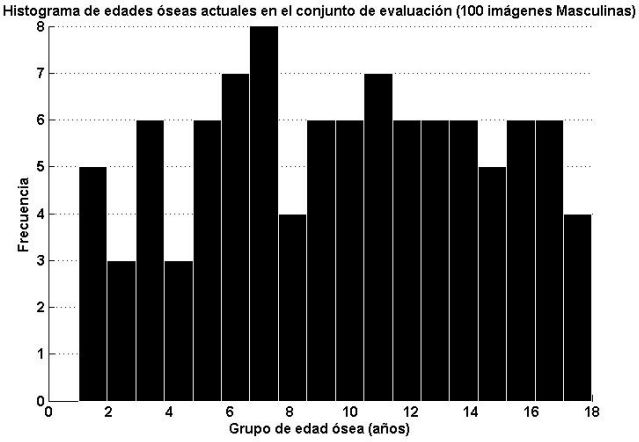

(b) Grupo masculino

Figura 4.9: Histogramas de la edad ósea actual de cada conjunto de 100 imágenes usadas para evaluación.

No se obtuvo una colocación de *landmarks* aceptable en todos los casos debido a la posición final de las *landmarks* se encontraba muy alejada de la colocación manual por lo que se excluyeron del grupo de evaluación. Se obtuvieron 94 de 100 imágenes aceptables para el grupo femenino y para el masculino 92 de 100.

Después de desarrollar el algoritmo de detección automática y observar que la colocación de *landmarks* es adecuada se procede a integrar el algoritmo al sistema desarrollado en el capítulo 3 para comparar la estimación de edad ósea con el algoritmo automático.

La figura (4.9) presenta los histogramas de edad ósea para ambos grupos de evaluación (femenino y masculino), en dónde se muestra que se utilizan todas las edades óseas (de 1 a 18 años) para obtener resultados del sistema desarrollado en todo el rango de edad.

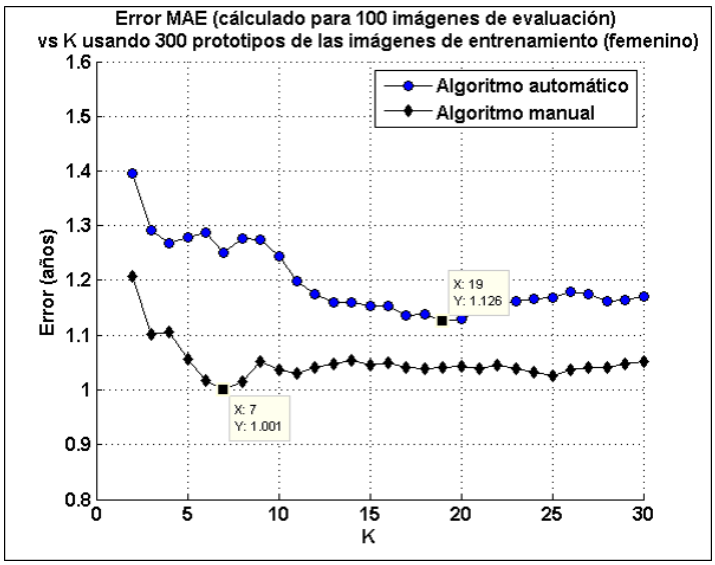

(a) Grupo femenino

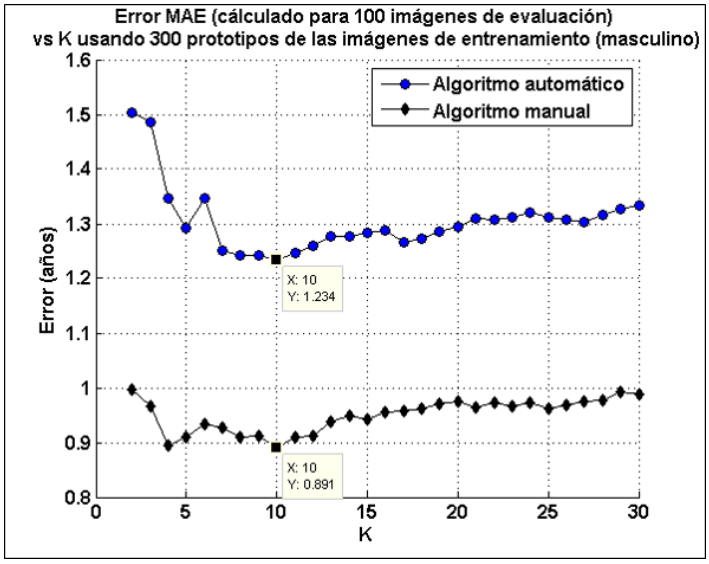

(b) Grupo masculino

Figura 4.10: Error MAE calculado en función del parámetro k del algoritmo *k-NN* comparando la estimación con la colocación manual y la detección automática de *landmarks*.

Se calculó el error medio absoluto (MAE) entre las 100 edades óseas actuales (edad ósea reportada en la base de datos) y las 100 edades óseas estimadas por el sistema con la colocación manual de *landmarks* y el algoritmo automático.

La evaluación con el algoritmo *k-NN* se realizó variando k de $k = 2$ a $k = 30$, usando el algoritmo para detección automática de *landmarks* se obtuvieron mejores resultados con $k = 19$ y $k = 10$ para las imágenes femeninas y masculinas respectivamente, como se muestra en la figura (4.10).

Finalmente, la figura (4.11) muestra la comparación entre las edades óseas actuales y las estimadas, ordenadas de menor a mayor usando el valor óptimo de k para cada grupo. Se observa en ambas gráficas una mayor separación de los valores actuales y estimados de la edad en los límites del rango de edad, 0 y 18 años.

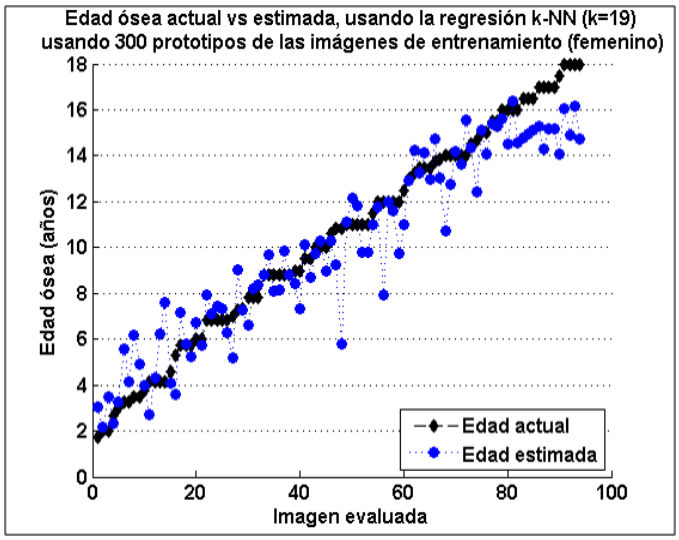

(a) Grupo femenino

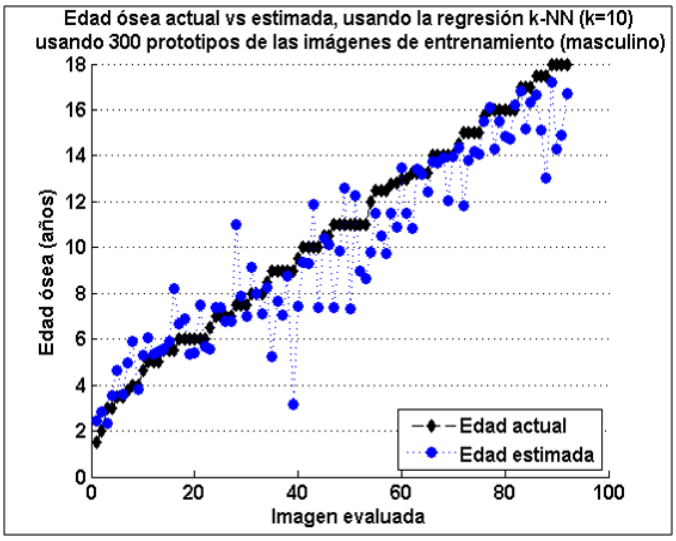

(b) Grupo masculino

Figura 4.11: Error MAE calculado en función del parámetro k del algoritmo *k-NN* comparando la estimación con la colocación manual y la detección automática de *landmarks*.

La tabla 4.3 muestra los errores reportados para diferentes métodos revisados en la literatura con la misma base de datos. En el método propuesto se obtiene un MAE de 1.18 años, al promediar el error obtenido del grupo femenino y del masculino.

Tabla 4.3: Comparación del método propuesto con algunos otros métodos revisados en la literatura.

Método	**Banco de imágenes**	**MAE**
Propuesta	Digital Hand Atlas Database System [6]	*1.18 años
Harmsen et al [21]	Digital Hand Atlas Database System(1097 imágenes) [6]	0.83 años
Fischer et al [22]	Digital Hand Atlas Database System(1097 imágenes) [6]	0.97 años
Spampinato et al [17]	Digital Hand Atlas Database System [6]	0.80 años
Giordano et al [16]	Conjunto de imágenes privadas (360 imágenes)	0.41 años

4.2.1. Discusión de resultados

La detección automática funcionó una distancia media alrededor de dos pixeles en comparación con la colocación manual de *landmarks*. Pero en algunos casos no se obtuvo el resultado deseado, es decir la colocación de landmarks es muy mala (diferencia mucho mayor a dos pixeles) por lo que se tomó la decisión de considerar estas imágenes como detección de landmarks no aceptable con el fin de obtener un mejor análisis de los resultados, obteniendo 94 de 100 imágenes aceptables para el grupo femenino y para el masculino 92 de 100.

Se evaluaron las imágenes con detección de *landmarks* aceptable para estimar la edad ósea y poder compararla con la estimación obtenida con la colocación manual de *landmarks* y también con la edad reportada en la base de datos. Los resultados presentados en la figura (4.10) muestran que el error MAE obtenido con el algoritmo automático es mayor como se esperaba, sin embargo la diferencia que existe es pequeña, usando el parámetro k óptimo en el algoritmo de *k-NN* para cada caso se tiene una diferencia de 0.125 y 0.343 años para el grupo femenino y masculino correspondientemente, este resultado también se esperaba debido a que la diferencia entre las *landmarks* es pequeña.

La figura (4.11) muestra la comparación de las edades ósea estimadas por el algoritmo automático y las edades reportadas en la base de datos en dónde se muestra una separación mayor cerca de los límites que es alrededor de 0 y 18 años, esto también se presentó con la colocación manual de *landmarks*, se considera que se debe a la interpolación del algoritmo *k-NN* usado para regresión.

4.3. Resultados del algoritmo de aprendizaje automático incremental

De acuerdo con el sistema general para estimar automáticamente la edad ósea descrito en el capítulo 2 el siguiente paso después de desarrollar el algoritmo para detectar automáticamente las *landmarks* es desarrollar el algoritmo de aprendizaje automático para estimar la edad ósea el cual se encuentra descrito en el capítulo 3. Entonces ahora lo que sigue es validar el funcionamiento adecuado de este algoritmo, para este fin se propuso utilizar cuatro diferentes bases de datos, obtener los resultados de estimación con el algoritmo propuesto y compararlos con el algoritmo *k-NN* para regresión que es el algoritmo que se había utilizado anteriormente.

4.3.1. Bases de datos para validación del algoritmo

Se utilizaron cuatro bases de datos para probar el algoritmo, las cuales se describen a continuación:

1. Para la primera base de datos se generaron puntos sintéticos aleatorios con dos coordenadas en un rango de -100 a 100 como se muestra en la figura 4.12, en dónde la etiqueta de cada punto se obtiene al calcular distancia que existe desde el centro del plano (0,0) hasta la ubicación del punto y posteriormente este valor se escala para tener etiquetas que van desde 0 hasta 18, esto genera una distribución en forma de círculos como se muestra en la figura 4.13, en dónde cada color representa un rango de valor de 2, es decir los puntos negros del centro van desde 0 hasta 2, los puntos azules que siguen van desde 2 hasta 4 y así sucesivamente hasta llegar a 18.

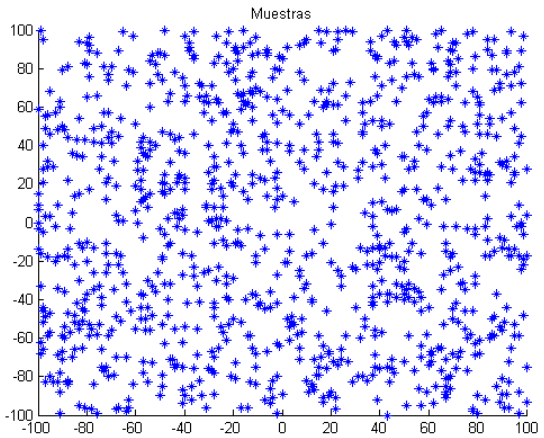

Figura 4.12: Puntos sintéticos con dos coordenadas para simular muestras.

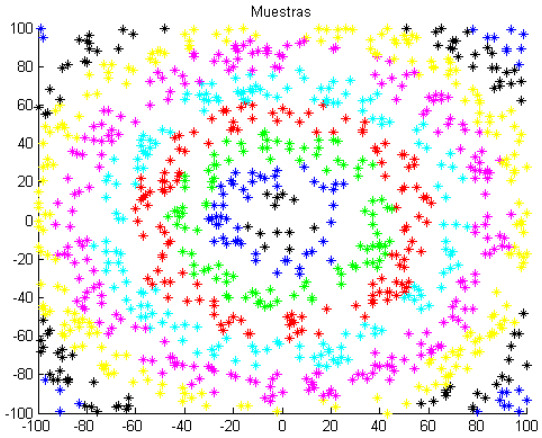

Figura 4.13: Puntos sintéticos en donde su etiqueta se obtiene calculando la distancia que existe entre el origen (0,0) y la ubicación del prototipo.

2. Para la segunda base de datos se utilizan los mismos puntos sintéticos presentados en la primera base de datos, pero con la diferencia de que en este caso la etiqueta se obtiene sumando los valores de las coordenadas de cada prototipo y posteriormente se escala a un rango de 0 a 18, con esto se obtienen distribuciones de puntos diagonales como se muestra en la figura 4.14, en este caso los colores también representan rangos de valores de 2.

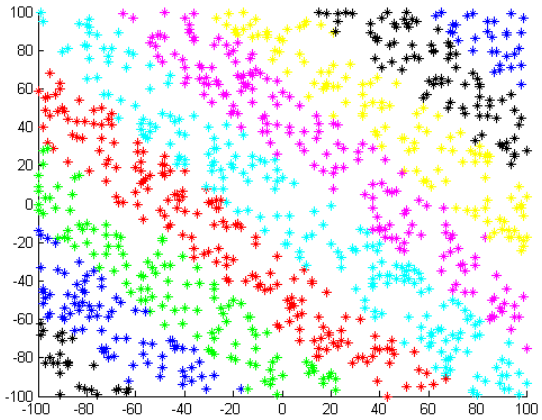

Figura 4.14: Puntos sintéticos en donde su etiqueta se obtiene sumando los valores de las coordenadas de cada punto.

3. Para la tercera base de datos también se utilizaron puntos sintéticos aleatorios en un rango de -1 a 1, en dónde la etiqueta es el resultado de evaluar una función descrita por la siguiente expresión: $f(x_1, x_2) = max\left\{e^{-10x_1^2}, e^{-50x_2^2}, 1{,}25e^{-5(x_1^2+x_2^2)}\right\}$. Generando así un conjunto de puntos que se muestra en la figura 4.15.

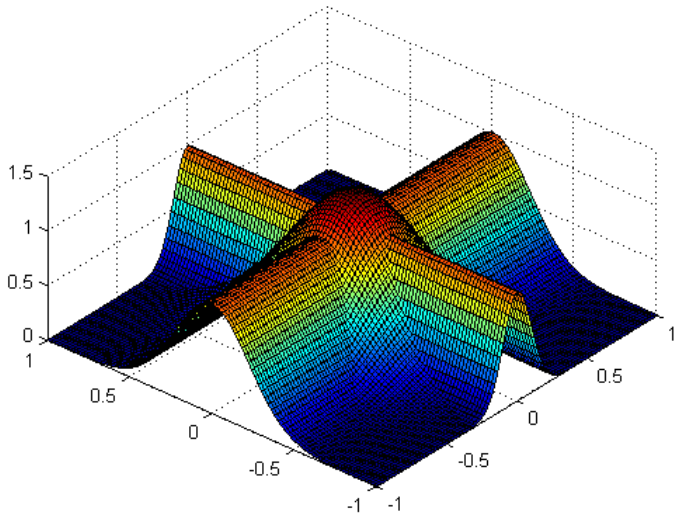

Figura 4.15: Puntos sintéticos en donde su etiqueta se obtiene usando una función para generar una superficie simétrica.

4. La cuarta y última base de datos contiene muestras usadas para estimar la edad ósea de una persona, estas muestras se obtuvieron a partir de un algoritmo que se está desarrollando en un trabajo de tesis para extraer regiones de interés en imágenes radiográficas de la mano de las personas. Cada muestra contiene un conjunto de características que se encuentran asociadas con una edad ósea, en este caso la edad es la etiqueta. Se cuenta con 1600 muestras que se encuentran separadas por género masculino (850 muestras) y femenino (750 muestras). Las imágenes radiográficas utilizadas para obtener las muestras provienen de las beses de datos [12] y [20].

4.3.2. Resultados

Los resultados que se muestran en cada base de datos corresponden a la comparación del error MAE obtenido con el algoritmo *k-NN* para regresión y el algoritmo de aprendizaje incremental propuesto. Primero se utilizo el algoritmo propuesto y se calculó el MAE, además se revisó cuantos prototipos fueron generados. Después se utilizó el algoritmo *k-NN* usando todas las muestras de entrenamiento como prototipos y se calculó el error. Finalmente se volvió a utilizar el algoritmo *k-NN* pero eligiendo aleatoriamente la misma cantidad de prototipos usados con el algoritmo propuesto.

Debido a que en las primeras dos bases de datos se utilizan puntos sintéticos de dos dimensiones como muestras, además de las gráficas del error MAE obtenido es posible visualizar los prototipos obtenidos con ambos algoritmos. En el caso de la tercera base de datos se tratan de muestras con tres dimensiones también es posible observarlos gráficamente pero no se hace debido a que su visualización no es muy clara. Finalmente para la base de datos relacionada con la edad ósea no es posible obtener una gráfica de los prototipos porque cada uno tiene más de tres dimensiones.

Para la primera base de datos, se usaron 1000 muestras de entrenamiento y 100 muestras de evaluación diferentes a las muestras de entrenamiento. En la figura 4.17 se muestra una comparación de los resultados obtenidos usando el algoritmo *k-NN* con todas las muestras de entrenamiento como prototipo en donde se obtuvo un MAE de 0.23991, con la propuesta se generaron 187 prototipos y se obtuvo un MAE de 0.2144 y usando 187 prototipos con el algoritmo *k-NN* se obtuvo un MAE de 0.73321. En la figura 4.16 se muestra un ejemplo de los prototipos obtenidos.

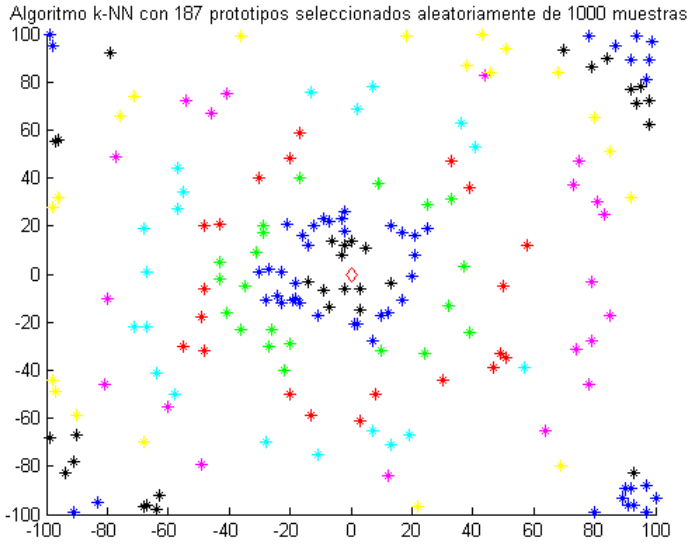

(a) 187 prototipos seleccionar aleatoriamente para el algoritmo *k-NN*

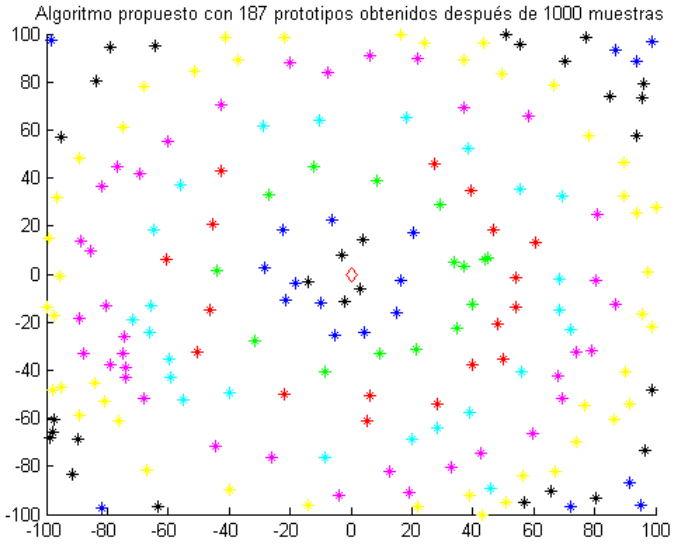

(b) 187 prototipos resultantes de la propuesta

Figura 4.16: Prototipos utilizados para evaluar las muestras en la primera base de datos.

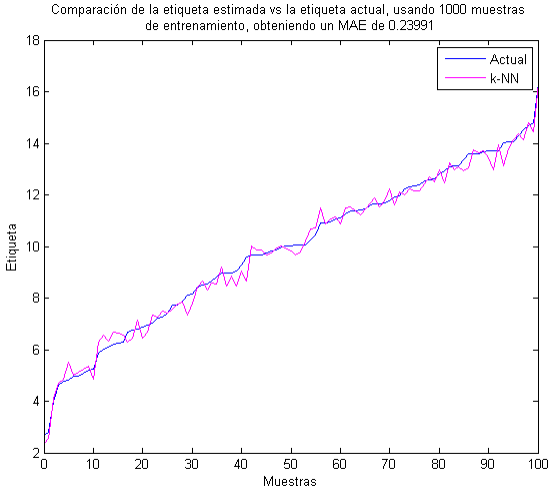

(a) *k-NN* usando 1000 muestras como prototipos

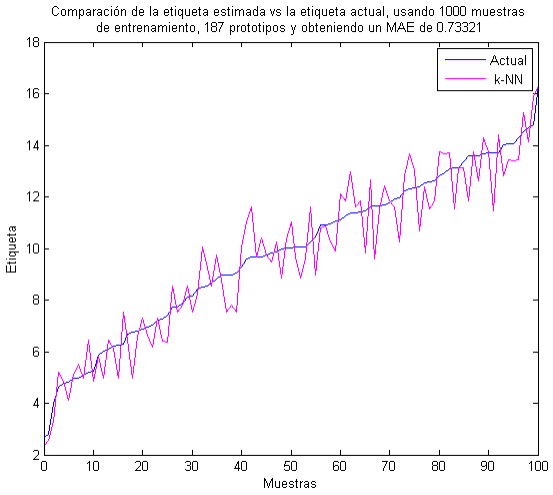

(b) *k-NN* usando 187 muestras como prototipos

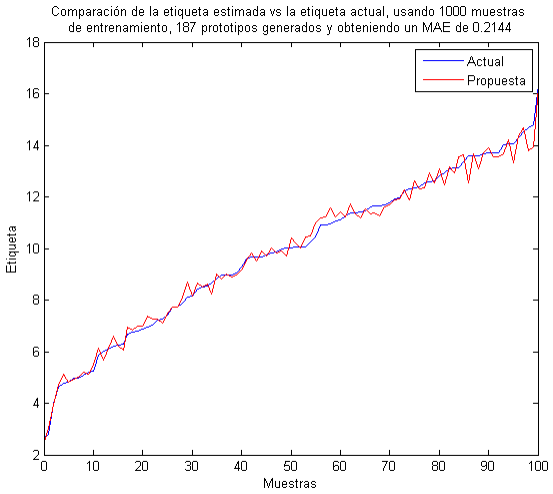

(c) Propuesta con 187 prototipos

Figura 4.17: Comparación de las etiquetas en la base de datos y las etiquetas estimadas por los algoritmos en la primera base de datos.

Para la segunda base de datos, se usaron 1000 muestras de entrenamiento y 100 muestras de evaluación diferentes a las muestras de entrenamiento. En la figura 4.19 se muestra una comparación de los resultados obtenidos usando el algoritmo *k-NN* con todas las muestras de entrenamiento como prototipo en donde se obtuvo un MAE de 0.11102, con la propuesta se generaron 68 prototipos y se obtuvo un MAE de 0.15546 y usando 68 prototipo con el algoritmo *k-NN* se obtuvo un MAE de 0.61391. En la figura 4.18 se muestra un ejemplo de los prototipos obtenidos.

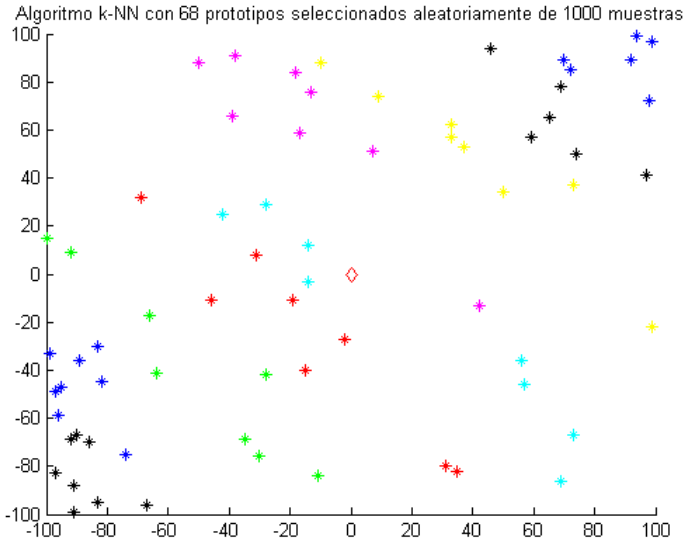

(a) 68 prototipos seleccionar aleatoriamente para el algoritmo *k-NN*

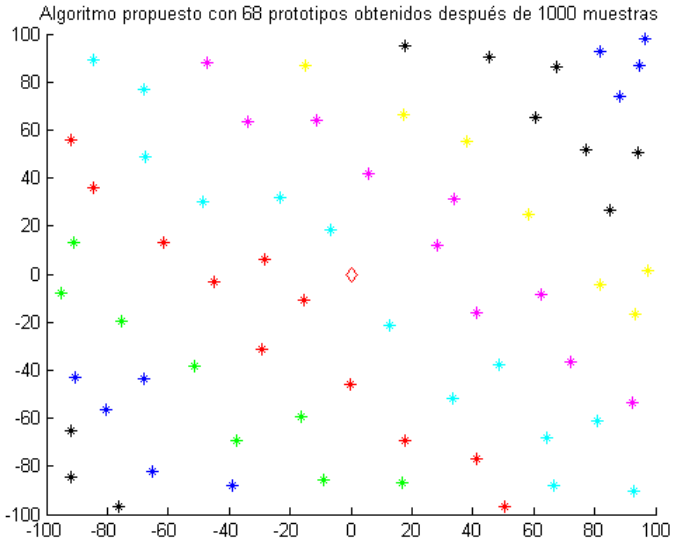

(b) 68 prototipos resultantes de la propuesta

Figura 4.18: Prototipos utilizados para evaluar las muestras en la segunda base de datos.

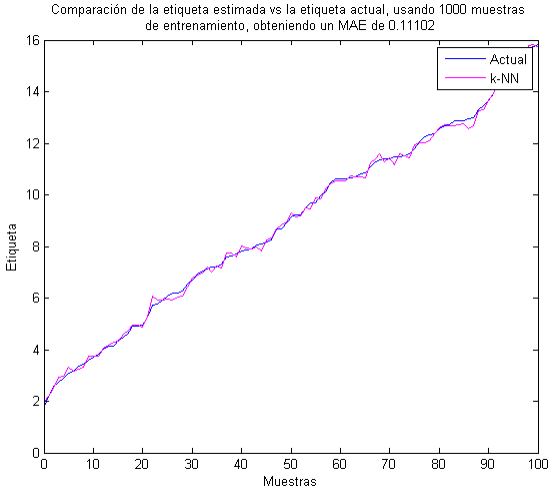

(a) *k-NN* usando 1000 muestras como prototipos

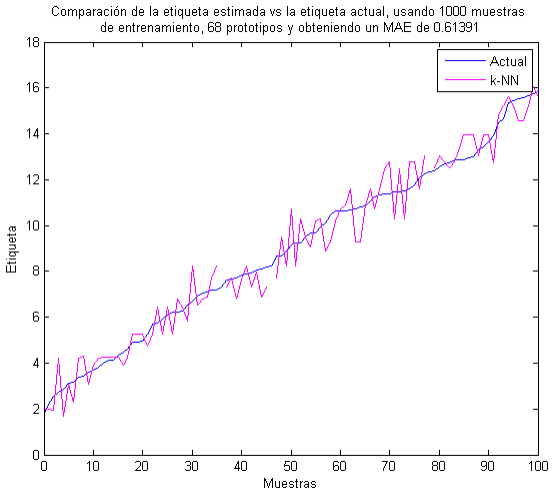

(b) *k-NN* usando 68 muestras como prototipos

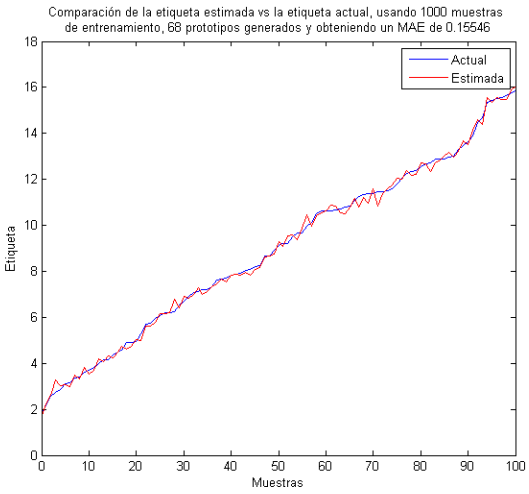

(c) Propuesta con 68 prototipos

Figura 4.19: Comparación de las etiquetas en la base de datos y las etiquetas estimadas por los algoritmos en la segunda base de datos.

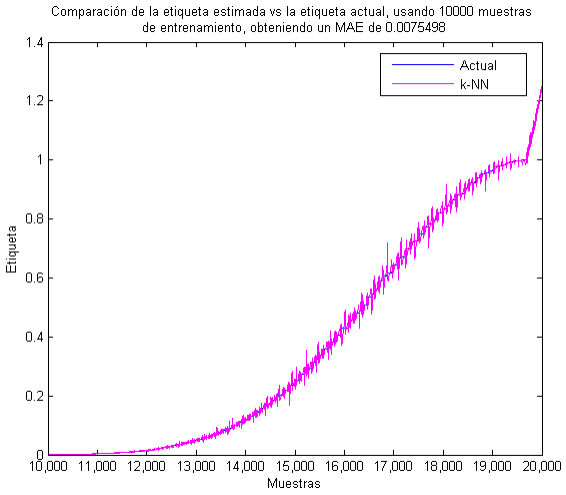

(a) *k-NN* usando 10000 muestras como prototipos

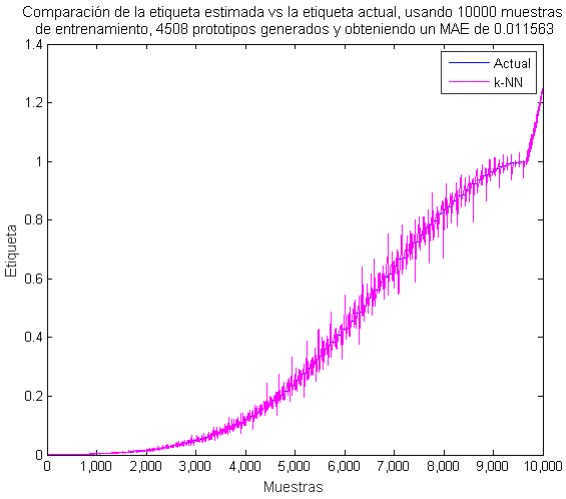

(b) *k-NN* usando 4508 muestras como prototipos

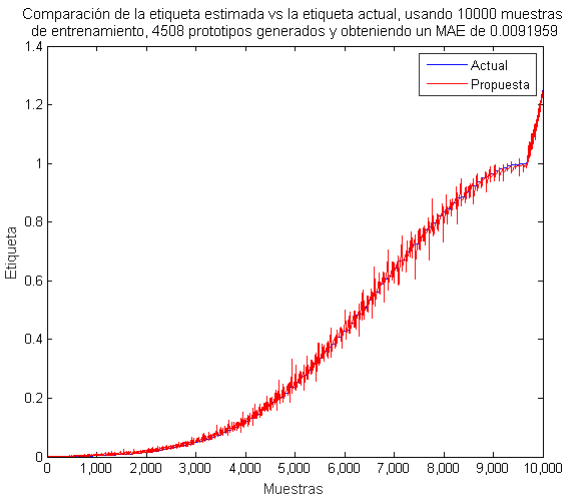

(c) Propuesta con 4508 prototipos

Figura 4.20: Comparación de las etiquetas en la base de datos y las etiquetas estimadas por los algoritmos en la tercera base de datos.

Para la tercera base de datos, se usaron 10000 muestras de entrenamiento y 10000 muestras de evaluación diferentes a las muestras de entrenamiento. En la figura 4.20 se muestra una comparación de los resultados obtenidos usando el algoritmo *k-NN* con todas las muestras de entrenamiento como prototipo en donde se obtuvo un MAE de 0.0075498, con la propuesta se generaron 4508 prototipos y se obtuvo un MAE de 0.0115630 y usando 4508 prototipo con el algoritmo *k-NN* se obtuvo un MAE de 0.0091959.

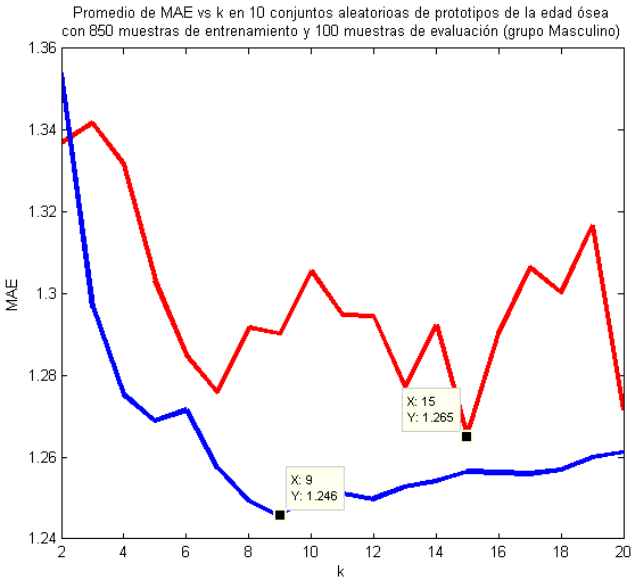

(a) Comparación de MAE obtenido con ambos algoritmos

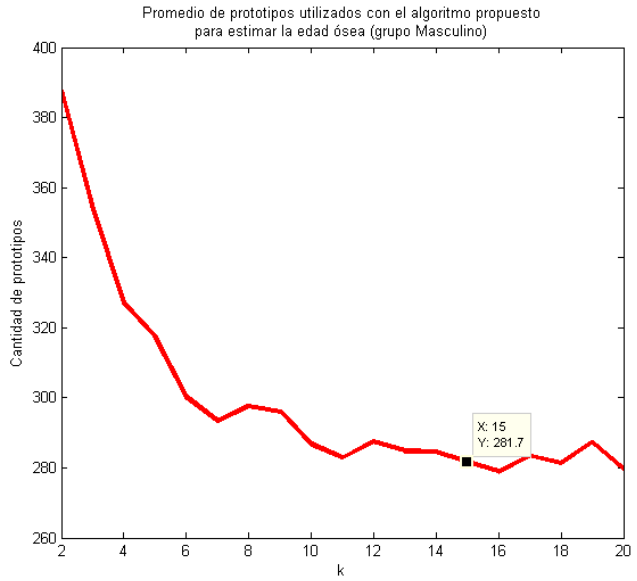

(b) Cantidad de prototipos generados vs k

Figura 4.21: Evaluación de MAE vs k en las muestras de estimación de edad ósea en el grupo masculino.

Para la última base de datos, se usaron 750 muestras de entrenamiento para el grupo masculino y 650 muestras para el femenino, en ambos casos se usaron 100 muestras de evaluación diferentes a las muestras de entrenamiento. En la figura 4.21 se muestra una comparación en el grupo masculino de los resultados obtenidos usando el algoritmo *k-NN* con todas las muestras de entrenamiento como prototipos en donde se obtuvo un MAE de 1.246, con la propuesta se generaron 280 prototipos y se obtuvo un MAE de 1.265. En la figura 4.22 se muestra el grupo femenino en donde usando *k-NN* con todas las muestras de entrenamiento como prototipos se obtuvo un MAE de 1.201, con la propuesta se generaron 240 prototipos y se obtuvo un MAE de 1.225.

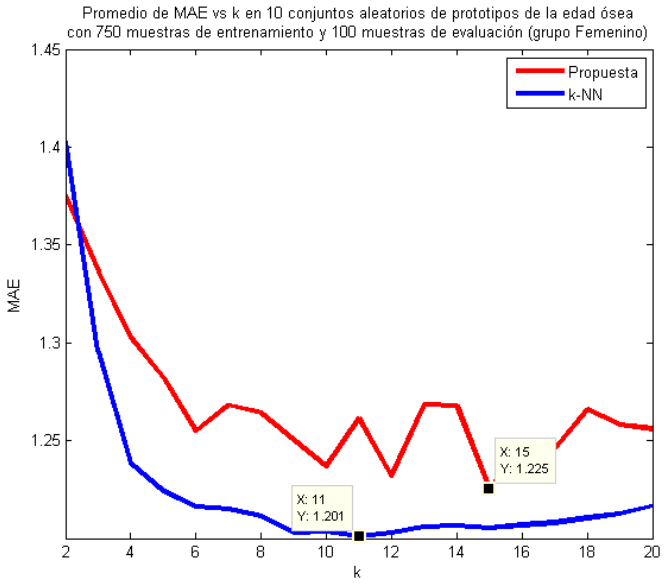

(a) Comparación de MAE obtenido con ambos algoritmos

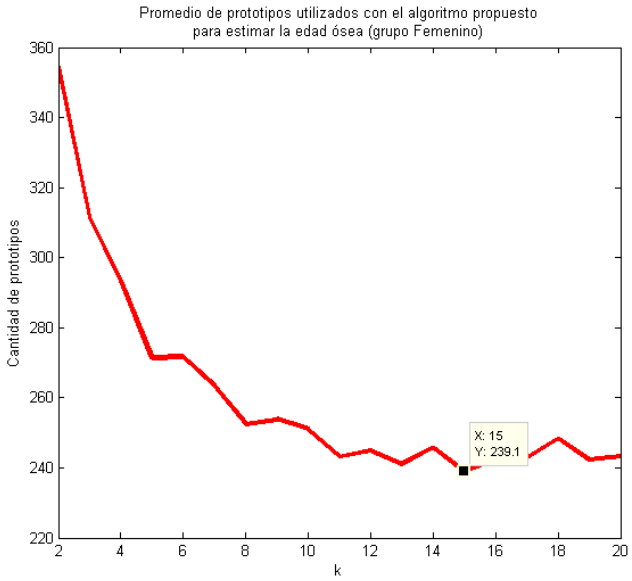

(b) Cantidad de prototipos generados vs k

Figura 4.22: Evaluación de MAE vs k en las muestras de estimación de edad ósea en el grupo femenino.

Se muestra una comparación de las edad óseas estimadas con las actuales, considerando dos casos: el primero supone que todas las *landmarks* fueron colocadas en la posición correcta, el segundo se realiza con el algoritmo de detección automática de *landmarks*.

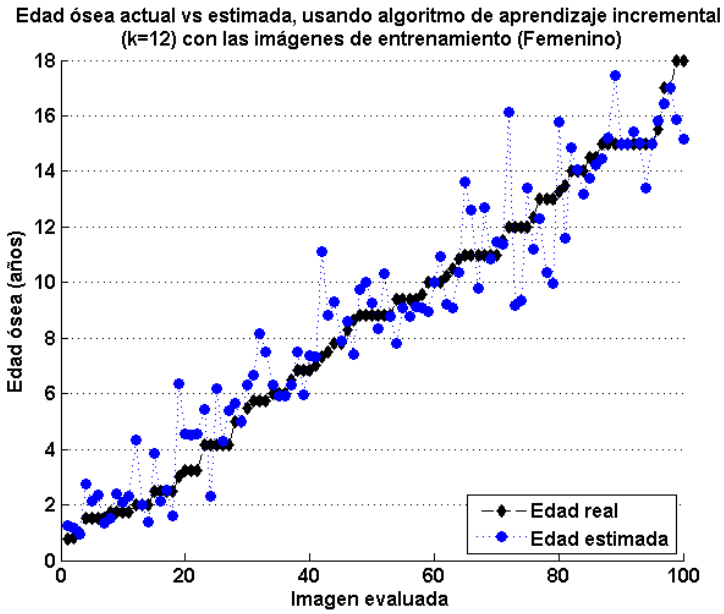

(a) Comparación de edad ósea en el grupo femenino

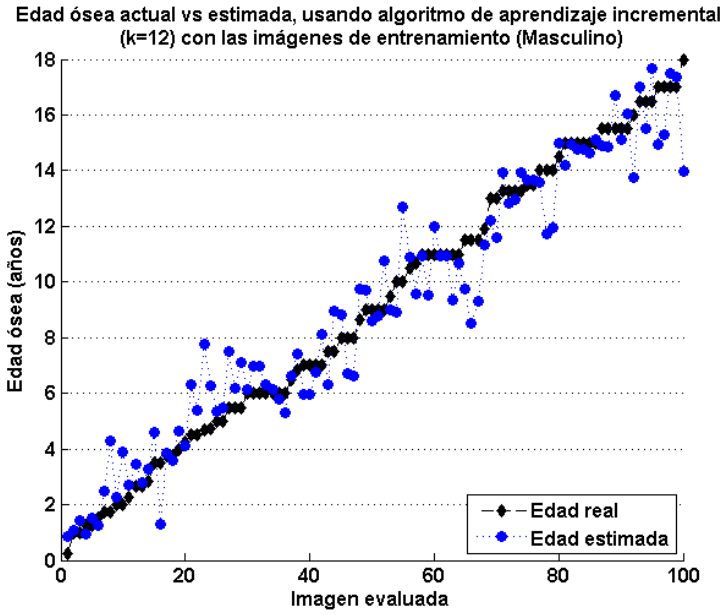

(b) Comparación de edad ósea en el grupo masculino

Figura 4.23: Comparación de la edad ósea actual vs la edad estimada usando las *landmarks* en su posición adecuada.

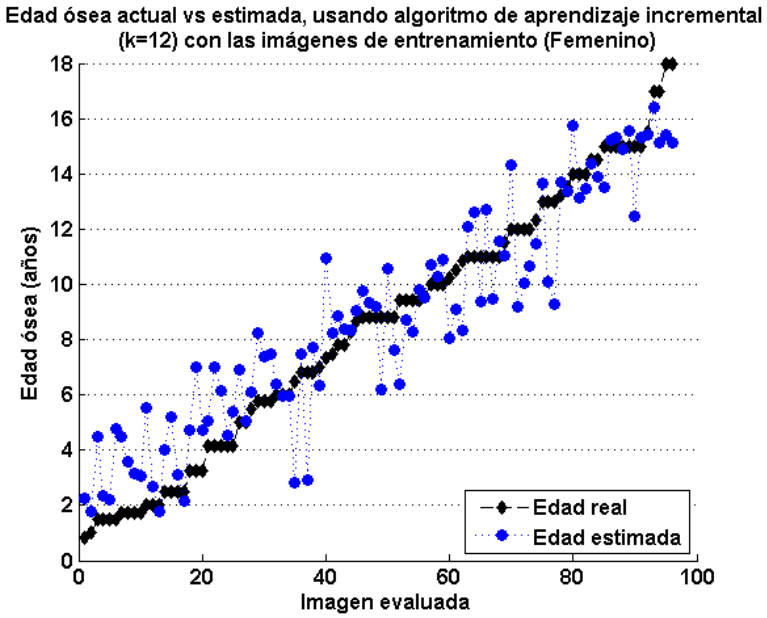

(a) Comparación de edad ósea en el grupo femenino

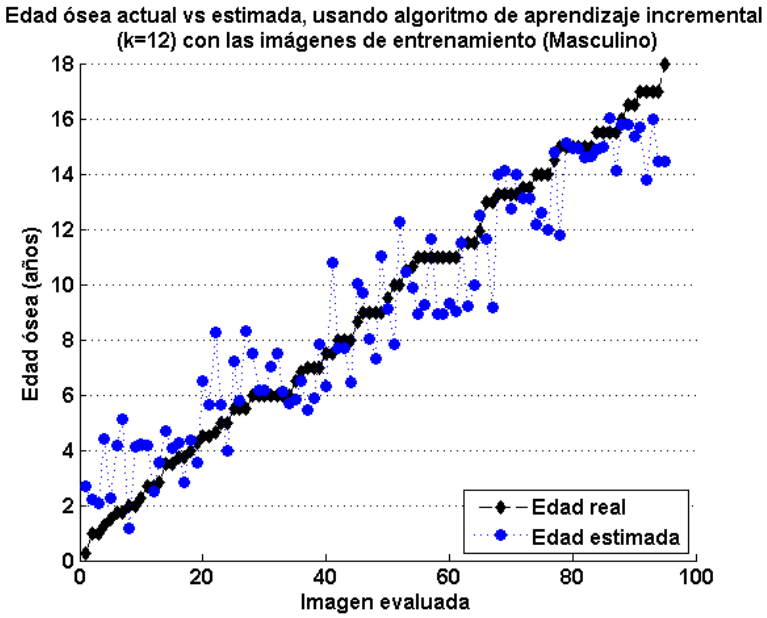

(b) Comparación de edad ósea en el grupo masculino

Figura 4.24: Comparación de la edad ósea actual vs la edad estimada usando las *landmarks* detectadas automáticamente.

Se utilizan algunas muestras para entrenamiento y otras diferentes para evaluación, para comprobar que el error obtenido no depende del conjunto de muestras usado en la evaluación, se intercambian las muestras de las etapas de entrenamiento y evaluación, entonces, en cada grupo (femenino y masculino) se tomaron 100 muestras aleatorias para la etapa de evaluación y el resto para el entrenamiento y se calculó el MAE, este proceso se repitió 10 veces usando el algoritmo *k-NN* para regresión con todas las muestras como prototipos, también se evaluaron

las muestras con el algoritmo propuesto y además se evaluaron usando el algoritmo *k-NN* para regresión pero usando la misma cantidad de prototipos que se obtuvo con la propuesta, en la tabla 4.4 se muestra el error MAE promedio y la desviación estándar.

Las figuras 4.23 y 4.24 muestran los resultados de evaluar el sistema usando una base de datos balanceada. Se usaron 641 y 645 imágenes para el grupo femenino y masculino respectivamente. En donde se utilizaron 35 imágenes por cada rango de edad de un año, es decir, 35 imágenes que tienen edad de 1 a 2, 35 con edad de 2 a 3 y así sucesivamente hasta llegar a 18 años, con la excepción en ambos casos con el rango de edad de 0 a 1, ahí se utilizaron menos debido a que las bases de datos [6, 20] no tenían suficientes imágenes en ese rango de edad.

Tabla 4.4: Comparación del error medio absoluto y la desviación estándar obtenidos usando el algoritmo *k-NN* para regresión y el algoritmo propuesto con diferentes conjuntos de entrenamiento y evaluación en las muestras para estimar la edad ósea.

Algoritmo(grupo)	**Muestras**	**Prototipos**	**MAE**	σ
k-NN (Femenino)	750	750	1.20	0.0445
k-NN (Femenino)	750	240	1.30	0.0526
Propuesta (Femenino)	240	750	1.23	0.0695
k-NN (Masculino)	850	850	1.25	0.1091
k-NN (Masculino)	850	280	1.32	0.1231
Propuesta (Masculino)	850	280	1.27	0.1074

4.3.3. Discusión de resultados

En la primera base de datos la diferencia usando ambos algoritmos (*k-NN* para regresión y la propuesta) la diferencia del error MAE fue de 0.02, obteniendo un mejor resultado con el algoritmo propuesto, una diferencia pequeña considerando que las etiquetas van desde 0 hasta 18, además la cantidad de prototipos utilizadas para obtener la estimación fue el 10 % de la cantidad utilizada para el algoritmo *k-NN*, es decir, el resultado fue favorable. Con la segunda base de datos se obtuvo una diferencia en los errores de 0.05, se obtuvo un menor error con el algoritmo *k-NN*, pero sólo se utilizó un 7 % de la cantidad de prototipos usando inicialmente. En la tercera base de datos se obtuvo una diferencia en los errores de 0.002, en este caso el rango de etiquetas fue de 0 a 1 y el error menor fue del algoritmo *k-NN*, pero sólo se usó el 45 % de prototipos con el algoritmo propuesto. Con la última base de datos los errores se reportan en la tabla 4.4, la diferencia fue de 0.01, en donde una vez más se obtuvo un menor error con el algoritmo *k-NN*, pero sólo se usó el 33 % de cantidad de prototipos utilizados en el algoritmo de *k-NN*. En general, con el algoritmo propuesto se reduce en gran parte la cantidad de prototipos necesarios para hacer una evaluación a cambio de obtener un error MAE ligeramente mayor. Si se utiliza una base de datos balanceada como lo muestran las figuras 4.23 y 4.24 se obtiene un MAE de 0.99 y 0.90 años para el grupo femenino y masculino respectivamente usando landmarks colocadas manualmente y se obtiene un MAE de 1.35 y 1.25 años para el grupo femenino y masculino respectivamente usando landmarks colocadas automáticamente.

4.4. Interfaz de usuario desarrollada

Al ser una interfaz de usuario está debe ser intuitiva, simple de usar, debe permitir visualizar cuáles son las regiones que se utilizaron para estimar la edad ósea y permitir recortar la imagen radiográfica si lo cree conveniente el usuario.

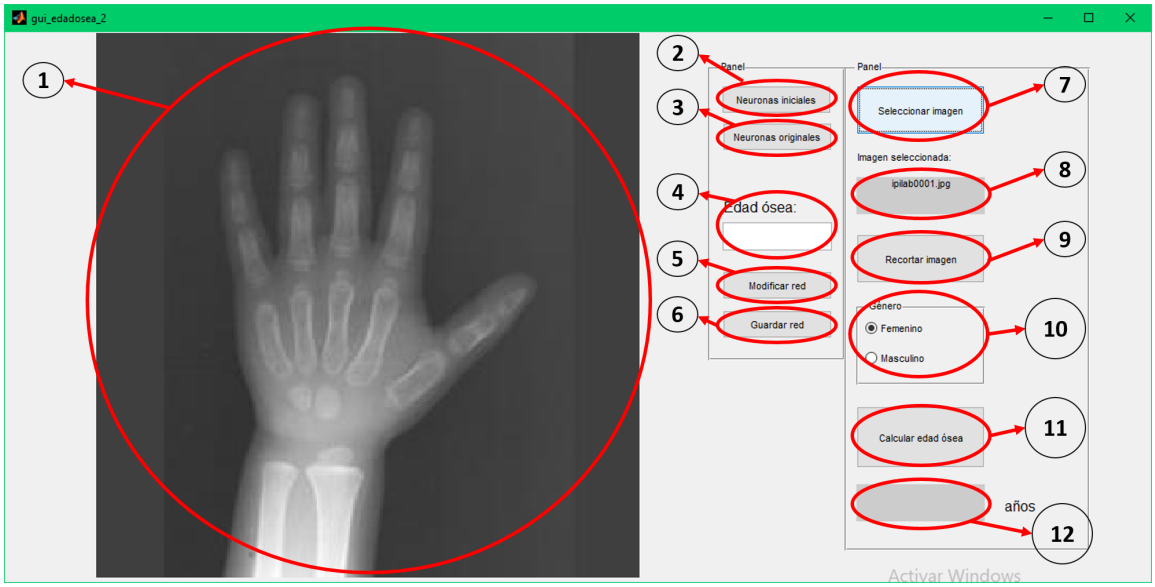

Figura 4.25: Interfaz de usuario desarrollada en MATLAB para estimar la edad ósea.

La figura 4.25 muestra las secciones con las cuenta la interfaz.
Descripción de cada sección de la interfaz

1. Imagen radiográfica, además también aquí se muestra la imagen con las regiones utilizadas para estimar la edad ósea como se muestra en la figura 4.26.

   Las partes de 2 a 6 se relacionan con el algoritmo de aprendizaje incremental por lo que podrían considerarse como partes opcionales. Se utiliza un algoritmo de aprendizaje incremental que usa una red de prototipos los cuales serán llamados neuronas.

2. Permite reiniciar las neuronas a como se encontraban justo antes de cambiar de imagen radiográfica, es decir, son las neuronas que ya fueron modificadas pero no por la imagen actual.

3. Permite reiniciar las neuronas a como se encontraban originalmente, es decir, sin ninguna modificación por parte del usuario.

4. Está sección sirve para que el usuario introduzca la edad ósea en años de la radiografía actual para mejorar la estimación del sistema.

5. Este botón sirve para implementar el algoritmo de aprendizaje incremental después de introducir la edad ósea, como resultado se obtienen las neuronas modificadas, además se muestran las regiones utilizadas para estimar la edad ósea y la edad ósea calculada por el sistema ya con la modificación.

6. Este botón sirve para guardar en el sistema las neuronas que acaban de ser modificadas.

   Las partes de 7 a 12 se relacionan con seleccionar una imagen, recortar la imagen y estimar la edad ósea de está misma.

7. Sirve para seleccionar una imagen que se encuentre almacenada en la computadora.

8. Muestra el nombre de la imagen seleccionada.

9. Sirve para recortar la imagen, se muestra un rectángulo que puede ser modificado, este indica cual es la región que va a ser utilizada, después se tiene que hacer doble clic para confirmar la región y obtener la imagen recortada. Esta función es opcional.

10. En esta parte se debe seleccionar el género correspondiente a la imagen radiográfica.

11. Este botón sirve para implementar la estimación de la edad ósea, al finalizar en la sección 1 se muestran las regiones utilizadas para la estimación de la edad.

12. Se muestra la edad ósea estimada por el sistema.

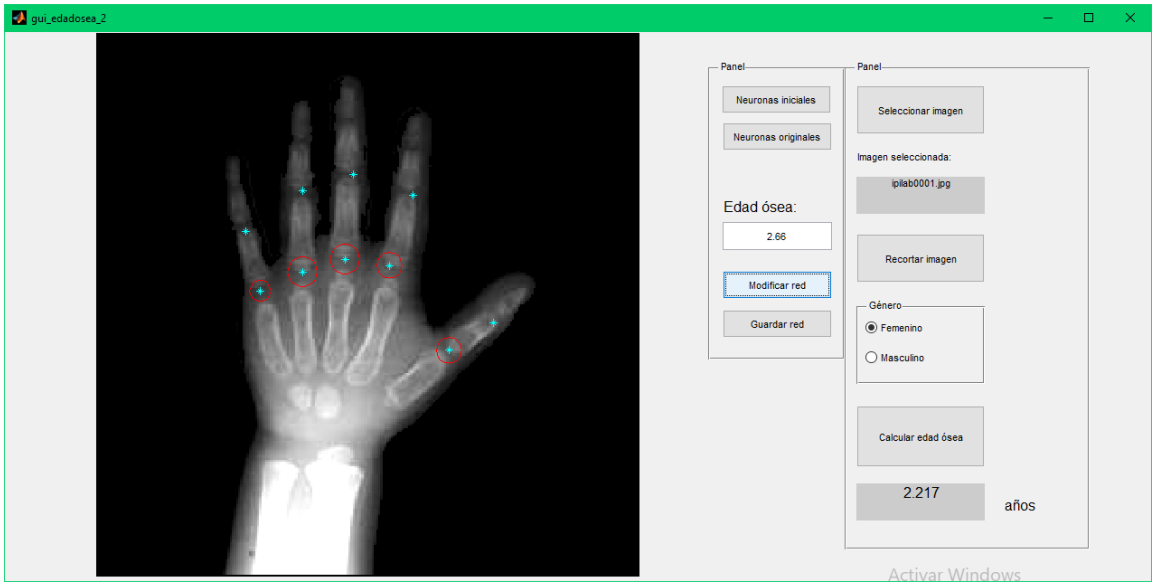

Figura 4.26: Interfaz de usuario desarrollada en MATLAB para estimar la edad ósea.

Capítulo 5

Conclusiones y trabajo futuro

5.1. Conclusiones

Se propuso un sistema automático para estimación de la edad ósea a partir de una imagen radiográfica de la mano de una persona. El sistema cuenta con una serie de etapas que cumplen una función especifica para realizar la tarea. Cada etapa se realizó usando algoritmos propuestos que se basan en procesamiento de imágenes y visión por computadora, este último utiliza algoritmos de aprendizaje automático. El diagrama general del sistema se muestra en la figura 2.1.

La primera parte consiste en el pre-procesamiento de cualquier imagen que entra al sistema en donde el principal reto fue la segmentación de la mano ya que algunas imágenes presentan un brillo con degradado lo que representa mayor complicación para utilizar algún método de segmentación conocido por lo que se propuso un algoritmo que segmentara la mano pero el cual está limitado a las imágenes radiográficas con las cuales se trabajo.

El siguiente paso consiste en la detección automática de *landmarks* de acuerdo con una disposición de puntos propuestos, en este caso se presentaron dos retos principales el primero es la colocación adecuada de *landmarks* en una imagen radiográfica de la mano debido a que existen diferentes configuraciones el segundo reto es tiene que ver con el procesamiento de los datos ya que este paso del algoritmo es el que consume más tiempo debido a la cantidad de operaciones que se realizan y también a la estructura actual del mismo algoritmo.

A partir de las landmarks se extrae un vector de características de la imagen que posteriormente es utilizado para hacer la estimación de la edad ósea, en este caso el reto que quedó pendiente de resolver fue la estimación de valores en los límites de las etiquetas, esto paso porque el algoritmo utiliza una interpolación y se piensa que al utilizar una técnica de extrapolación o algo similar podría llegar a resolverse este problema. Como parte adicional se puede utilizar ese vector de características para mejorar el algoritmo de estimación, en este caso se desarrollo un algoritmo de aprendizaje incremental el cual contiene varios parámetros que pueden ser modificados, es decir, se tiene un área de oportunidad interesante para implementar o mejor el algoritmo con diferentes aplicaciones.

Se propuso una disposición de puntos (*layout*) en la imagen radiográfica para lo cual se propuso y se validó un sistema semi-automático para estimación de la edad ósea. Además de la validación del *layout*, se considera que las contribuciones obtenidas en esta parte son:

- El desarrolló de un método semi-automático para estimar la edad ósea que forma vectores de características útiles para una clasificación exitosa, el cual puede utilizarse como base para proponer un método automático.
- Un algoritmo para segmentar manos en una imagen radiográfica.
- Un algoritmo original para alinear las regiones de interés de las imágenes radiográficas de la mano de una persona.

Una vez que se tenía el *layout*, la siguiente parte fue diseñar y validar un algoritmo para la detección automática de *landmarks* con esa disposición de puntos.

La detección automática funcionó en la mayoría de las imágenes, pero en algunos casos no se obtuvo el resultado deseado, al observar la imágenes en dónde fallo el algoritmo se detecto que la mayoría pertenecía a edades óseas cercanas a cero años, esto podría deberse a que en el grupo de entrenamiento (y en el conjunto de imágenes de la base de datos) existen pocos ejemplos con edad cercana a cero años en comparación con las demás edades por lo tanto el sistema no tiene los ejemplos suficientes para aprender las características adecuadas para colocar las *landmarks* en la posición adecuada en este tipo de imágenes.

Parte del desarrollo de este algoritmo consiste en alinear regiones de imágenes similar y debido a esto es posible usar el análisis de componentes principales para desarrollar el algoritmo de detección automática de *landmarks*.

Las aportaciones obtenidas con el desarrollo de este algoritmo para obtener un sistema automático para estimar la edad ósea son:

- Un algoritmo para orientar automáticamente regiones de imágenes similares en función de lo que es llamado su ángulo dominante.
- Un algoritmo para ubicar automáticamente *landmarks* de acuerdo a un *layout* propuesto en imágenes radiográficas.

La siguiente parte consistió en diseñar y validar un algoritmo de aprendizaje automático supervisado incremental, para hacer la estimación de la edad ósea y también como parte opcional permite mejorar la estimación usando ejemplos nuevos sin la necesidad de volver a entrenar el algoritmo con todos los ejemplos previos.

La aportación obtenida de esta etapa es:

- Un algoritmo de aprendizaje automático supervisado e incremental que permite aumentar su información con muestras nuevas sin la necesidad de volver a repetir la etapa de entrenamiento con todas las muestras anteriores.

El cual se probó con diferentes bases de datos, las cuales presentaban etiquetas con diferente distribución, en el caso de los puntos sintéticos es más sencillo obtener los datos porque se puede generar la cantidad que se necesite de estos mismos, para el caso de las muestras relacionadas con la edad ósea resulta más complicado obtener las muestras porque se requiere un proceso que involucra varios factores, a pesar de esto se logró obtener una estimación de las etiquetas con resultados adecuados usando una cantidad reducida de prototipos comparada con el algoritmo *k-NN* que inicialmente se había utilizado.

5.2. Trabajo futuro

Como trabajo futuro se pretende hacer más robusto el algoritmo de detección de *landmarks* debido a que falló en algunas radiografías, además en algunas imágenes la posición de un punto estaba incorrecto por lo que se pretende implementar un método que ayude a corregir esas situaciones utilizando la posición de las *landmarks* en los ejemplos de entrenamiento haciendo que mejore la detección automática de forma incremental.

Además, el algoritmo propuesto de aprendizaje automático incremental presenta diferentes reglas de funcionamiento por lo que se pretende probar con diferentes configuraciones y analizar el comportamiento para identificar posibles aplicaciones, también se pretende probar el algoritmo con bases de datos diferentes que no sean sintéticas con el objetivo de observar si su funcionamiento para diferentes casos.

Finalmente se tiene planeado implementar o desarrollar un método de extrapolación para la estimación de la edad ósea, esto debido a que el algoritmo no funciona adecuadamente cuando se trata de estimar una etiqueta que se encuentre en los límites en este caso es 0 y 18 años.

Bibliografía

[1] Adeshina, S.A., Cootes, T.F., Adams, J.E., *Evaluating different structures for predicting skeletal maturity using statistical appearance models*, In: In Proc. MIUA. (2009).

[2] Greulich, Pyle, S., *Radiographic atlas of skeletal development of hand wrist*, Standford University Press 2nd ed. (1971).

[3] W. W. Greulich and S. I. Pyle. *Radiographic Atlas of Skeletal Development of Hand Wrist*, Palo Alto, CA: Stanford Univ. Press, 1971.

[4] Tanner, J., Whitehouse, R., Cameron, N., Marshall, W., Healy, M., Goldstein, H., *Skeletal maturity and prediction of adult height (tw2 method)*, Academic Press, London 2nd ed. (1975).

[5] V. Gilsaz, O. Ratib. *"Indicators of Skeletal Maturiy in Children and Adolescents" in Hand Bone Age A Digital Atlas of Skeletal Maturity*, Germany: Springer, 2005, pp. 9-17.

[6] Image Processing and Informatics Lab. *"Digital Hand Atlas"*, [Online] Available: http://www.ipilab.org/BAAweb

[7] E. Faini. *"Indicadores de maduración esqueletal. Edad ósea, dental y morfológica"*, Rev Cubana Ortod 1988, 13(2), pp. 121-125.

[8] E. Pietka, A. Gertych, S. Pospiech, F. Cao, H. K. Huang, and V. Gilsanz. *Computer-assited bone age assessment: image preprocessing and epiphyseal/metaphyseal roi extraction* IEEE Transactions on Medical Imaging, 20(8):715-729, 2001.

[9] D. R. Kirks. *Practical Pediatric Imaging: Diagnostic Radiology of Infants and Children.* Brown and Co, Boston, MA: 1984.

[10] T. Todd. *Atlas of skeletal maturation (Hand).* C.V. Mosby Co., 1937.

[11] P. Kaplowitz, S. Srinivasan, J. He, R. McCarter, M. R. Hayeri, R. Sze. *Comparison of bone age readings by pediatric endocrinologists and pediatric radiologists using two bone age atlases* Springer, DOI 10.1007/s00247-010-1915-0, 2011.

[12] R. Bull, P. Edwards, P. Kemp, S. Fry, I. Hughes. *Bone age assessment: a large scale comparison of the Greulich and Pyle, and Tanner and Whitehpuse (TW2) methods* Archive of Disease in Childhood, 81(2):172-173, 1999.

[13] H. Thodberg, S. Kreiborg, A. Juul, K. Pedersen. *The bonexpert method for automated determination of skeletal maturity.* Medical Imaging, IEEE transactions on, 1(1309):52-66, 2009.

[14] Gertych, A., Zhang, A., Sayre, J., Pospiech-Kurkowska, S., Huang, H., *Bone age assessment of children using a digital hand atlas*, Computerized Medical Imaging and Graphics. 31, (2007) 322-331.

[15] M. Kashif, T. M. Deserno, D. Haak, S. Jonas. *Feature description with SIFT, SURF, BRIEF, BRISK, or FREAK? A general question answered for bone age assessment.* Computers in Biology and Medicine, 68:67-75, (2016).

[16] Giordano, D., Kavasidis, I., Spampinato, C., *Modeling skeletal bone development with hidden Markov models*, Computer Methods and Programs in Biomedicine. 124, pp. 138-147, (2016).

[17] Spampinato, C., Palazzo, S., Giordano, D., Aldinucci, M., Leonardi, R., *Deep learning for automated skeletal bone age assessment in x-ray images*, Medical Image Analysis. 36, pp. 41-51, (2017).

[18] Ayala-Raggi, S., Montoya, F., Barreto-Flores, A., Sánchez-Urrieta, S., Portillo-Robledo, J., Bautista-López, V., *A supervised incremental learning technique for automatic recognition of the skeletal maturity, or can a machine learn to assess bone age without radiological training from experts?*, International Journal of Pattern Recognition and Artificial Intelligence (2017).

[19] M. Turk and A. Pentland. *Eigenfaces for Recognition*, Journal of Cognitive Neuroscience, vol. 3, no. 1, pp. 71-86, (1991).

[20] Larson, D., Chen, M., Lungren, M., Halabi, S., Stence, N. and Langlotz C., *Performance of a Deep-Learning Neural Network Model in Assessing Skeletal Maturity on Pediatric Hand Radiographs*, Radiology, vol. 287, no. 1, (2017).

[21] M. Harmsen, B. Fischer, H. Schramm, T. Seidl, T.M. Deserno, *Support vector machine classification based on correlation prototypes applied to boneage assessment*, IEEE Journal of Biomedical and Health Informatics, vol.17, (2013).

[22] B. Fischer, P. Welter, R. W. Günther, T.M.Deserno, *Web based bone age assessment by content based image retrieval for case based reasoning*, Int J CARS (2012).

[23] P. Cunha, D.C. Moura, M.A. Guevara, C. Guerra, D. Pinto, I. Ramos, *Impact of Ensemble Learning in the Assessment of Skeletal Maturity* J Med Syst (2014).

[24] J. Arlow, I. Neustatd,. *UML 2 and The Unified Proccess. Addison Wesley* 2da Edición, Massachusetts, USA (2005).