



**UNIVERSIDAD
DE ANTIOQUIA**

**DIACEFAL – Algoritmo para el diagnóstico cefalométrico
utilizando radiografía lateral del cráneo**

Sebastián González Herrera

Trabajo de grado presentado para optar al título de Ingeniero
Electrónico.

Tutores

David Stephen Fernández Mc Cann, (Ph.D.)

Elizabeth Llano Sánchez, (Mg)

Universidad de Antioquia
Facultad de Ingeniería
Ingeniería Electrónica
Medellín, Antioquia, Colombia
2024

Cita	S. González Herrera
Referencia	
Estilo IEEE (2020)	[1] S. González Herrera, “DIACEFAL – Algoritmo para el diagnóstico cefalométrico utilizando radiografía lateral del cráneo”, Trabajo de grado, Ingeniería Electrónica, Universidad de Antioquia, Medellín, Antioquia, Colombia, 2024.



Grupo de Electrónica de Potencia, Automatización y Robótica (GEPAR)

Facultad de Odontología, Universidad de Antioquia

Seleccione centro de investigación UdeA (A-Z)



Centro de Documentación Ingeniería (CENDOI) Seleccione biblioteca, CRAI o centro de documentación UdeA (A-Z)

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Agradecimientos

En primer lugar, quiero expresar mi más sincero agradecimiento a mis padres. Su amor, paciencia y apoyo incondicional me han dado la fuerza necesaria para enfrentar y superar los desafíos que he encontrado en mi camino académico.

A Jhon Mario, mi hermano, quiero agradecerte profundamente por tu compañía y solidaridad durante este proceso. Tu constante aliento y fe en mí han sido una fuente de inspiración que me ha impulsado a perseguir mis ambiciones con determinación.

Quiero expresar mi profundo agradecimiento a los profesores de excelencia que han dejado una huella indeleble en mi trayectoria y han cultivado en mí una verdadera pasión por mi campo profesional. En particular, deseo destacar la orientación invaluable y el apoyo brindado por mis tutores, el Profesor David Stephen Fernandez y la Dra Elizabeth Llano Sánchez. Con su experiencia y sabiduría, me han guiado y moldeado en cada etapa de este trabajo, por lo cual les estoy sumamente agradecido.

Por último, quiero expresar mi sincero agradecimiento a todos mis amigos, conocidos y familiares que han estado presentes en cada paso y en cada logro. Su apoyo y aliento han sido fundamentales para alcanzar este importante hito en mi vida académica.

Gracias a todos por ser parte de este viaje.

SIGLAS, ACRÓNIMOS Y ABREVIATURAS

IA	Inteligencia artificial
DL	Deep learning
ANN	Artificial Neural Network
ML	Machine Learning
SD	Standard Deviation
SDR	Successful Detection Rate
YOLO	You Only Look Once
API	Application Programming Interface

RESUMEN

En la actualidad, el análisis cefalométrico es un procedimiento esencial en el diagnóstico, planificación y seguimiento de tratamientos de ortodoncia, ortopedia y odontopediatría. A pesar de que existen software para realizar análisis cefalométrico, no se contemplan en ellos algunas medidas utilizadas de referencia, lo que obliga a los profesionales a realizarlas de manera manual, lo que se convierte en un proceso laborioso que consume tiempo y propenso a errores. La necesidad de un método automatizado eficiente motivó el desarrollo de un algoritmo basado en aprendizaje profundo (DL).

El proyecto se centró en implementar el análisis cefalométrico de Bimler, utilizando el modelo de detección de objetos YOLOv8. Se recopiló un conjunto de datos compuesto por radiografías laterales del cráneo, que fueron etiquetadas manualmente para identificar los puntos cefalométricos. Estos datos se utilizaron para entrenar el modelo, aprovechando la plataforma Roboflow para la gestión del dataset. El desarrollo del sistema incluyó varios componentes clave: la creación de un dataset etiquetado, el entrenamiento y ajuste del modelo YOLOv8, y el desarrollo de una interfaz de usuario en Java para la aplicación clínica del modelo.

Los resultados del proyecto fueron prometedores. El sistema automatizado logró identificar 19 de los 20 puntos de referencia cefalométricos con una precisión notable, alcanzando una tasa de detección igual al 80 % para un umbral de precisión de 2 mm. Las métricas de evaluación utilizadas incluyeron el Error Radial Medio (MRE), la Desviación Estándar (SD) y la Tasa de Detección Exitosa (SDR), todas las cuales indicaron un alto nivel de precisión y fiabilidad del modelo desarrollado.

Como resultado, este trabajo presenta una solución efectiva al problema de la automatización del análisis cefalométrico, demostrando que las técnicas de aprendizaje profundo pueden mejorar considerablemente la precisión y eficiencia en el diagnóstico craneofacial. El software desarrollado, DIACEFAL, representa un avance significativo en la integración de inteligencia artificial en la práctica clínica, reduciendo errores y optimizando el tiempo de los especialistas. Este proyecto no solo aporta beneficios directos en el campo de la ortodoncia, ortopedia y odontopediatría, sino también que contribuye al campo de las aplicaciones de algoritmos de inteligencia artificial en la odontología.

Palabras clave — Cefalometría, aprendizaje automático, Visión artificial, Bimler, Java, Software, Puntos de referencias.

ABSTRACT

Nowadays, cephalometric analysis is an essential procedure in the diagnosis, planning, and follow-up of orthodontic, orthopedic, and pediatric dentistry treatments. Although there is software available to perform cephalometric analysis, some reference measurements are not included, which forces professionals to perform them manually, making it a laborious, time-consuming process prone to errors. The need for an efficient automated method motivated the development of an algorithm based on deep learning (DL).

The project focused on implementing Bimler's cephalometric analysis using the YOLOv8 object detection model. A dataset consisting of lateral skull X-rays was collected and manually labeled to identify cephalometric points. This data was used to train the model, leveraging the Roboflow platform for dataset management. The development of the system included several key components: creating a labeled dataset, training and fine-tuning the YOLOv8 model, and developing a user interface in Java for the clinical application of the model.

The project's results were promising. The automated system successfully identified 19 out of 20 cephalometric reference points with notable accuracy, achieving a detection rate equal to 80 % for a precision threshold of 2 mm. The evaluation metrics used included Mean Radial Error (MRE), Standard Deviation (SD), and Successful Detection Rate (SDR), all of which indicated a high level of precision and reliability of the developed model.

As a result, this work presents an effective solution to the problem of automating cephalometric analysis, demonstrating that deep learning techniques can significantly improve accuracy and efficiency in craniofacial diagnosis. The developed software, DIACEFAL, represents a significant advancement in the integration of artificial intelligence into clinical practice, reducing errors and optimizing specialists' time. This project not only provides direct benefits in the fields of orthodontics, orthopedics, and pediatric dentistry but also contributes to the broader field of artificial intelligence algorithm applications in dentistry.

Keywords — Cephalometry, machine learning, computer vision, Bimler, Java, software, reference points.

1 INTRODUCCIÓN

El análisis cefalométrico se ha establecido como una herramienta fundamental para los diagnósticos craneofaciales, en la cual se requiere la medición de múltiples factores lineales y angulares en las imágenes cefalométricas. Cada factor se calcula en base a puntos de referencia clínicamente importantes y proporcionan información útil para facilitar diagnósticos de crecimiento, planificación de tratamientos ortopédicos y ortodóncicos y evaluación de resultados de tratamientos. La identificación de puntos de referencia se ven afectados en muchos casos por problemas con las imágenes, pero mucho más importante por sesgos de los expertos, lo que causa variabilidad en la detección de puntos de referencia, lo que imposibilita tener una “regla de oro” para la detección de los puntos [1]. Además, la identificación de puntos de referencia basada en la evaluación visual de la imagen cefalométrica sigue siendo una tarea difícil que requiere formación especial. Desafortunadamente, el proceso manual es propenso a errores de medición. Un examen clínico con un soporte automático reduciría la carga de trabajo y proporcionaría a los odontólogos y especialistas como odontopediatras, ortopedistas u ortodoncistas más tiempo para una planificación óptima de los procedimientos. El avance en la tecnología de reconocimiento de imágenes usando la red neuronal convolucional profunda (CNN), supone una mejora en el diagnóstico por imagen [2]. En 2014 y 2015, el Simposio Internacional del Instituto de Ingenieros Eléctricos y Electrónicos (IEEE) sobre Imágenes Biomédicas (ISBI) organizó desafíos para el análisis cefalométrico automatizado, en donde el mejor resultado se obtuvo con el modelo random forest (RF) en donde las tasas de detección satisfactoria (SDR) en dos conjuntos de datos de prueba dentro de un rango de precisión clínicamente aceptado de 2,0 mm fueron del 73,68 % y del 66,11 % [3]. Actualmente los modelos desarrollados lograron superar el SDR del 88 % [1]. Hoy en día no se han publicado modelos específicos para el método de Bimler, por lo que el objetivo de este trabajo es desarrollar un algoritmo basado en Deep Learning (DL) para la identificación de los puntos de referencia del análisis cefalométrico de Bimler.

2 OBJETIVOS

2.1. Objetivo general

Implementar un algoritmo que realice el método BIMLER de análisis cefalométrico a partir de una radiografía lateral del cráneo con el fin de apoyar diagnósticos ortopédicos y ortodóncicos a través de un modelo existente de DL como YOLOv8, para lo cual se utilizará una plataforma de desarrollo de modelos como Roboflow para la creación del dataset y el entrenamiento del modelo y se validará su funcionalidad a través de un software desarrollado en Java 8.

2.2. Objetivos específicos

1. Recopilar el dataset de radiografías digitalizadas necesarias para el entrenamiento del modelo del registro de archivo de la facultad de odontología de la Universidad de Antioquia (UDEA).
2. Etiquetar las radiografías digitalizadas, mediante el uso de herramientas orientada al desarrollo de modelos de DL tales como Roboflow para la creación del dataset y el entrenamiento del modelo.
3. Escoger el modelo DL a utilizar para la cefalometría y realizar su entrenamiento, mediante el entrenamiento de varios modelos tales como YOLOv8, YOLOv5, etc. y la evaluación de su precisión.
4. Realizar una interfaz de usuario que permita al personal calificado utilizar el modelo entrenado como ayuda diagnóstica, programado en Java 8.
5. Validar el modelo y la interfaz de usuario con especialistas de la facultad de odontología de la UDEA.

3 MARCO TEÓRICO

La base de este trabajo se fundamenta en diversos conceptos odontológicos, especialmente de las áreas de la ortodoncia y ortopedia. El análisis cefalométrico resulta de gran utilidad en el diagnóstico del crecimiento craneofacial, la planificación de tratamientos ortopédicos y ortodóncicos, así como en la evaluación de los resultados de dichos tratamientos. En este contexto, las redes neuronales profundas (DL) emergen como una solución prometedora para automatizar y mejorar la precisión en la detección de puntos de referencia cefalométricos mediante el método Bimler, ampliamente utilizado en el análisis cefalométrico. Este capítulo busca arrojar luz sobre estos dominios, otorgando credibilidad y contexto a la metodología propuesta.

3.1. Inteligencia artificial (IA)

El término inteligencia artificial (IA) aparece en la literatura por primera vez en 1956 en el proyecto de investigación de Verano de Dartmouth de John McCarthy, aunque las bases de estos algoritmos y conceptos tiene su origen en el matemático inglés Alan Turing [4]. La inteligencia artificial es la habilidad de que una máquina simule y ejecute tareas que normalmente requieren inteligencia humana, tales como el razonamiento lógico, el aprendizaje y la solución de problemas. La base de la inteligencia artificial son los algoritmos y tecnologías de aprendizaje automático que le permite a las máquinas aplicar determinadas capacidades cognitivas y realizar tareas de manera autónoma o semiautónoma [5]. La capacidad de la inteligencia artificial para resolver problemas avanzados se basa en la creación de modelos analíticos que generan predicciones, reglas, propuestas, recomendaciones o salidas similares [6]. La inteligencia artificial se puede clasificar por su grado de capacidad cognitiva o por su grado de autonomía. La capacidad puede ser débil o limitada, general o superlativa. Por su autonomía, puede ser reactiva, deliberativa, cognitiva o totalmente autónoma [5]. A medida que mejore la inteligencia artificial, se automatizarán y mejoran muchos procesos como por ejemplo la toma de decisiones en el campo de la salud.

3.2. Machine learning (ML)

En términos generales, ML significa que el rendimiento de un programa informático mejora con la experiencia con respecto a una tarea o medida de rendimiento. Como tal el ML tiene

como objetivo automatizar la tarea de construcción de modelos analíticos para realizar tareas cognitivas como la detección de objetos o la traducción del lenguaje natural. En la actualidad impulsados por el desarrollo de nuevos frameworks de programación con nuevas características, la disponibilidad de grandes conjuntos de datos y el amplio acceso a la potencia de cómputo necesaria, cada vez se construyen más modelos analíticos, esto se logra mediante la aplicación de algoritmos que aprenden iterativamente de los datos de entrenamiento específicos del problema, lo que permite a las computadoras encontrar información oculta y patrones complejos sin ser programados explícitamente. ML libera al ser humano de la carga de explicar y formalizar su conocimiento en una forma que sea procesable para la máquina y permite desarrollar sistemas inteligentes de manera más eficiente [6].

3.3. Redes neuronales artificiales (ANN)

Durante los últimos años el campo de ML ha tenido un crecimiento acelerado, trayendo con este una gran variedad de avances en algoritmos de aprendizaje sofisticados y técnicas de preprocesamiento. Uno de estos avances fue la evolución de las redes neuronales artificiales (ANN) hacia arquitecturas de redes neuronales cada vez más profundas con capacidades de aprendizaje mejoradas como Deep learning (DL). Las ANN consisten en representaciones matemáticas de unidades de procesamiento conectadas llamadas neuronas artificiales, las cuales son un sistema que simula la sinapsis en un cerebro, cada conexión entre neuronas está regida por un peso que se ajusta continuamente durante el proceso de aprendizaje y que representa la sinapsis. Las señales sólo son procesadas por las neuronas posteriores si se supera un cierto umbral determinado por una función de activación. Las neuronas suelen estar organizadas en varias capas, siendo la primera la de entrada, la última la de salida y las intermedias las ocultas. Los parámetros que se definen antes del entrenamiento se conocen como hiper parámetros como por ejemplo la cantidad de capas [6].

3.4. Deep learning (DL)

Las redes DL generalmente constan de más de una capa oculta, estas generalmente están organizadas en arquitecturas profundamente anidadas, además, suelen contener neuronas avanzadas en contraste con las ANN simples, es decir, pueden usar operaciones avanzadas como convoluciones o activaciones múltiples en una neurona en lugar de usar una función de activación simple. Estas funciones avanzadas permiten que las redes DL tengan la capacidad de extraer características en un conjunto de datos de manera automática y que también realicen la tarea de aprendizaje correspondiente. Esta capacidad de extracción de las redes, se le conoce como Deep learning, las ANN simples y otros algoritmos de ML como los árboles de decisión pueden incluirse en el término de aprendizaje automático superficial, ya que no proporcionan tal funcionalidad. Como todavía no existe una demarcación exacta entre los dos conceptos en la literatura, se ilustra en la Figura 3-1.

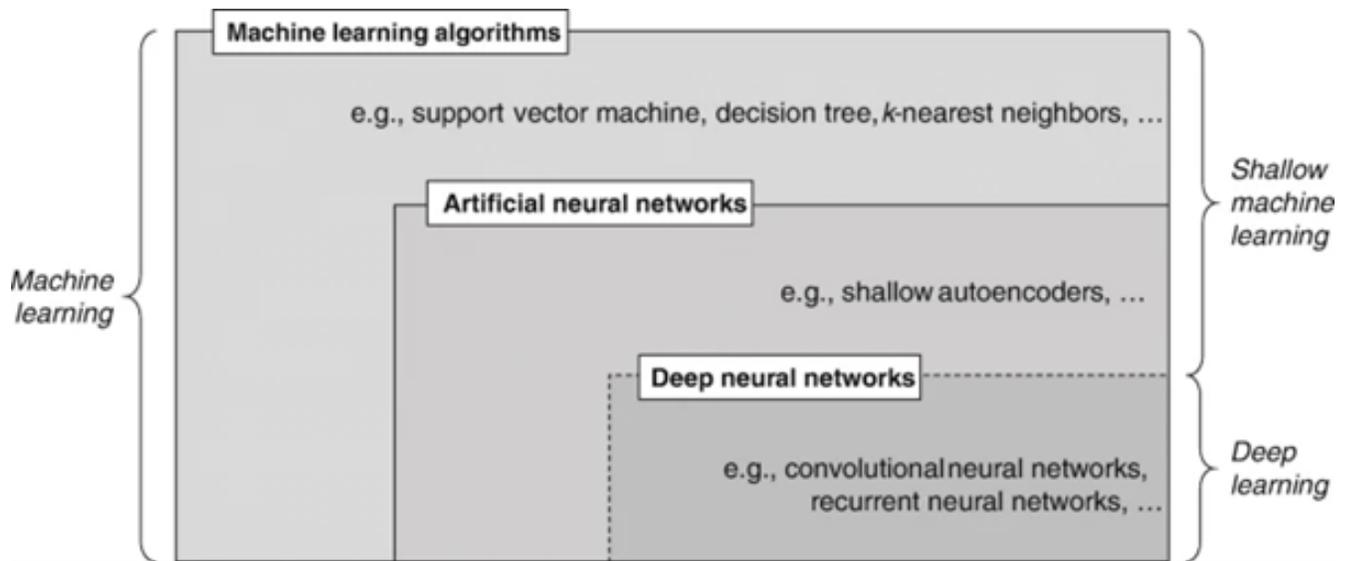


Figura 3-1: Relación entre los conceptos de ML, ANN y DL con los conceptos de Shallow Machine Learning Y Deep Learning.[6]

Los algoritmos de ML poco profundos se consideran intrínsecamente interpretables por humanos y, por lo tanto, cajas blancas, mientras que los algoritmos de ML más avanzados es imposible interpretar su funcionamiento por lo cual, constituyen una caja negra. Para muchas aplicaciones específicas DL ha mostrado un rendimiento superior al ser humano, sin embargo, estos beneficios también tienen un precio, ya que existen varios desafíos que superar para implementar con éxito modelos analíticos, estos incluyen la elección adecuada entre múltiples opciones de implementación, sesgo y deriva en los datos, la mitigación de las propiedades de caja negra y la reutilización de modelos preconfigurados [6].

3.5. Cefalometría de BIMLER

Integra el sistema diagnóstico-terapéutico de la filosofía de Bimler que cuenta con técnicas de análisis, puntos y sistemas de referencia. Analiza la morfología facial y clasifica la cara tipológicamente. Los datos resultantes de este análisis se evalúan y se clasifican en relación con las opciones de valores, buscando establecer por comparación, las condiciones de armonía o desarmonía dentofacial. Este procedimiento ha pasado por varios cambios en donde algunas mediciones fueron abandonadas, se creó el análisis compacto y se introdujera el código de colores y el índice SAGA. Se denominará análisis cefalométrico simplificado de Bimler a la versión que contiene las medidas angulares y lineales y las clasificaciones para analizar la cara de perfil [7].

3.5.1. Puntos de referencia

Algunos de los puntos de referencia usados en este análisis fueron definidos por Bimler. Los demás han sido descritos por otros autores y son de uso común en otras técnicas cefalométricas.

Cuadro 3-1: Conjunto de puntos de referencia utilizados para el análisis cefalométrico de Bimler. [7] (continúa en la siguiente página)

Punto	Descripción
Or	ORBITARIO: punto más bajo del contorno de la órbita
Po	PORION: punto más alto del meato acústico externo
T	TUBER: Intersección de Frankfurt, de la vertical que pasa por la parte más posterior de la pared anterior de la fosa pterigomaxilar
N	NASION: punto más anterior de la sutura frontonasal
A	PUNTO A: punto más posterior de la concavidad anterior del proceso alveolar del maxilar superior, cerca de la altura del ápice incisivo
A'	Proyección del punto A sobre la horizontal de Frankfurt
B	PUNTO B: punto más posterior de la concavidad anterior del proceso alveolar de la mandíbula
B'	Proyección del punto B sobre la horizontal de Frankfurt
M	MENTONIANO: punto más inferior del contorno del mentón
No	NOTCH: punto más alto de la incisura antegonial
Go	GONION: bisectriz del ángulo formado por las tangentes al margen posterior de la rama ascendente y el plano mandibular
ENA	ESPINA NASAL ANTERIOR: Punto extremo anterior de la espina nasal anterior
ENP	ESPINA NASAL POSTERIOR: Punto extremo posterior de la espina nasal posterior

Continúa en la siguiente página

Cuadro 3-1 – Continuación

Punto	Descripción
Cls	CLIVUS SUPERIOR: Punto en el tercio superior del clivus, arbitrariamente ubicado a 1cm del extremo superior
Cli	CLIVUS SUPERIOR: Punto en el tercio inferior del clivus, arbitrariamente ubicado a 1cm del extremo inferior
Me	MENTALE (de Bimler): Punto más posterior y medio del contorno interno de la sínfisis mentoniana
Cm	CENTRO MASTICATORIO (Bimler): Centro de la curva de Spee. Es el centro de una circunferencia que pasa por las caras oclusales de los dientes posteriores y simultáneamente al punto Capitulare
S	SILLA: punto central de la silla turca
C	CAPITULARE: Punto central de la cabeza del cóndilo mandibular
TM	TEMPOROMANDIBULAR (Bimler): Proyección del punto C sobre la horizontal de Frankfurt (HF)
Ap	APICAL (Bimler): ápice de la raíz del primer premolar superior
Gn	GNATION: punto mediano entre los puntos más anterior e inferior del contorno de la sínfisis
Cd	CONDILION: Punto posterosuperior de la cabeza del cóndilo mandibular

Para mejorar la precisión y la comodidad al calcular el punto T, se definió el punto T' como la parte más posterior de la pared anterior de la fosa pterigomaxilar. Este punto, que no pertenece al análisis original de Bimler, se utiliza como referencia para calcular el punto T.

3.5.2. Sistemas de referencia

Bimler estableció dos sistemas referenciales para orientar su cefalometría, el sistema ortogonal y el sistema esférico, que permiten las mediciones y comparaciones goniométricas y lineales.

3.5.2.1. Sistema ortogonal

Es un sistema de coordenadas constituido por la horizontal de Frankfurt (HF) y por la vertical que pasa por el punto T (VT), complementado por las verticales que pasan por el punto A (VA) y por el punto C (VC), definiendo respectivamente las referencias anterior y posterior. Todas las medidas angulares, la mayoría de las lineales y el índice facial están relacionadas con el Sistema Ortogonal de Referencia.

3.5.2.2. Sistema esferico

Según Bimler, un sistema esférico sería lo más adecuado para representar las relaciones entre el equilibrio funcional de los músculos masticatorios, de las ATMs, y de la interrelación de los arcos dentarios. Seleccionó la curva de Spee para integrar el sistema, y estableció, empíricamente, que podría ser representado en las telerradiografías de perfil, por un segmento de arco que pasa por las caras oclusales de los dientes posteriores y por el centro de la cabeza del cóndilo mandibular (C). El centro hipotético de esta curva de Spee lo denominó centro masticatorio (CM), y juntamente con los puntos mentale (Me), Apical (Ap) y capitulare (C), forman el conjunto de puntos de referencia de Sistema Esférico. La recta que conecta el CM al Me se le llama eje de “stress” de la dentición o F6 (Factor 6) y en relación con el punto Ap, es un importante indicador de las relaciones gnatodentarias.

3.5.3. Factores

Durante muchos años se analizaron 10 factores. Revisando su cefalometría, Bimler retiró los factores 9 (planum del esfenoides) y 10 (línea nasal), del análisis de rutina, por ser muy limitada su aplicación en la clínica [7].

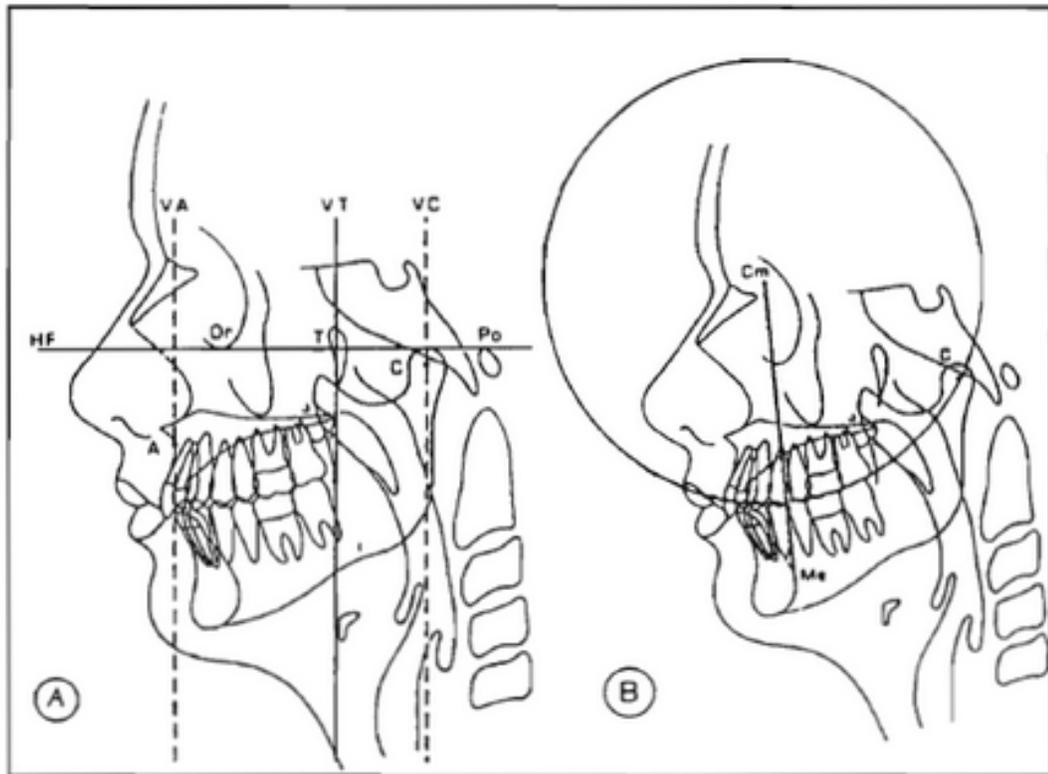


Figura 3-2: Sistemas de referencias del análisis de Bimler. A sistema ortogonal y B sistema esférico.
[7]

Cuadro 3-2: Sistema de factores del análisis cefalométrico de Bimler. [7]

Factores	Descripción	Clasificación
Factor 1 o plano N-A	Es la línea que une los puntos cefalométricos N y A. representa el ángulo superior de perfil.	<ul style="list-style-type: none"> ■ PROGNATA: ángulo del plano más grande que 1° ■ ORTOGNATA: ángulo del plano entre -1° y 1° ■ RETROGNATA: ángulo del plano más pequeño que -1°
Factor 2 o plano A-B	Llamado ángulo inferior del perfil y representa la inclinación de la línea A-B	<ul style="list-style-type: none"> ■ RETRÓGENO: ángulo del plano más grande que 1°, denominado clase III ■ ORTÓGENO: ángulo del plano entre -1° y 1°, denominado clase I ■ PRÓGENO: ángulo del plano más pequeño que -1°, denominado clase II

Continúa en la siguiente página

Cuadro 3-2 – *Continuación*

Factores	Descripción	Clasificación
Factor 3 o plano M-No	Es el factor que mide la inclinación mandibular llamado plano mandibular y representa la inclinación de la línea M-No, su trazado puede ser prolongado hasta la región del gonion para facilitar la visualización y medición	<ul style="list-style-type: none"> ■ DOLICOGNATA: ángulo del plano entre 0° y 15°, denominado de cara profunda y crecimiento horizontal ■ MESOGNATA: ángulo del plano entre 15° y 30°, denominado de cara mediana y crecimiento neutro ■ LEPTOGNATA: ángulo del plano entre 30° y 45°, denominado de cara larga y crecimiento vertical
Factor 4 o plano ENA-ENP	Representa la inclinación del maxilar, siendo conocido también como plano palatino y como plano biespinal. Se define por la línea de unión de los puntos ENA y ENP	<ul style="list-style-type: none"> ■ RETROINCLINACIÓN: ángulo del plano menor a -2°, indicando una mordida abierta ■ ORTOINCLINACIÓN: ángulo del plano entre -2° y 2°, indicando una mordida neutral ■ PROINCLINACIÓN: ángulo del plano mayor a 2°, indicando una mordida profunda

Continúa en la siguiente página

Cuadro 3-2 – *Continuación*

Factores	Descripción	Clasificación
Factor 5 o plano Cls-Cli	Es la línea que une los puntos Cls y Cli. Expresa la inclinación del plano del clivus en relación con el plano horizontal de Frankfurt	<ul style="list-style-type: none"> ■ Inclinación baja: ángulo del plano entre 50° y 60°, caracteriza una base baja u horizontal ■ Inclinación mediana: ángulo del plano entre 60° y 70°, caracteriza una base media o neutra ■ Inclinación alta: ángulo del plano entre 70° y 80°, caracteriza una base alta o vertical
Factor 6 o plano Cm-Me	Es la línea que conecta los puntos Cm y Me. Se define como eje stress de la dentición. Gráficamente es una prolongación del radio de la Curva de Spee, conectando su centro a la parte más interna del contorno de la sínfisis mentoniana. Bimler considero indispensable la medición del ángulo del factor 6, que pasó a ser representado sólo gráficamente, siendo el eje referencial para la clasificación Correlativa.	-

Continúa en la siguiente página

Cuadro 3-2 – *Continuación*

Factores	Descripción	Clasificación
Factor 7 o línea N-S	Es la conexión de los puntos N y S. Frecuentemente se llama inclinación de la base craneana	<ul style="list-style-type: none"> ■ Para la inclinación del plano entre 0° y 6°, se denomina cara profunda y crecimiento horizontal ■ Para la inclinación del plano entre 6° y 8°, se denomina de cara mediana y crecimiento neutro ■ Para la inclinación del plano entre 8° y 14°, se denomina de cara larga y crecimiento vertical
Factor 8 o línea C-Go	Es la línea que une los puntos C y Go, también se conoce como línea de la rama ascendente y representa la medida de la flexión de la mandíbula	<ul style="list-style-type: none"> ■ HIPOFLEXIÓN: ángulo del plano menor a -1° ■ ORTOFLEXIÓN: ángulo del plano entre -1° y 8° ■ HIPERFLEXIÓN: ángulo del plano mayor a 8°

3.5.4. Ángulos de la cara

Bimler completa el análisis angular de la morfología de la cara con algunos ángulos, formados por factores, conocidos como ángulos de la cara [7].

Cuadro 3-3: Sistema de ángulos del análisis cefalométrico de Bimler. [7]

Ángulo	Descripción	Clasificación
Ángulo del perfil	El perfil está representado por el ángulo N-A-B, constituido por los factores 1 y 2 (N-A y A-B). Su evaluación se hace como la suma algebraica de los factores 1 y 2	<ul style="list-style-type: none"> ■ Para ángulos más pequeños que -1° se clasifica como cóncavo (clase III) ■ Para ángulos entre -1° y 1° se clasifica como recto (clase I) ■ Para ángulos más grandes que 1° se clasifica como convexo (clase II)
Ángulo basal superior	Está compuesto por los planos clivus y palatino. Su evaluación puede ser hecha por la medición directa o por la suma algebraica de los factores 4 y 5	<ul style="list-style-type: none"> ■ DÓLICO o D (DEEP): ángulo entre 50° y 60° con tipo de crecimiento horizontal ■ MESO o M (MEDIUM): ángulo entre 60° y 70° con tipo de crecimiento neutro ■ LEPTO o L (LONG): ángulo entre 70° y 80° con tipo de crecimiento vertical

Continúa en la siguiente página

Cuadro 3-3 – Continuación

Ángulo	Descripción	Clasificación
Ángulo basal inferior	Formado por los planos palatino y mandibular. Su evaluación se hace restando el factor 3 del 4 cuando este es positivo, de lo contrario se suman los dos factores	<ul style="list-style-type: none"> ■ DÓLICO o D(DEEP): ángulo entre 0° y 15° con tipo de crecimiento horizontal ■ MESO O M(MEDIUM): ángulo entre 15° y 30° con tipo de crecimiento neutro ■ LEPTO O L(LONG): ángulo entre 30° y 45° con tipo de crecimiento vertical
Ángulo Goniaco	Es una forma de analizar y describir la morfología de la mandíbula. El ángulo goniaco se evalúa a través de los factores 3 y 8. El ángulo goniaco se puede evaluar por medición directa o sumando 90° al resultado de la suma algebraica de los factores 3 y 8	<ul style="list-style-type: none"> ■ DOLICOGNATA o D(DEEP): ángulo entre 90° y 105° con tipo de crecimiento horizontal ■ MESOGNATA O M(MEDIUM): ángulo entre 105° y 120° con tipo de crecimiento neutro ■ LEPTOGNATA O L(LONG): ángulo entre 120° y 135° con tipo de crecimiento vertical

Los ángulos basales facilitan la descripción de la arquitectura facial y la identificación de las composiciones con falta de armonía. Bimler observó que en las caras de composición armónica, la clasificación de los ángulos basales coincidía con las combinaciones D/D D/M M/D M/M M/L L/M L/L y las relaciones extremas, D/L y L/D, son comúnmente observadas en los casos de pronóstico menos favorable y que presentan mayores dificultades en el tratamiento [7].

3.5.5. Medidas lineales

Cuadro 3-4: Medidas lineales del análisis cefalométrico de Bimler. [7]

Medida	Descripción	Clasificación
A'-T	Largo proyectado del maxilar. Medida del punto A' hasta la intersección con la vertical T	<ul style="list-style-type: none"> ■ Para longitud entre 44 a 47 mm se clasifica como maxilar pequeño ■ Para longitud entre 48 a 52 mm se clasifica como maxilar mediana ■ Para longitud entre 53 a 56 mm se clasifica como maxilar grande
T-TM	Posición de las ATMs (distancia del punto T hasta la proyección del punto C en Horizontal de Frankfurt (TM))	<ul style="list-style-type: none"> ■ Para longitud entre 24 a 27 mm se clasifica como pequeña ■ Para longitud entre 28 a 32 mm se clasifica como mediana ■ Para longitud entre 33 a 36 mm se clasifica como grande

Continúa en la siguiente página

Cuadro 3-4 – *Continuación*

Medida	Descripción	Clasificación
A'-TM	Representa la profundidad facial. Es la suma de las distancias A'-T y T-TM	<p>Se calcula como la suma de A'-T con T-TM. Junto con la Horizontal de Frankfurt a M determina el índice facial.</p> <ul style="list-style-type: none"> ■ Para longitud menor de 77 mm se clasifica como pequeña ■ Para longitud entre 77 a 83 mm se clasifica como promedio ■ Para longitud mayor a 83 mm se clasifica como grande
A'-B'	Llamada resalte óseo o escalón óseo, es la distancia de los puntos A y B proyectados en HF	<ul style="list-style-type: none"> ■ Para valores menores a 0, se denomina de clase III ■ Para valores entre 0 y 10 mm, se denomina de clase I ■ Para valores mayores a 10 mm, se denomina de clase II

Continúa en la siguiente página

Cuadro 3-4 – *Continuación*

Medida	Descripción	Clasificación
B'-TM	Largo proyectado de la mandíbula. Representado por la distancia de los puntos B y C proyectados en HF	<p>Se utiliza para verificar la medición de A'-T y A'-TM y para calcular A'-B'.</p> <ul style="list-style-type: none"> ■ Para longitud menor de 76 mm se clasifica como cuerpo pequeño ■ Para longitud entre 76 a 80 mm se clasifica como cuerpo promedio ■ Para longitud mayor a 80 mm se clasifica como cuerpo grande
N-S	Largo de la base craneana anterior. Es la distancia del nasion hasta silla, medida directamente	<ul style="list-style-type: none"> ■ Para longitud menores a 60 mm se clasifica como corta ■ Para longitud entre 60 a 80 mm se clasifica como mediana ■ Para longitud mayores a 80 mm se clasifica como larga
Gn-Cd	Largo diagonal de la mandíbula, medido directamente del gnation hasta el condilion	<ul style="list-style-type: none"> ■ Para longitud entre 80 a 99 mm se clasifica como pequeña ■ Para longitud entre 100 a 120 mm se clasifica como mediana ■ Para longitud entre 121 a 140 mm se clasifica como grande

Continúa en la siguiente página

Cuadro 3-4 – *Continuación*

Medida	Descripción	Clasificación
N-HF	Altura del nasion. Altura entre el punto N y la HF	<p>Se usa para evaluar la altura del nasion y la altura total de la cara.</p> <ul style="list-style-type: none"> ■ Para longitud menor de 25 mm se clasifica como bajo ■ Para longitud entre 25 a 31 mm se clasifica como medio ■ Para longitud mayor a 31 mm se clasifica como alto
HF-M	Altura facial suborbital, medida de la HF al punto mentoniano	<p>Se usa junto con A'-TM para calcular el índice facial.</p> <ul style="list-style-type: none"> ■ Para longitud menor de 75 mm se clasifica como pequeña ■ Para longitud entre 75 a 80 mm se clasifica como mediana ■ Para longitud mayor a 80 mm se clasifica como grande
N-M	Altura total de la cara. Es la suma de las distancia N-HF y HF-M	<ul style="list-style-type: none"> ■ Para longitud menor de 115 mm se clasifica como disminuída ■ Para longitud entre 115 a 125 mm se clasifica como promedio ■ Para longitud mayor a 125 mm se clasifica como aumentada

Continúa en la siguiente página

Cuadro 3-4 – *Continuación*

Medida	Descripción	Clasificación
S-HF	Altura de la silla turca. Distancia entre el punto S y HF	<p>Se usa para comparar radiografías del mismo individuo permitiendo dimensionar cambios ocurridos durante el crecimiento.</p> <ul style="list-style-type: none"> ■ Para longitud menor de 18 mm se clasifica como pequeña ■ Para longitud entre 18 a 22 mm se clasifica como mediana ■ Para longitud mayor a 22 mm se clasifica como grande

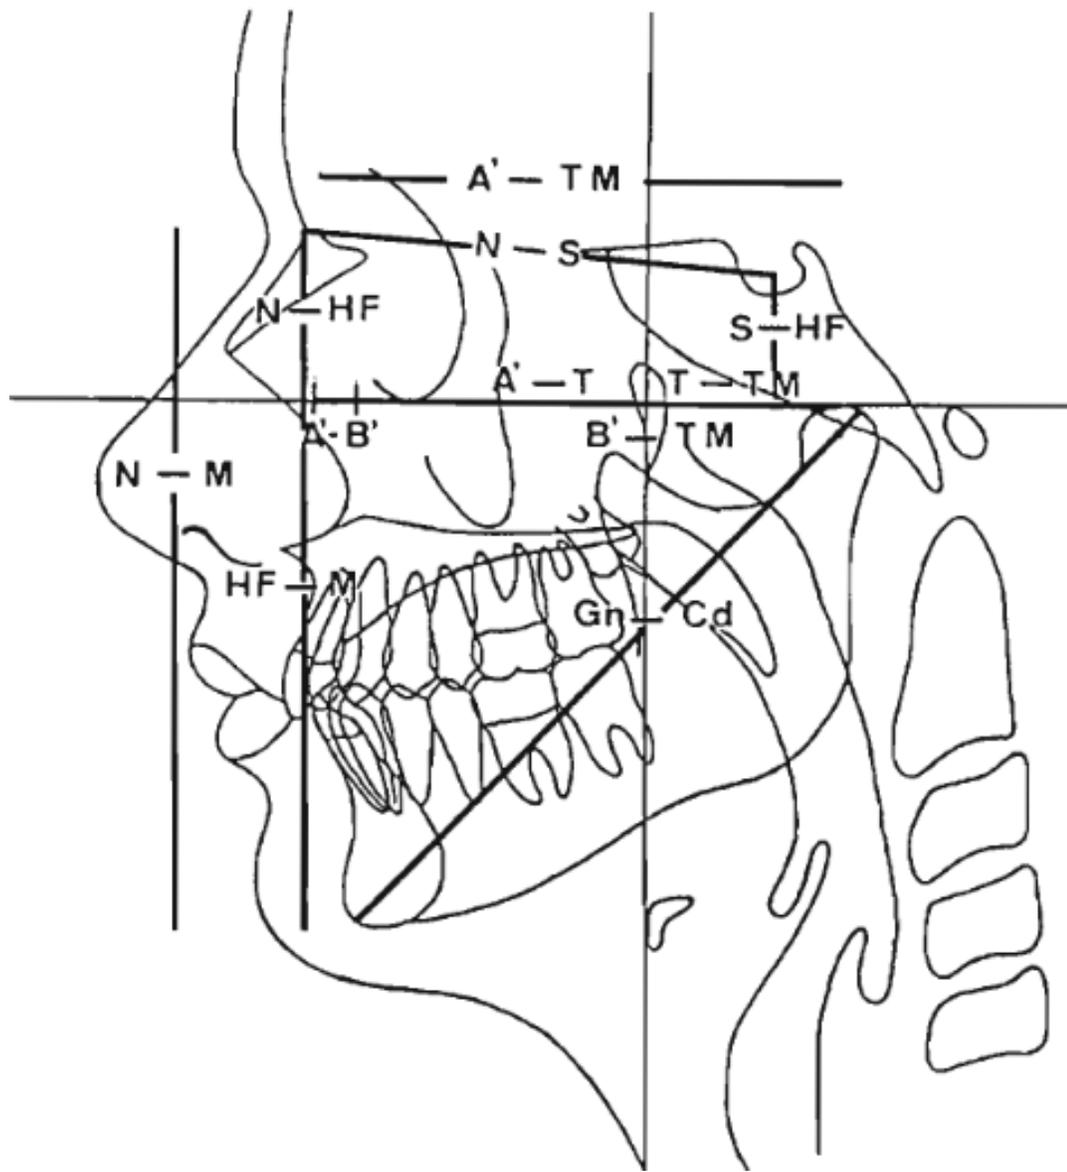


Figura 3-3: Medidas lineales utilizadas en el análisis de Bimler. [7]

3.6. Métricas de evaluación en detección de puntos

La eficacia de un sistema de detección de puntos no se limita a su habilidad para identificar dichos puntos, sino que también radica en su precisión. En este sentido, diversas métricas, tanto tradicionales como específicas del aprendizaje automático, desempeñan un papel crucial en la evaluación del rendimiento de estos sistemas. Métricas como el error radial medio, la desviación estándar y la tasa de detección exitosa ofrecen una visión profunda del comportamiento del modelo.

3.6.1. Error Radial Medio (MRE)

El Error Radial Medio o Mean Radial Error (MRE) es una métrica ampliamente utilizada para evaluar el rendimiento de algoritmos de detección y localización de puntos de referencia en imágenes, particularmente en el campo del análisis cefalométrico. Se calcula como la media de las distancias euclidianas entre las ubicaciones predichas por el algoritmo y las ubicaciones reales (ground truth) de los puntos de referencia anatómicos en radiografías cefalométricas.

El MRE se calcula de la siguiente manera [8]:

$$\text{MRE} = \frac{1}{N} \sum_{i=1}^N R_i \quad (3-1)$$

Donde:

$$R_i = \sqrt{(x_i - x'_i)^2 + (y_i - y'_i)^2} \quad (3-2)$$

y:

- N es el número total de puntos de referencia
- (x_i, y_i) es la ubicación real del punto de referencia i
- (x'_i, y'_i) es la ubicación predicha por el algoritmo para el punto de referencia i

3.6.2. Desviación Estándar (SD)

La desviación estándar o Standard Deviation (SD) es una medida de dispersión que indica cuánto varían los valores de un conjunto de datos respecto a la media o promedio. En otras palabras, la desviación estándar mide la cantidad de dispersión o variabilidad de los datos en relación con la media.

La SD se calcula de la siguiente manera [8]:

$$SD = \sqrt{\frac{\sum_{i=1}^N (R_i - MRE)^2}{N - 1}} \quad (3-3)$$

Donde:

- R_i es el error radial para el punto de referencia i
- MRE es el Mean Radial Error (MRE)
- N es el número total de puntos de referencia

3.6.3. Tasa de Detección Exitosa (SDR)

La tasa de detección exitosa o successful detection rate (SDR) es una medida importante para evaluar el rendimiento de algoritmos de detección de puntos de referencia en imágenes, particularmente en el contexto del análisis cefalométrico. Las coordenadas estimadas se consideran correctas si el error entre las coordenadas estimadas y la posición correcta es menor que un rango de precisión.

La SDR se calcula de la siguiente manera [8]:

$$SDR = \frac{\text{Número de puntos de referencia detectados exitosamente}}{\text{Número total de puntos de referencia}} \times 100 \% \quad (3-4)$$

Donde:

- Un punto de referencia se considera detectado exitosamente si la distancia euclidiana entre la ubicación predicha por el algoritmo y la ubicación real (ground truth) es menor o igual a un umbral de error máximo permitido.

- El umbral máximo de error es un valor establecido, típicamente en intervalos como 2, 2.5, 3 o 4 mm.

4 METODOLOGÍA

El proceso de desarrollo de este proyecto incluyó cinco fases: Recopilación de los datos para el dataset, proceso de creación del dataset, selección del modelo de YOLO, realización del software en Java 8 y validación del modelo y el software.

4.1. Fase 1: Recopilación de los datos para el dataset

La fase inicial de recopilación de datos para conformar el dataset se centró en la obtención de radiografías cefalométricas y la subsecuente identificación de los puntos cefalométricos clave según el método Bimler. Este enfoque se fundamentó en el análisis minucioso de las relaciones y proporciones existentes entre las diversas estructuras craneofaciales y dentales presentes en las radiografías.

4.1.1. Actividad 1: Obtención de material radiográfico cefalométrico

La recopilación de radiografías cefalométricas para conformar el conjunto de datos se realizó de recursos disponibles en internet. Se llevó a cabo una revisión de los datasets públicos, repositorios abiertos y bases de datos especializadas en el ámbito de la odontología y la radiología en línea. Diversos portales web, como plataformas de investigación, bibliotecas digitales y sitios web de instituciones académicas, fueron examinados en busca de colecciones de radiografías cefalométricas. Gracias a los avances en la digitalización y el acceso abierto a recursos científicos, fue posible identificar y obtener un número considerable de radiografías cefalométricas debidamente anonimizadas, provenientes de proyectos de investigación de diversas partes del mundo. Esta estrategia permitió conformar un conjunto de datos robusto y diverso.

4.1.2. Actividad 2: Etiquetar los puntos de referencia en las radiografías cefalométricas

El proceso de etiquetado de las radiografías cefalométricas se dividió en dos fases metódicas. En la primera fase, el estudiante realizó un estudio a profundidad del método Bimler. Tras esta preparación inicial, el estudiante recibió capacitación por parte de la especialista en odontopediatría y ortopedia maxilar, quien impartió instrucciones detalladas sobre la técnica de identificación precisa de los puntos cefalométricos según el método Bimler. Una vez completada esta formación, el estudiante procedió a realizar una primera identificación y marcado de dichos puntos en el conjunto de radiografías. Posteriormente, en la segunda fase, la especialista llevó a cabo una revisión minuciosa de los puntos etiquetados por el estudiante, realizando correcciones y ajustes cuando fue necesario. Para el marcado y revisión de los puntos se utilizó el software desarrollado para el proyecto. Esta rigurosa metodología de dos fases, que combina el estudio previo del método Bimler, la formación inicial, la identificación preliminar y la posterior validación por parte de un experto, garantizó la alta calidad y precisión del etiquetado de las radiografías cefalométricas, sentando una base sólida para el posterior análisis y desarrollo de modelos de inteligencia artificial.

4.2. Fase 2: Proceso de creación del dataset

En esta etapa, se recopiló el conjunto de archivos que contenían las etiquetas de los puntos cefalométricos, generadas mediante el software desarrollado para este proyecto. Estos archivos se complementaron con las respectivas radiografías cefalométricas asociadas. Posteriormente, se utilizó la plataforma Roboflow para consolidar y estructurar todos estos elementos, creando así el dataset final. Durante este proceso, se implementaron técnicas de aumento de datos, con el objetivo de enriquecer y diversificar el conjunto de imágenes disponibles. Esto se logró mediante la aplicación de transformaciones geométricas. El resultado fue un dataset listo para ser utilizado en el entrenamiento y evaluación de modelos de inteligencia artificial.

4.2.1. Actividad 1: Aprender el funcionamiento de plataformas como Roboflow para la implementación de modelos de IA

Se estudió la documentación necesaria para comprender los procesos de etiquetado de radiografías cefalométricas, creación de conjuntos de datos, construcción de modelos de inteligencia artificial y su implementación en la plataforma Roboflow. Este estudio previo permitió abordar cada etapa del proyecto con un entendimiento adecuado y siguiendo las mejores prácticas recomendadas.

4.2.2. Actividad 2: Realizar la creación del dataset con los puntos etiquetados anteriormente

Tras el estudio exhaustivo del material y los procesos necesarios, se procedió a crear diversas versiones del dataset en la plataforma Roboflow para el desarrollo de diversos modelos. Con cada nueva iteración, se incrementó progresivamente la cantidad de datos incorporados, enriqueciendo y ampliando el conjunto de imágenes y anotaciones disponibles.

4.2.3. Actividad 3: Evaluación del desempeño del modelo para determinar si es necesario aumentar el conjunto de entrenamiento

Se implementó un proceso de etiquetado continuo de radiografías cefalométricas, el cual se prolongó hasta alcanzar niveles de precisión satisfactorios. Este proceso iterativo permitió aumentar gradualmente la cantidad del etiquetado, garantizando que los puntos cefalométricos fueran identificados con un alto grado de exactitud. El objetivo establecido fue superar o igualar el umbral de precisión del 80 %, asegurando así que el conjunto de datos resultante cumpliera con los estándares de calidad requeridos para el posterior entrenamiento y evaluación de modelos de inteligencia artificial confiables.

4.3. Fase 3: selección del modelo de YOLO

Durante esta etapa, se seleccionó el modelo de aprendizaje profundo para la detección de los puntos cefalométricos de Bimler y se procedió con su entrenamiento. Para ello, se realizaron el entrenamiento y la evaluación de diferentes versiones de los modelos YOLOv8 y YOLOv9 con el objetivo de determinar cuál modelo presentaba mejor precisión.

4.3.1. Actividad 1: Realizar el estudio de diferentes modelos para el problema objetivo

Se realizó un estudio de la documentación técnica disponible para seleccionar las versiones más adecuadas del modelo YOLO para la tarea específica de detección de puntos cefalométricos. Tras analizar las características de cada variante, se eligieron las versiones YOLOv8 y YOLOv9 del algoritmo. Esta selección cuidadosa permitió realizar una evaluación comparativa, con el objetivo de determinar cuál de ellas demostraba un rendimiento superior y una mayor precisión en la tarea específica de identificación de puntos cefalométricos en radiografía.

4.3.2. Actividad 2: Recopilar y analizar el material bibliográfico sobre la implementación de los modelos

Una vez seleccionados los modelos a evaluar, se llevó a cabo el estudio del material y las herramientas necesarias para el entrenamiento de los mismos. Se analizaron detalladamente los jupyter notebooks, los cuales proporcionan un entorno interactivo y flexible para el desarrollo y experimentación con modelos de aprendizaje profundo. Estos notebooks contienen el código fuente, las instrucciones y las configuraciones requeridas para realizar el proceso de entrenamiento de manera efectiva.

Adicionalmente, se estudiaron a profundidad las capacidades y funcionalidades de la plataforma Roboflow, la cual sería utilizada para el despliegue de los modelos entrenados. Se examinaron las guías y documentación proporcionadas por Roboflow, con el fin de comprender los procedimientos necesarios para la implementación exitosa de los modelos.

4.3.3. Actividad 3: Implementar el modelo en la plataforma de desarrollo

Se realizó el proceso de entrenamiento y comparación de los modelos YOLO. Mediante la metodología de entrenamiento y validación con el conjunto de datos previamente preparado, se analizó detalladamente el rendimiento de cada uno de estos modelos en la identificación precisa de los puntos cefalométricos. Esta comparativa permitió determinar de forma objetiva cuál de estas variantes exhibía un desempeño superior en términos de precisión y confiabilidad, seleccionándola como la opción óptima para su implementación en el análisis cefalométrico automatizado.

4.4. Fase 4: Realización del software en Java 8

Se ha desarrollado un programa en Java 8 que permite la detección aproximada de los puntos de referencia de Bimler, lo cual facilita que el personal calificado utilice el modelo entrenado como ayuda diagnóstica. Además, el programa permite ajustar manualmente los puntos de referencia, guardarlos y generar un informe con el análisis de Bimler, junto con un archivo con las etiquetas de los puntos. De esta manera, se brinda una herramienta útil para el diagnóstico y seguimiento de pacientes, optimizando el proceso y respaldando la toma de decisiones odontológicas.

4.4.1. Actividad 1: Establecer las medidas y diagnósticos que se implementarán en el software

Se realizó un análisis de todas las medidas y diagnósticos contemplados en el análisis cefalométrico simplificado de Bimler, con el objetivo de implementarlos de manera precisa en el software desarrollado. Cada uno de los parámetros y criterios específicos propuestos por este enfoque cefalométrico fue cuidadosamente estudiado y trasladado al entorno de programación, asegurando una representación fiel y una interpretación correcta de los mismos.

4.4.2. Actividad 2: Realizar un mockup de la interfaz

En las etapas iniciales del proyecto, se elaboró un prototipo o mockup de la aplicación, el cual representaba de manera visual y conceptual las herramientas y funcionalidades que estarían presentes en el software final. Este mockup sirvió como una guía preliminar para plasmar las ideas y requerimientos iniciales, permitiendo explorar y refinar la interfaz de usuario, la disposición de los elementos, los flujos de trabajo y las interacciones que los usuarios tendrían con la aplicación. El desarrollo de este prototipo temprano proporcionó una referencia tangible para facilitar la comunicación y la validación de los conceptos con los diferentes stakeholders involucrados en el proyecto. Además, permitió identificar y abordar de manera temprana cualquier desafío potencial en términos de usabilidad, accesibilidad y experiencia de usuario, antes de avanzar con las etapas posteriores de desarrollo e implementación.

4.4.3. Actividad 3: Recopilar y analizar el material bibliográfico de Java 8 para el diseño de interfaz

Se llevó a cabo un análisis de las diversas librerías disponibles en Java 8 para el diseño de interfaces gráficas de usuario (GUI). Se evaluó en detalle Java Swing, una librería consolidada que ofrece una amplia gama de componentes visuales, como botones, menús, paneles y otros elementos, lo que permite crear interfaces intuitivas y atractivas para el usuario final.

Esta revisión rigurosa de las opciones disponibles tuvo como objetivo seleccionar la librería o marco de trabajo más adecuado para el diseño y construcción de una interfaz de usuario amigable, eficiente y visualmente atractiva, que cumpla con los requisitos específicos del software de análisis cefalométrico automatizado.

4.4.4. Actividad 4: Realizar la programación de mockup

Se llevó a cabo la implementación de los componentes gráficos necesarios para obtener la interfaz de usuario deseada. Se seleccionaron y configuraron cuidadosamente los elementos visuales, como botones, paneles, menús y otros controles. Cada componente se integró de manera armoniosa y coherente, creando una interfaz intuitiva y atractiva para facilitar la interacción del usuario con el software.

4.4.5. Actividad 5: Implementar las funcionalidades establecidas

Se llevó a cabo la implementación de las funcionalidades correspondientes a las herramientas del software de análisis cefalométrico en Java. Cada una de estas herramientas fue desarrollada con meticulosidad, integrando las bibliotecas y algoritmos necesarios para cumplir con los requisitos y objetivos establecidos.

Se prestó especial atención a garantizar que las herramientas fueran precisas y, al mismo tiempo, fáciles de utilizar para el usuario final. Además, se enfatizó en brindar una experiencia fluida y productiva al usuario, mediante una interfaz intuitiva y una implementación optimizada de las funcionalidades.

4.5. Fase 5: validación del modelo y el software

El software desarrollado, incluyendo la implementación del modelo de inteligencia artificial para el análisis cefalométrico, fue sometido a un proceso de validación llevado a cabo por una especialista en odontopediatría y ortopedia maxilar de la Facultad de Odontología de la Universidad de Antioquia (UDEA). Esta etapa de validación fue fundamental para garantizar la calidad, precisión y confiabilidad del sistema.

Durante este proceso, la especialista evaluó cada uno de los componentes y funcionalidades del software, verificando que los cálculos, mediciones y diagnósticos generados estuvieran alineados con los estándares y mejores prácticas en el análisis cefalométrico. Además, se prestó especial atención a la integración del modelo de inteligencia artificial, asegurando que su desempeño en la detección de puntos cefalométricos fuera eficiente.

4.5.1. Actividad 1: Validar la utilidad del software para la detección de los puntos de referencia

La especialista en odontopediatria y ortopedia maxilar llevó a cabo la evaluación del correcto funcionamiento del modelo de inteligencia artificial integrado en el software. Se analizó el desempeño del modelo en la tarea de detección de los puntos cefalométricos, verificando que su precisión y confiabilidad cumplieran con los estándares clínicos exigidos, para estos además se realizó la medición de las métricas MRE, SD y SDR.

Asimismo, se examinaron los resultados obtenidos por el sistema, incluyendo las mediciones, cálculos y diagnósticos generados a partir del análisis cefalométrico automatizado. Esta revisión por parte de la experta en el campo permitió validar la integridad, exactitud y coherencia de los datos arrojados por el software.

5 Resultados y Análisis

5.1. Métricas identificadas

Las métricas MRE, SD y SDR son muy útiles para medir y evaluar los resultados obtenidos en la identificación automática de puntos cefalométricos en radiografías. Permiten cuantificar de manera objetiva el rendimiento y la precisión del método propuesto. El MRE mide el error promedio en la localización de los puntos cefalométricos identificados por el modelo, con respecto a las ubicaciones manuales dadas por la experta, el SD indica qué tan dispersos están los errores radiales individuales con respecto al valor medio MRE y el SDR representa el porcentaje de puntos cefalométricos que fueron identificados correctamente dentro de un umbral de error especificado.

5.2. Conjunto de imágenes

El conjunto de datos empleado consistió en un total de 148 radiografías cefalométricas, divididas en tres subconjuntos: entrenamiento, prueba y validación. Específicamente, se utilizaron 120 imágenes para entrenar el modelo, 19 imágenes para evaluar su desempeño durante las pruebas y 9 imágenes para la validación final. Todas las radiografías tenían un tamaño original de 1935 x 2400 píxeles, con un tamaño de píxel de 0.1 x 0.1 milímetros. Estas imágenes fueron previamente marcadas por un especialista, quien identificó manualmente los 20 puntos cefalométricos relevantes en cada una. Antes de su procesamiento, se realizó un ajuste de contraste en las imágenes marcadas para mejorar la calidad y facilitar la identificación de características. Posteriormente, se aplicó una técnica de aumento de datos mediante el reflejo de las imágenes, lo que duplicó el número total de muestras disponibles. Finalmente, las imágenes fueron redimensionadas a un tamaño de 640 x 640 píxeles, para el entrenamiento del modelo utilizado.

5.3. Análisis de los errores radiales

Después de desarrollar y desplegar el modelo, se realizaron predicciones de los puntos de referencia cefalométricos sobre el conjunto de radiografías de prueba. Esta evaluación permitió

verificar la precisión en la ubicación de dichos puntos. La Tabla 5-1 muestra el error radial medio (MRE) y la desviación estándar (SD) promedio obtenidos para los veinte puntos cefalométricos identificados.

Cuadro 5-1: Errores radiales de los puntos de referencia. [7]

Punto	MRE (mm)	SD (mm)
Cls	1.439812	0.903165
C	1.046044	0.471043
Cm	6.144785	4.209443
Cli	1.593217	1.278824
Gn	0.596410	0.359873
B	0.959468	0.533380
No	1.693468	1.433723
M	0.722894	0.416074
T'	1.824790	1.221306
S	0.660613	0.427050
AP	1.571852	1.155804
A	0.908914	0.619044
Go	1.739048	1.021043
Me	1.111239	0.752543
Cd	1.172609	0.574888
Or	1.316685	0.700476
ENP	1.140292	0.656383
N	1.337183	0.914387
Po	1.404117	0.954317
ENA	1.373201	0.881326
Promedio	1.487832	0.974205

Se observa que el modelo obtuvo un MRE y un SD que en la mayoría de los casos, no superaron los 2 mm y los 1.9 mm respectivamente. Sin embargo, se puede apreciar que, entre los veinte puntos cefalométricos identificados, el punto Cm destaca por tener un MRE considerablemente más alto que el resto, con un valor de 6.144785 mm, mientras que el MRE medio fue de 1.487832 mm. Asimismo, el punto Cm presentó una desviación estándar de 4.209443 mm, notablemente superior a la SD media de 0.974205 mm. Esta mayor dificultad en la identificación precisa del punto Cm podría atribuirse a que, a diferencia de otros puntos que dependen directamente de estructuras craneales o dentales, la ubicación de Cm se deriva del punto de referencia C y de la curva de oclusión de molares y premolares, lo que introduce una mayor complejidad para el modelo.

5.4. Análisis de la tasa de detección exitosa

Tras calcular los errores radiales para cada radiografía del conjunto de prueba, se evaluó la tasa de detección exitosa (SDR). Esta métrica permitió cuantificar el porcentaje de puntos cefalométricos localizados correctamente dentro de diferentes umbrales de error. La Tabla 5-2 presenta los valores de SDR obtenidos para umbrales de 2, 3, 4 y 5 milímetros, considerando los veinte puntos cefalométricos identificados por el modelo propuesto.

Cuadro 5-2: Tasas de detección exitosa.

Punto	SDR (%)			
	2mm	3mm	4mm	5mm
M	100	100	100	100
ENA	81.578947	94.736842	100	100
AP	73.684211	89.473684	94.736842	100
N	81.578947	89.473684	100	100
S	97.368421	100	100	100
Or	84.210526	100	100	100
Me	84.210526	97.368421	100	100
Go	68.421053	89.473684	97.368421	97.368421
Gn	100	100	100	100
ENP	84.210526	100	100	100
B	94.736842	100	100	100
Cd	86.842105	100	100	100
A	94.736842	100	100	100
T'	65.789474	84.210526	89.473684	100
Po	76.315789	92.105263	100	100
Cm	15.789474	26.315789	39.473684	44.736842
No	73.684211	81.578947	89.473684	97.368421
C	97.368421	100	100	100
Cls	76.315789	92.105263	100	100
Cli	65.789474	84.210526	92.105263	100
Promedio	80.13158	91.052632	95.131579	96.973684

Se observa que el modelo logró una tasa de detección exitosa (SDR) superior al 70% en la mayoría de los casos. No obstante, se aprecia que el punto Cm presenta un SDR notablemente inferior al resto, con un valor de 15.789474% para el umbral de 2 mm, mientras que la SDR media fue de 80.13158%. Esta dificultad adicional en la identificación precisa del punto Cm podría atribuirse nuevamente a que su ubicación se deriva del punto de referencia C y de la curva de oclusión de molares y premolares, lo cual introduce una mayor complejidad para el modelo en comparación con otros puntos cefalométricos que dependen directamente de estructuras craneales o dentales.

5.5. Inferencias del modelo

La Figura 5-1 presenta una muestra representativa del conjunto de imágenes empleado para el entrenamiento y evaluación del modelo propuesto. En dicha figura, se encuentran etiquetados los puntos de referencia sobre la radiografía. Adicionalmente, la Tabla 5-3 detalla el nombre de cada uno de los puntos cefalométricos identificados, correspondientes a las etiquetas numéricas mostradas en la imagen.

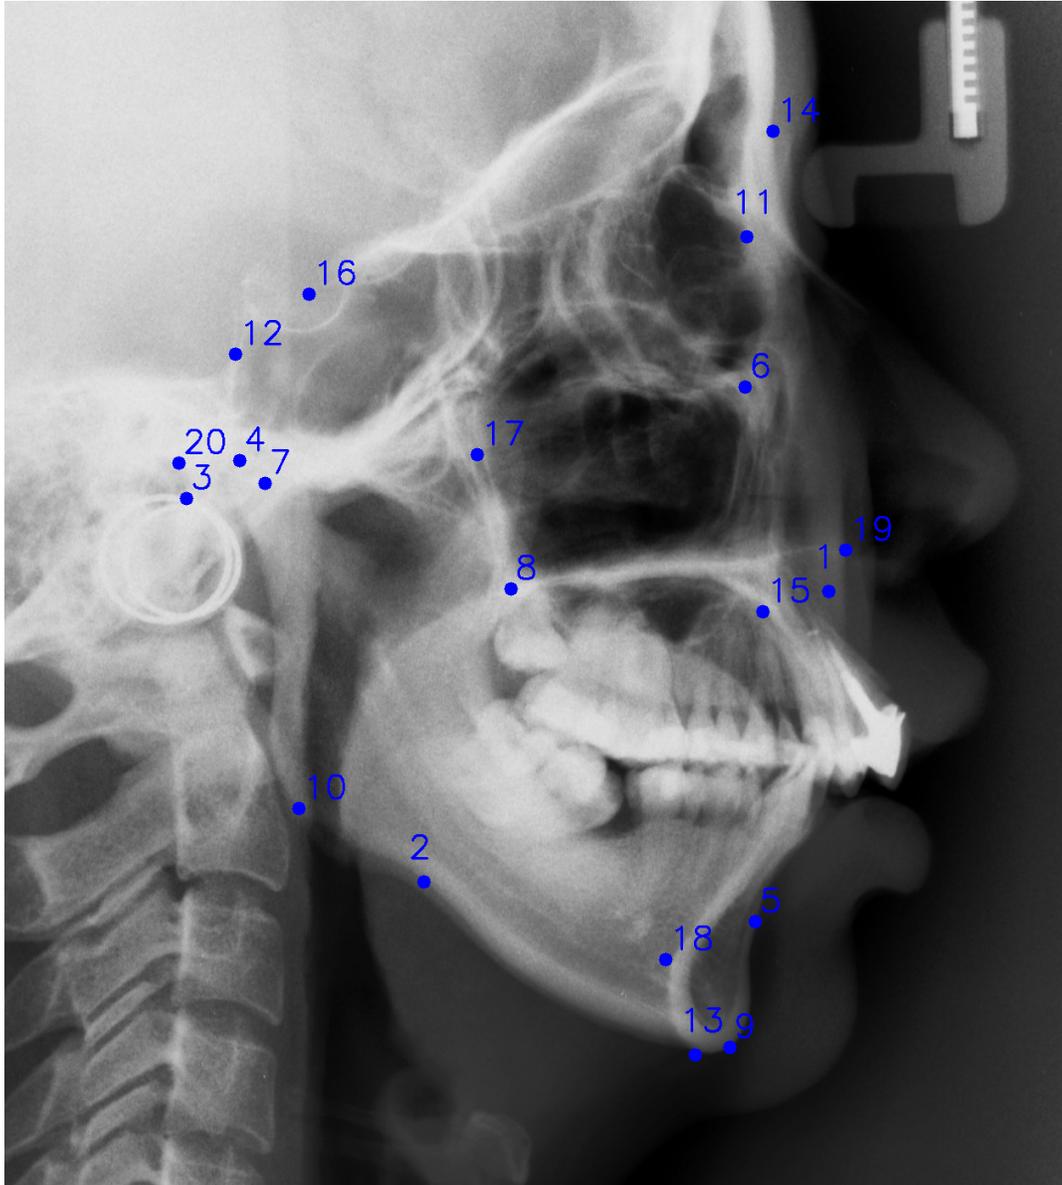


Figura 5-1: Radiografía etiquetada con los puntos de referencia.

Cuadro 5-3: Lista de Puntos de Referencia

No.	Punto	No.	Punto
1	A	11	Cm
2	No	12	Cls
3	Cli	13	M
4	Cd	14	N
5	B	15	AP
6	Or	16	S
7	C	17	T'
8	ENP	18	Me
9	Gn	19	ENA
10	Go	20	Po

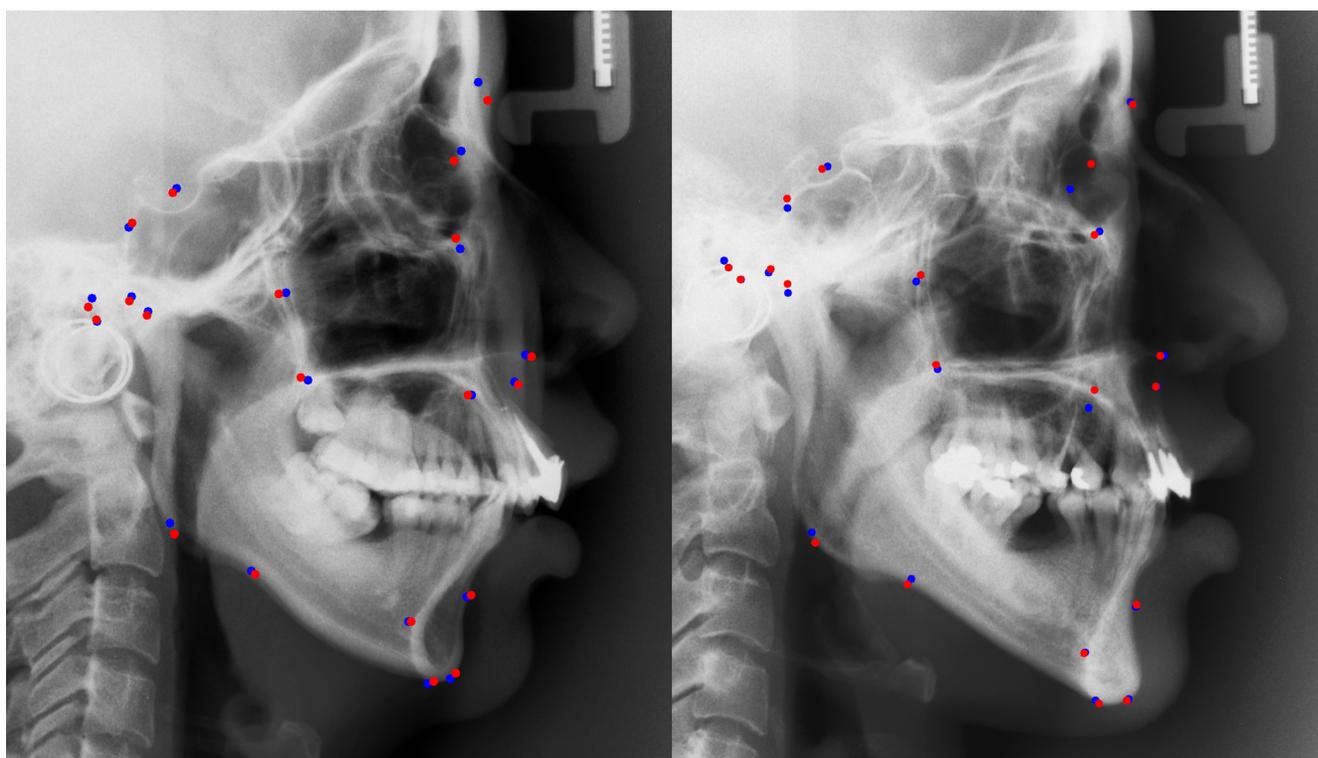


Figura 5-2: Ejemplo de identificación de puntos de referencia: ubicaciones determinadas por una especialista (azul) y por el modelo (rojo).

La Figura 5-2 ilustra un ejemplo de las ubicaciones calculadas por el modelo junto con las calculadas por la experta. En estas imágenes, los puntos cefalométricos marcados manualmente por una experta se encuentran etiquetados en color azul, mientras que las predicciones del modelo para la localización de dichos puntos se representan en color rojo. Esto permite visualizar y comparar directamente la precisión del modelo en la identificación de los puntos de referencia.

5.6. Software desarrollado

El software desarrollado, denominado DIACEFAL, es una herramienta diseñada para realizar análisis cefalométricos automatizados en radiografías craneofaciales laterales, utilizando la metodología propuesta por BIMLER. Este software emplea un modelo de DL para detectar de manera aproximada la ubicación de los puntos de referencia cefalométricos. Además, DIACEFAL cuenta con un panel de ajuste manual que permite al usuario refinar la posición de dichos puntos. La aplicación también incorpora una interfaz gráfica que facilita la visualización e interpretación de los resultados del análisis cefalométrico.

La figura 5-3 muestra una primera vista del panel de ajuste manual, el cual brinda la capacidad de modificar la ubicación de los puntos de referencia mediante el uso del ratón. Este panel está provisto de diversas herramientas, como la opción para aumentar y disminuir el tamaño de la imagen, un transportador con varios radios, una regla en forma de circunferencia y otra para dibujar una recta en el ángulo medio entre dos rectas definidas por la regla. Además, permite la visualización de los resultados del análisis mientras se realizan ajustes.

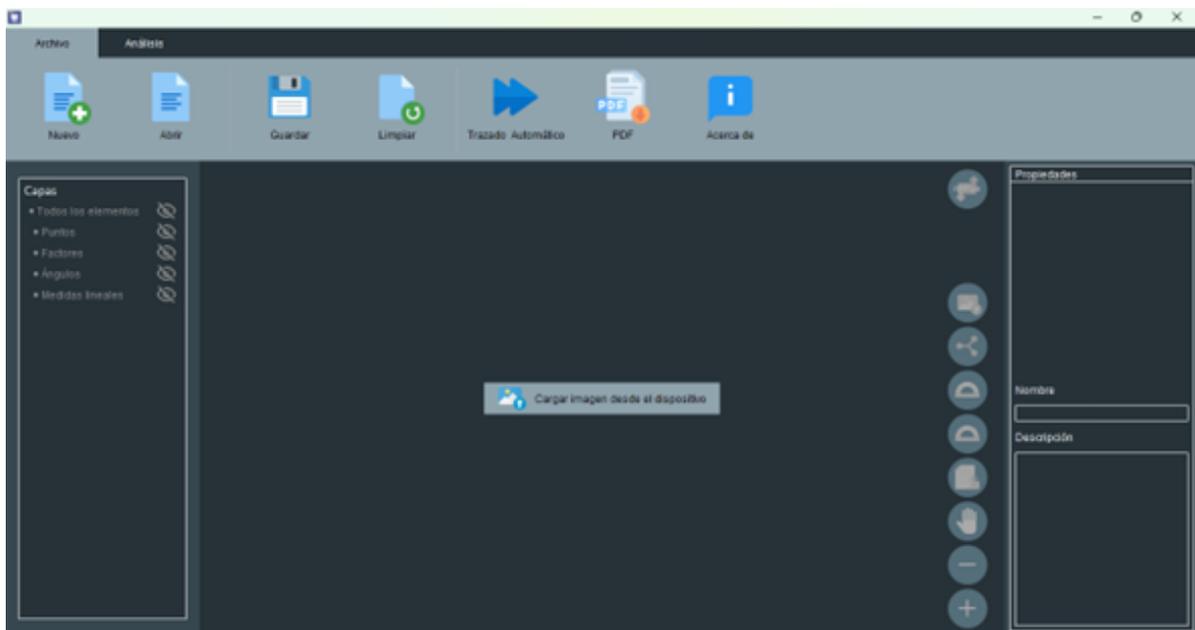


Figura 5-3: Interfaz principal DIACEFAL.

La figura 5-4 muestra una primera vista de la interfaz de visualización de resultados del análisis, la cual presenta los datos de manera organizada en diversas tablas, que incluyen factores, medidas angulares, medidas lineales e índices. Además, brinda la capacidad de guardar la información del paciente, como su nombre, edad y la fecha del análisis. Además, el software ofrece la opción de generar un informe del análisis en formato PDF, así como de guardar y cargar el estado de un análisis previo.

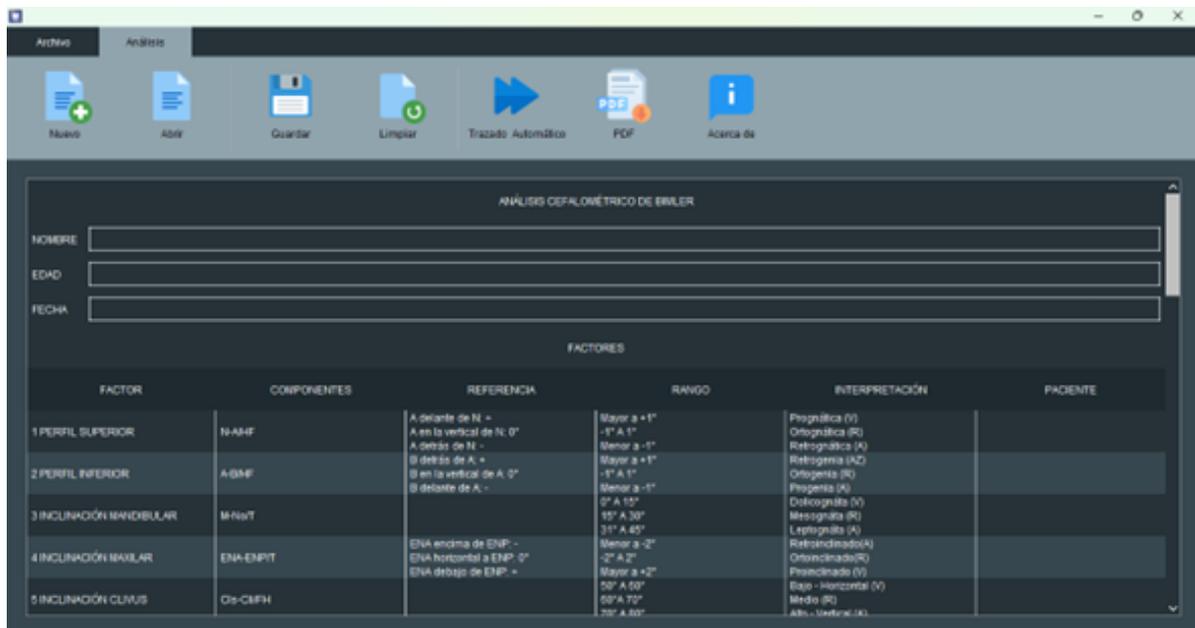


Figura 5-4: Segunda Interfaz DIACEFAL.

5.7. Interfaz de la barra de opciones

La figura 5-5 muestra la composición de la barra de opciones, la cual ofrece varias funcionalidades. Primero, se encuentra el botón “Nuevo” que permite crear un nuevo proyecto para así poder guardar el estado de un análisis en curso. A continuación, se dispone del botón “Abrir” para abrir proyectos guardados y otro botón “Guardar” para guardar el estado del proyecto actual. Además, se incluye el botón “Limpiar” destinado a eliminar el análisis actual. También se encuentra disponible el botón “Trazado Automático” para realizar un posicionamiento aproximado de los puntos de referencia de manera automática. Asimismo, se ofrece la opción de guardar el estado del análisis en formato PDF mediante el botón “PDF”. Finalmente, se presenta el botón “Acerca de” que despliega una ventana para dar crédito a las personas que contribuyeron al proyecto.

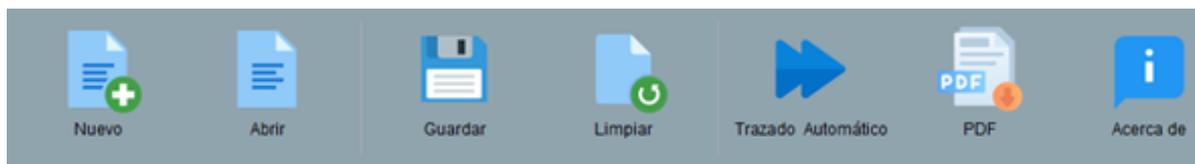


Figura 5-5: Interfaz de la barra de opciones.

5.8. Interfaz del panel de ajuste manual

La Figura 5-6 ilustra la composición del panel de ajuste manual, el cual está dividido en tres secciones principales. En primer lugar, se encuentra el panel de selección de capas, el cual permite elegir qué datos del análisis se desean visualizar en el panel central. Las opciones incluyen mostrar todos los elementos del análisis, los puntos de referencia, los valores de los factores, los ángulos y las medidas lineales. En el panel central, se muestra la radiografía junto con los datos seleccionados en el panel de selección de capas. Además, este panel incluye un conjunto de herramientas que permiten realizar diversas acciones, como calcular la escala de la radiografía, cargar una nueva radiografía, utilizar una regla que dibuja una recta en el ángulo medio entre dos rectas definidas por la regla, usar la regla con forma circular y la regla con forma de transportador, bloquear el reposicionamiento de los puntos de referencia, mover la radiografía, y ajustar el tamaño de la imagen. Por último, se encuentra un panel destinado a visualizar las características de los puntos de referencia, en este panel, se puede ver una imagen de la ubicación de cada punto, su nombre y una breve descripción.

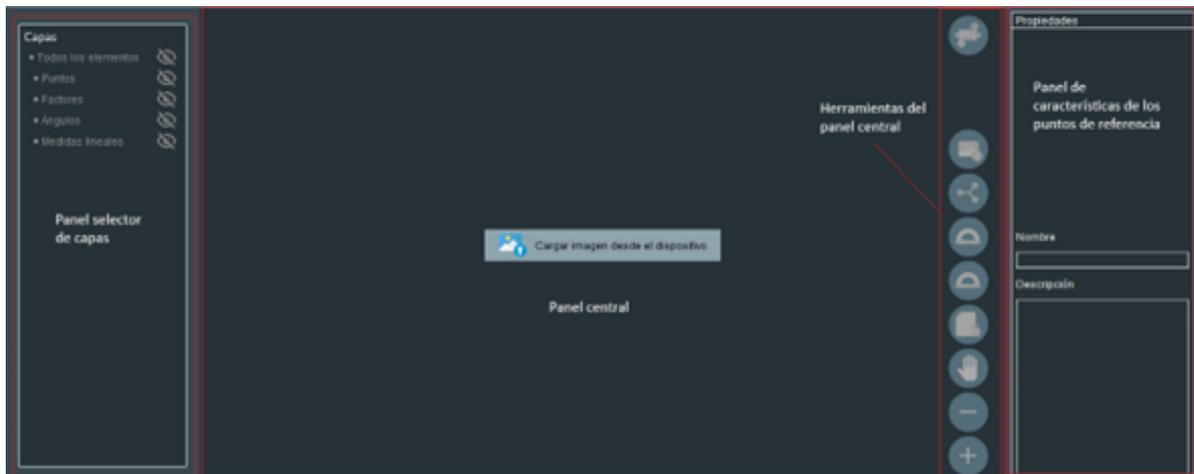


Figura 5-6: Composición del panel de ajuste manual.

5.8.1. Panel de selección de capas

La figura 5-7 muestra el panel de selección de capas, el cual permite elegir qué datos del análisis se desea visualizar en el panel central, para esto cuenta con un conjunto de cinco etiquetas que permite mostrar o esconder un conjunto de datos del análisis, La primera opción permite mostrar todos los elementos del análisis, la cual muestra la información relacionada a las cuatro capas siguientes, la segunda opción permite mostrar o ocultar los puntos de referencia sobre la radiografía, la tercera opción permite mostrar los datos correspondientes a los factores, la cuarta

opción permite mostrar los datos relacionados a los ángulos y la quita opción permite mostrar los datos relacionados a las medidas lineales.

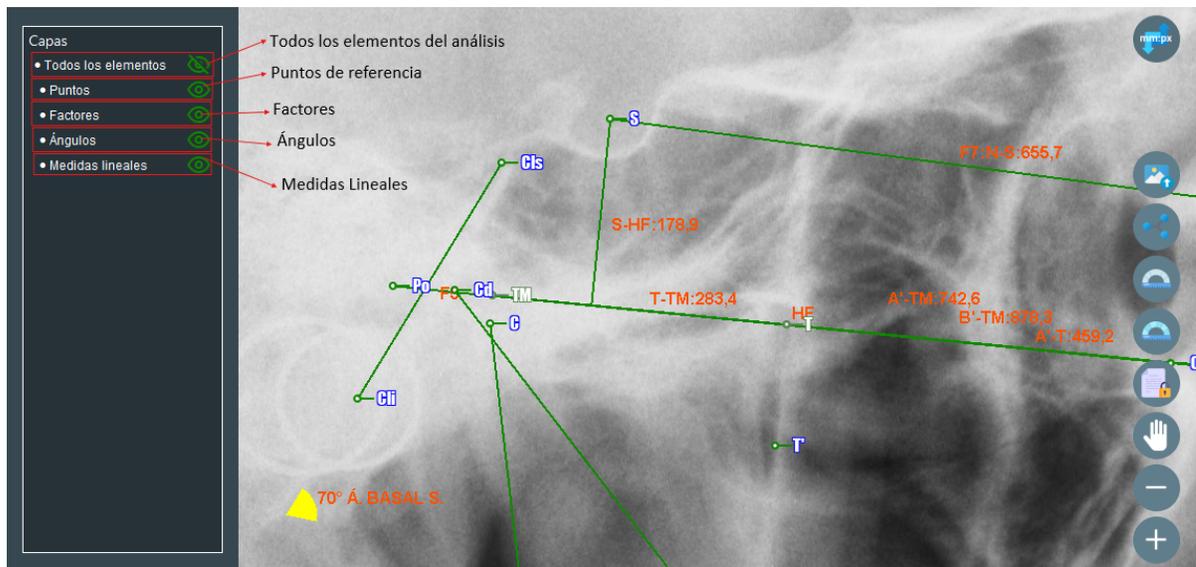


Figura 5-7: Panel de selección de capas.

5.8.2. Panel de central

La figura 5-8 muestra el panel central, el cual tiene como función principal mostrar tanto la radiografía como los datos del análisis seleccionados en el panel de selección de capas, para esto la interfaz inicial cuenta con una etiqueta inicial que permite cargar la radiografía. Este panel cuenta con las herramientas de calcular la escala de la radiografía en la cual al presionar el botón de nueva escala se deberá seleccionar dos puntos de la radiografía para posteriormente ingresar el valor en mm al que corresponde esa distancia en la radiografía, también se cuenta con la herramienta de cargar una nueva radiografía, cuya función es cambiar la radiografía actual por una nueva, también se puede utilizar tres tipos de reglas, la primera regla corresponde a la de ángulo medio, la cual permite dibujar una recta en el ángulo medio de dos rectas definidas a través de los tres puntos con los que cuenta la regla, uno central y dos puntos extremos de las rectas. La segunda regla presenta forma circular y tiene como función ser un soporte visual para identificar los puntos relacionados con estructuras de forma parcialmente circular, y la tercera regla cuenta con forma de transportador y tiene como función principal servir de apoyo para identificar el centro de la curva de oclusión que pasa por los molares y premolares y el punto C, también se cuenta con una herramienta para bloquear el reposicionamiento de los puntos de referencia una vez que se tiene certeza de su correcta ubicación. También se cuenta con un botón que activa o desactiva el desplazamiento de la radiografía en el panel central, y por último se cuenta con dos botones cuya función es la de aumentar o disminuir el tamaño de la radiografía.

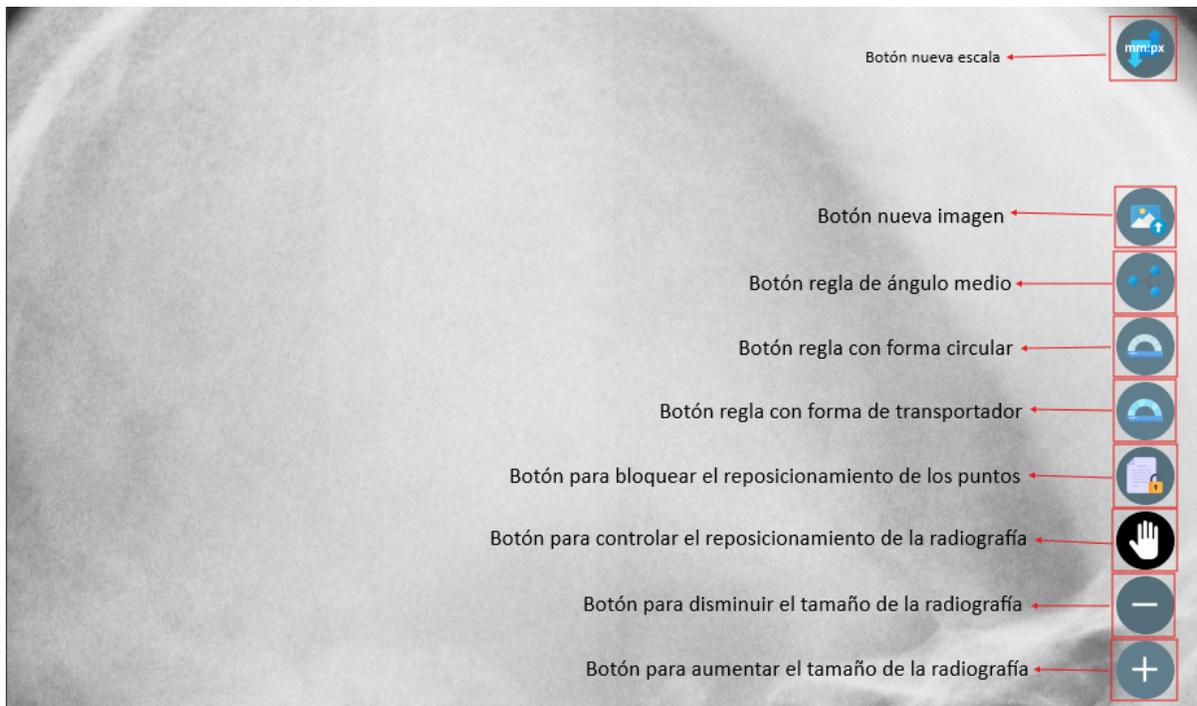


Figura 5-8: Panel de central.

5.8.3. Panel de características de los puntos de referencia

La figura 5-9 muestra el panel de características, el cual tiene como propósito mostrar las características de los puntos de referencia del análisis de BIMLER. Al seleccionar un punto de referencia en el panel central, este panel se actualiza para mostrar los datos correspondientes a dicho punto. Consta de una imagen de ejemplo que muestra la ubicación del punto en la radiografía, el nombre del punto y una breve descripción.

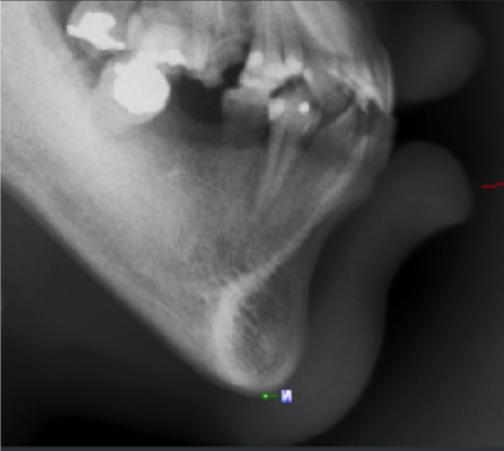
Propiedades	
	Imagen Ejemplo
Nombre <input type="text" value="MENTONIANO (M)"/>	Nombre del punto
Descripción <input type="text" value="Punto más inferior del contorno del mentón"/>	Breve descripción

Figura 5-9: Panel de características.

5.9. Interfaz del panel de visualización del análisis

La figura 5-10 muestra la composición del panel de visualización, el cual está dividido en dos secciones principales. En primer lugar, se encuentra el panel de ingreso de datos, el cual permite ingresar los datos del paciente como nombre y edad, además también se cuenta con un campo para ingresar la fecha del análisis, para ayudar a llevar un registro del paciente. Además, se cuenta con un conjunto de tablas para visualizar los datos del análisis.

FACTOR	COMPONENTES	REFERENCIA	RANGO	INTERPRETACIÓN	PACIENTE
1 PERFIL SUPERIOR	N-AHF	A delante de N - A en la vertical de N 0° A detrás de N -	Mayor a +1° -1° A 1° Menor a -1° Mayor a +1° -1° A 1°	Prognática (V) Ortogónica (R) Retrógnica (A)	
2 PERFIL INFERIOR	A-BHF	B detrás de A + B en la vertical de A 0° B delante de A -	Mayor a +1° -1° A 1° Menor a -1°	Retrógnica (A2) Ortogena (R) Prognia (A)	
3 INCLINACIÓN MANDIBULAR	M-NuT		0° A 15° 15° A 30° 31° A 45°	Dicognática (V) Mesognática (R) Leptognática (A)	
4 INCLINACIÓN MAXILAR	ENA-ENPYT	ENA encima de ENP - ENA horizontal a ENP 0° ENA debajo de ENP +	Menor a -2° -2° A 2° Mayor a +2°	Retrorclinado(R) Ortoclinado(R) Proclinado (V)	
5 INCLINACIÓN CLIVUS	Os-CBFH		50° A 60° 60° A 70° 70° A 80°	Bajo - Horizontal (V) Medio (R) Alto - Vertical (A)	

Figura 5-10: Interfaz del panel de visualización del análisis.

El panel de visualización de datos cuenta con cuatro tablas: la tabla de factores, que se muestra en la figura 5-11; la tabla de ángulos, detallada en la figura 5-12; la tabla de medidas lineales, mostrada en la figura 5-13; y la tabla de índices, exhibida en la figura 5-14.

FACTOR	COMPONENTES	REFERENCIA	RANGO	INTERPRETACIÓN	PACIENTE
1 PERFIL SUPERIOR	N-AHF	A delante de N - A en la vertical de N 0° A detrás de N -	Mayor a +1° -1° A 1° Menor a -1° Mayor a +1° -1° A 1°	Prognática (V) Ortogónica (R) Retrógnica (A)	
2 PERFIL INFERIOR	A-BHF	B detrás de A + B en la vertical de A 0° B delante de A -	Mayor a +1° -1° A 1° Menor a -1°	Retrógnica (A2) Ortogena (R) Prognia (A)	
3 INCLINACIÓN MANDIBULAR	M-NuT		0° A 15° 15° A 30° 31° A 45°	Dicognática (V) Mesognática (R) Leptognática (A)	
4 INCLINACIÓN MAXILAR	ENA-ENPYT	ENA encima de ENP - ENA horizontal a ENP 0° ENA debajo de ENP +	Menor a -2° -2° A 2° Mayor a +2°	Retrorclinado(R) Ortoclinado(R) Proclinado (V)	
5 INCLINACIÓN CLIVUS	Os-CBFH		50° A 60° 60° A 70° 70° A 80°	Bajo - Horizontal (V) Medio (R) Alto - Vertical (A)	
6 CLASIFICACIÓN CORRELATIVA	On-Me (Eje stress)Ap	Eje stress detrás de Ap Eje stress pasa por Ap Eje stress delante de Ap	Menor a -2° -2° A 2° Mayor a +2°	Prognática (A2) Periapical (R) Pretiapical (A)	
7 INCLINACIÓN BASE DE CRÁNEO	S-NT		0° A 6° 6° A 8° 8° A 14°	Baja/Profunda - Horizontal (V) Medio - Neutro (R) Alta/Larga - Vertical (A)	
8 FLEXIÓN DE LA RAMA	C-GoTM	Go detrás de C - Go vertical a C 0° Go delante de C +	Menor a 0° 0° A 6° Mayor a 6°	Hipoflexión (A) Ortoflexión (R) Hiperflexión (V)	

Figura 5-11: Interfaz de la tabla de factores.

ÁNGULOS				
MEDIDAS ANGULARES	COMPONENTES/REFERENCIA	RANGO	INTERPRETACIÓN	PACIENTE
PERFIL ESQUELÉTICO	F1+F2	Mayor a 1° + -1° A 1° Menor de -1° -	Convexo (AZ) Recto (R) Cóncavo (A)	
ÁNGULO BASAL SUPERIOR	F4+F5	50° a 60° 60° a 70° 70° a 80°	Profundo/Dolicocepro - Horizontal (V) Mesodolicocepro - Neutral (R) Largo/Leptoprosope - Vertical (A)	
ÁNGULO BASAL INFERIOR	F3+F4 (si F4 es positivo se resta, si F4 es negativo se suma)	0° a 15° 15° a 30° 30° a 45°	Profundo/D - Horizontal (V) Mediano/M - Neutral (R) Largo/L - Vertical (A)	
ÁNGULO GOMIADO	F3+F8+90°	80° a 105° 105° a 120° 120° a 135°	Dolico gnata (V) Mesognata (R) Leptognata (A)	

Figura 5-12: Interfaz de la tabla de ángulos.

MEDIDAS LINEALES				
MEDIDAS LINEARES	COMPONENTES	RANGO	INTERPRETACIÓN	PACIENTE
TAMAÑO MAXILAR	A-T	44 a 47 48 a 52 53 a 56	Pequeña (A) Mediana (R) Grande (V)	
RESALTE ÓSEO	A-B'	Menor de 0 0 a 10 Mayor de 10	Clase III (A) Clase I (R) Clase II (AZ)	
PROFUNDIDAD FACIAL	A-TM	Menor de 77 77 a 83 Mayor de 83	Pequeña Mediana Grande	
CUERPO MANDIBULAR	B-TM	Menor de 76 76 a 80 Mayor de 80	Pequeña Mediana Grande	
POSICIÓN ATM	T-TM	24 a 28 28 a 32 32 a 36	Pequeña (A) Mediana (R) Grande (V)	
BASE CRANIAL	N-S	Menor de 60 60 a 80 Mayor de 80	Corta Mediana Larga	
DIAGONAL MANDIBULAR	C3-C6	80 a 100 100 a 120 120 a 140	Pequeña (A) Mediana (R) Grande (V)	
ALTURA SUBORBITAL	M-HF	Menor de 75 75 a 80 Mayor de 80	Pequeña Mediana Grande	
ALTURA SILLA	S-HF	Menor de 18 18 a 22 Mayor de 22	Pequeña Mediana Grande	
ALTURA NASION	N-HF	Menor de 25 25 a 31 Mayor de 31	Bajo Medio Alto	
ALTURA TOTAL	N-M	Menor de 115 115 a 125 Mayor de 125	Pequeña Mediana Grande	
ÍNDICE FACIAL	Altura Facial suborbital- Profundidad facial	Altura menor a profundidad (-) Altura mayor que profundidad 0-5 Altura Mayor que profundidad mayor a 5	Dolicocefálico(V) Mesoprosope(R) Leptoprosope(A)	

NOTA: En paréntesis se encuentra el valor si se magnificara por 10 las medidas longitudinales

Figura 5-13: Interfaz de la tabla de medidas lineales.

ÍNDICES				
ÍNDICES	COMPONENTES	RANGO	INTERPRETACIÓN	PACIENTE
OOI	90 - ángulo basal inferior + factor 2	Menor a 69° 69° a 77° Mayor a 77°	Morfo abierta Normal Morfo profunda	

Figura 5-14: Interfaz de la tabla de índices.

5.10. Trabajos a Futuro

En este trabajo, se abordó una propuesta para desarrollar un sistema de soporte que facilite la realización de análisis cefalométricos mediante el método de BIMLER, con el objetivo de reducir la carga de trabajo de los especialistas. Sin embargo, se identificaron algunas áreas de interés y recomendaciones para futuras investigaciones en este campo:

- **Ampliación del conjunto de datos:** Tras analizar la precisión en la ubicación de los puntos, se observó una baja precisión al detectar el punto de referencia C_m . Por lo tanto, un aumento del conjunto de datos podría mejorar la capacidad del modelo para localizar este punto con mayor exactitud.
- **Nuevos Análisis:** Incorporación de medidas dentales y de nuevos análisis de otros autores que permitan hacer comparaciones de diagnóstico.
- **Cálculo indirecto de C_m :** Para evitar la complejidad adicional que presentan los modelos al calcular C_m , se podría utilizar dos puntos de referencia auxiliares ubicados sobre la curva de oclusión, el primero entre los molares y el segundo entre los premolares. Estos puntos auxiliares podrían representar una menor complejidad para el modelo. Posteriormente, con las posiciones de los dos puntos auxiliares y del punto de referencia C , se puede calcular el centro de la circunferencia que pasa por estos tres puntos, el cual corresponde a C_m .
- **Implementación de un sistema de comparación de análisis:** Para aumentar la funcionalidad del software, se podría desarrollar una funcionalidad que permita comparar diferentes análisis, brindando la capacidad de analizar la evolución de los pacientes a lo largo del tiempo.
- **Implementar herramientas de procesamiento de imágenes:** Desarrollar herramientas que permitan mejorar la calidad de las imágenes, como el ajuste del contraste o resaltar las estructuras craneofaciales en las radiografías, esto podría ser beneficioso para el análisis cefalométrico.

6 CONCLUSIONES

1. La implementación y evaluación del modelo de aprendizaje profundo (DL) en el contexto del análisis cefalométrico demuestra cómo las técnicas de inteligencia artificial pueden aprovecharse para aliviar la carga de trabajo de los especialistas en este campo. Al automatizar parcialmente el proceso de identificación de puntos de referencia cefalométricos.
2. El algoritmo YOLOv8 demuestra una alta eficacia y facilidad de entrenamiento para la tarea específica de detección de puntos de referencia craneodentales en radiografías cefalométricas. Los resultados obtenidos indican que este enfoque basado en aprendizaje profundo es capaz de localizar con precisión los puntos cefalométricos.
3. Los resultados obtenidos en este trabajo resaltan la complejidad inherente en la localización precisa del punto cefalométrico Cm utilizando técnicas de aprendizaje profundo. A diferencia de otros puntos de referencia que dependen directamente de estructuras craneales o dentales bien definidas, la ubicación de Cm se deriva indirectamente de la curva de oclusión de molares y premolares, así como de la posición del punto C. Esta dependencia de características y la falta de una correspondencia directa con estructuras anatómicas evidentes, introduce un desafío adicional para los modelos de aprendizaje automático.
4. Las métricas elegidas en este trabajo, como el error radial medio (MRE), la desviación estándar (SD) y la tasa de detección exitosa (SDR), son esenciales para cuantificar de manera objetiva la precisión y confiabilidad de los modelos en la identificación de puntos cefalométricos. Estas medidas brindan información valiosa sobre la capacidad de los algoritmos para localizar correctamente los puntos de referencia dentro de umbrales de error aceptables.
5. El software DIACEFAL, desarrollado en el marco de este trabajo, representa un avance en la automatización del análisis cefalométrico. Al integrar modelos de aprendizaje profundo y herramientas de procesamiento de imágenes, esta aplicación logra identificar con precisión 19 de los 20 puntos de referencia cefalométricos en radiografías craneales laterales, reduciendo así la carga de trabajo manual para los especialistas.
6. El sistema desarrollado en este trabajo, compuesto por un modelo de aprendizaje profundo y el software DIACEFAL, representa un avance en la automatización y optimización del análisis cefalométrico. Al combinar la potencia de las técnicas de inteligencia artificial con una interfaz intuitiva y herramientas de procesamiento de imágenes, esta solución integral aborda diversos desafíos que enfrentan los especialistas en este campo.

7. La capacidad del modelo para adaptarse y mejorar con datos adicionales sugiere que su precisión continuará aumentando. Esto implica un potencial significativo para la evolución continua del sistema mediante la integración de nuevos datos.



PRACTICANTE: Sebastián González Herrera

ASESORES: David Stephen Fernández Mc Cann
Elizabeth Llano Sánchez

PROGRAMA: Ingeniería Electrónica

Semestre de la práctica: 2023-2

Este trabajo se enfocó en desarrollar un programa que, utilizando técnicas de aprendizaje profundo, permita la detección automática de los 20 puntos de referencia definidos en el análisis cefalométrico de Bimler. Además, el programa es capaz de medir y calcular los valores del análisis, incluyendo factores, ángulos y medidas lineales.



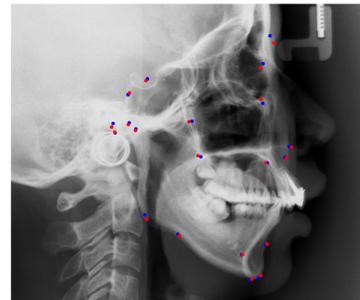
Este tipo de análisis son herramientas cruciales para el diagnóstico, planificación y seguimiento de tratamientos de ortodoncia, ortopedia y odontopediatría.



Introducción

El análisis cefalométrico se ha consolidado como una herramienta esencial en los diagnósticos craneofaciales, permitiendo la medición precisa de factores lineales y angulares en imágenes cefalométricas. Sin embargo, la identificación manual de puntos de referencia es un proceso complejo y propenso a errores. Este proyecto aborda esta problemática mediante el desarrollo de un algoritmo basado en aprendizaje profundo (DL) para automatizar la detección de puntos de referencia en el análisis cefalométrico de Bimler, utilizando el modelo de detección de objetos YOLOv8.

Identificación de puntos de referencia por una especialista (azul) y por el modelo (rojo)



Metodología

La metodología utilizada en este proyecto incluyó cinco fases: Recopilación de los datos para el dataset, proceso de creación del dataset, selección del modelo de YOLO, realización del software en Java 8 y validación del modelo y el software.



Resultados

Los resultados del proyecto fueron prometedores. El sistema automatizado logró identificar 19 de los 20 puntos cefalométricos de referencia con una precisión notable, alcanzando una tasa de detección promedio del 80% para un umbral de precisión de 2 mm. Las métricas de evaluación utilizadas, incluyendo el Error Radial Medio (MRE), la Desviación Estándar (SD) y la Tasa de Detección Exitosa (SDR), indicaron un alto nivel de precisión y fiabilidad del modelo desarrollado.

ÁNGULOS				
MEDIDAS ANGULARES	COMPONENTES	RANGO	INTERPRETACIÓN	PACIENTE
PERFIL ESQUELÉTICO	F1-F2	Mayor de 11° Menor de 11°	Céfalo (A2) Céfalo (A)	11.11 Céfalo (A)
ÁNGULO BASAL SUPERIOR	F4-F5	80° a 100° 80° a 100°	Maxilar/Maxilar (A) Maxilar/Maxilar (A)	88.81 Maxilar/Maxilar (A) - Maxilar (A)
ÁNGULO BASAL INFERIOR	F2-F4 (si F4 es positivo se resta, si F4 es negativo se suma)	27° a 157° 27° a 157° 27° a 157°	Proclividad Maxilar (A) Maxilar/Maxilar (A) Largos - Vertical (A)	32.41 Maxilar/Maxilar (A) Largos - Vertical (A)
ÁNGULO DORSOCCIPITAL	F2-F4-F6*	60° a 100° 100° a 120°	Céfalo (A) Largos (A)	102.27 Largos (A)
MEDIDAS LINEALES				
MEDIDAS LINEALES	COMPONENTES	RANGO	INTERPRETACIÓN	PACIENTE
TAMAJO MAXILAR	A-I	44 a 62 44 a 62	Maxilar (A) Céfalo (A)	57.19
RESALTE ORO	A-B	Mayor de 9 Menor de 10	Céfalo (A) Céfalo (A)	32.1
PROFUNDIDAD FACIAL	A-TM	Mayor de 77 Menor de 81	Maxilar (A) Céfalo (A)	80.13 Céfalo (A)
CUERPO MANDIBULAR	B-TM	Mayor de 16 Menor de 18	Maxilar (A) Céfalo (A)	60.12 Céfalo (A)
POSICIÓN ATM	T-TM	Mayor de 60 Menor de 62	Maxilar (A) Céfalo (A)	59.14 Céfalo (A)
BASE CRANIAL	N-S	Mayor de 80 Menor de 80	Céfalo (A) Largos (A)	80.12 Largos (A)



Objetivos

- ✓ Recopilar el dataset de radiografías digitalizadas necesarias para el entrenamiento del modelo del registro de archivo de la facultad de odontología de la Universidad de Antioquia (UDEA).
- ✓ Etiquetar las radiografías digitalizadas, mediante el uso de herramientas orientada al desarrollo de modelos de DL tales como Roboflow para la creación del dataset y el entrenamiento del modelo.
- ✓ Escoger el modelo DL a utilizar para la cefalometría y realizar su entrenamiento, mediante el entrenamiento de varios modelos tales como YOLOv8, YOLOv5, etc. y la evaluación de su precisión.
- ✓ Realizar una interfaz de usuario que permita al personal calificado utilizar el modelo entrenado como ayuda diagnóstica, programado en Java 8.
- ✓ Validar el modelo y la interfaz de usuario con especialistas de la facultad de odontología de la UDEA.

Conclusiones

- ✓ El algoritmo YOLOv8 demuestra una alta eficacia para la tarea específica de detección de puntos de referencia craneodentales.
- ✓ El software desarrollado representa un avance en la integración de inteligencia artificial en la práctica clínica, optimizando el tiempo de los especialistas y reduciendo errores.
- ✓ Al integrar modelos de aprendizaje profundo, el software logra identificar con precisión 19 de los 20 puntos cefalométricos de referencia.
- ✓ El software DIACEFAL, desarrollado en el marco de este trabajo, representa un avance significativo en la automatización del análisis cefalométrico.

DATOS DE CONTACTO DEL AUTOR:

3008813894

+57 300881394

Sebastian.gonzalez7@udea.edu.co

sebastiangh21

http://linkedin.com/in/sebastian-gonzalez-herrera/

Figura 6-1: Poster.

Bibliografía

- [1] Young Hyun Ki, Chena Le, H. Eun-Gyu, Yoon Jeong Cho, and Sang Sun Ha. A fully deep learning model for the automatic identification of cephalometric landmarks. *Imaging Science in Dentistry*, 51, 2021. ISSN 22337830. doi: 10.5624/ISD.20210077.
- [2] Chonho Lee, Chihiro Tanikawa, Jae-Yeon Lim, and Takashi Yamashiro. Deep learning based cephalometric landmark identification using landmark-dependent multi-scale patches. *Choice Reviews Online*, 6 2019.
- [3] Hannah Kim, Eungjune Shim, Jungeun Park, Yoon Ji Kim, Uilyong Lee, and Youngjun Kim. Web-based fully automated cephalometric analysis by deep learning. *Computer Methods and Programs in Biomedicine*, 194, 2020. ISSN 18727565. doi: 10.1016/j.cmpb.2020.105513.
- [4] John Fraser. What is artificial intelligence? *Petroleum Review*, 46, 1992. ISSN 00203076. doi: 10.1142/q0255.
- [5] Andrew Entwistle. What is artificial intelligence? *Engineering materials and design*, 32, 1988. ISSN 00138045. doi: 10.55248/gengpi.2022.31261.
- [6] Christian Janiesch, Patrick Zschech, and Kai Heinrich. Machine learning and deep learning. *Electronic Markets*, 31, 2021. ISSN 14228890. doi: 10.1007/s12525-021-00475-2.
- [7] Wilma A Simoes. Ortopedia funcional de los maxilares. *Wilma Alexandre Simões-Artes Médicas, São Paulo*, 1, 2004.
- [8] Van Nhat Thang Le, Junhyeok Kang, Il Seok Oh, Jae Gon Kim, Yeon Mi Yang, and Dae Woo Lee. Effectiveness of human–artificial intelligence collaboration in cephalometric landmark detection. *Journal of Personalized Medicine*, 12, 2022. ISSN 20754426. doi: 10.3390/jpm12030387.