



UNIVERSIDAD NACIONAL DE COLOMBIA

# **Uso de Técnicas de Aprendizaje Automatizado para Predicción de Morfología Mandibular en Clase I, II y III Esquelética**

**Tania Camila Niño Sandoval**

Universidad Nacional de Colombia  
Facultad de Odontología, Maestría en Odontología  
Bogotá, Colombia  
2012



# **Uso de Técnicas de Aprendizaje Automatizado para Predicción de Morfología Mandibular en Clase I, II y III Esquelética**

**Tania Camila Niño Sandoval**

Tesis de investigación presentada como requisito parcial para optar al título de:

**Magister en Odontología**

Directora:

M.Sc Antropología Biológica. Especialista en Ortodoncia. OD.

Sonia Victoria Guevara Pérez

Codirector:

Ph.D. & M.Sc. in Computer Science, M.Sc. en Matemáticas, Ingeniero de Sistemas.

Fabio Augusto González Osorio

Línea de Investigación:

Biometría Craneofacial

Grupo de Investigación:

Crecimiento y Desarrollo Craneofacial

Universidad Nacional de Colombia

Facultad de Odontología, Maestría en Odontología

Bogotá, Colombia

2012



*A las 4 razones de mi feliz existencia: mis papás divinos: Nicolás y Marina y mis hermanitos preciosos: Werner y Margarita los adoro con toda mi alma y todo mi ser. ¡Lo son TODO!*

*A mi familia grande y hermosa Niño-Sandoval-Ussa-Niño que ha estado pendiente de mí siempre (también desde arriba) y a quienes amo inmensamente.*

*A mis amigos maravillosos de todos los tiempos y todas las dimensiones y a mi novio bonito, quienes me dan su apoyo y su buena energía.*

*A mis directores de tesis, asesores, profesores y compañeros de la maestría de quienes he aprendido mucho.*

*A la vida por permitirme vivir esta oportunidad.*

*¡Gracias Totales!*



## Agradecimientos

Para la realización de este trabajo se necesitó los valiosos aportes de las siguientes personas e instituciones:

- Maestría en Odontología de la Universidad Nacional de Colombia, Dirección de Investigación Sede Bogotá y Facultad de Odontología de la Universidad Nacional de Colombia, entidades que financiaron de esta tesis.
- Doctora Sonia Guevara, Ingeniero Fabio González, Ingeniero Andrés Jaque y Doctora Clementina Infante por sus asesorías y enseñanzas para la realización de la tesis.
- Doctora Nancy Esperanza Castro por su colaboración en recolección de la muestra, entrenamiento en ubicación de puntos y aporte de las bases de datos con coordenadas de landmarks craneofaciales.
- Doctora Mireya Suárez y el Centro radiológico “Radiología Digital Galerías” por la toma de la muestra en condiciones de estandarización.
- Integrantes del Área de Salud de Bienestar Universitario de la Universidad Nacional de Colombia, Dirección de Bienestar de la Facultad de Odontología de la Universidad Nacional de Colombia, Fundación Universitaria San José e Instituto Triángulo y Grupos extracurriculares de la Universidad Católica, que fueron nuestras principales fuentes para la recolección de la muestra.
- Camilo Andrés Mateus González y Sonia Rocío Velandia Porras, estudiantes de pregrado del Departamento de Estadística de la Universidad Nacional de Colombia, por su asesoría en las pruebas de repetibilidad.





## Resumen

Las técnicas de aprendizaje automatizado se emplean principalmente para clasificar y predecir datos en diferentes aplicaciones. El objetivo de esta investigación fue predecir a través de estos métodos la morfología mandibular en maloclusiones Clase I, Clase II y Clase III esquelética, empleando medidas craneomaxilares. Se recolectaron 229 radiografías posteroanteriores y de perfil de adultos jóvenes colombianos de ambos sexos. Se emplearon coordenadas de landmarks óseos para formar variables craneomaxilares y mandibulares. Se probó inicialmente la clasificación de maloclusiones esqueléticas por medio de una máquina de vectores de soporte con un kernel lineal, excluyendo las variables mandibulares. En las radiografías posteroanteriores tuvo una precisión del 66%, clasificando en 71.43%, 70% y 60.87% para la Clase I, II y III. Para las radiografías de perfil, la precisión fue de 74.51%, con un 62.50%, 77.78% y 82.35% en la Clase I, II y III, definida por los atributos ENP-A-Pr, Zm-A-Pr, Te-Pr-A, Pr-A-Te, Rhi-A-Pr, A-Pr-Rhi, A-Te-Pr, A-N-Pr, N-Pr-A, Pr-A-N. En predicción, se usaron variables mandibulares específicas a partir de medidas craneofaciales seleccionadas evaluándose por medio de un coeficiente de correlación a través de una ridge regression; las variables Cdd-God, Cdd-Me, Cdi-Cdd, Cdi-Me y Goi-God tuvieron un  $r$  de 0.72, 0.82, 0.77, 0.86 y 0.76 con las redes neuronales en las radiografías posteroanteriores. Y en las radiografías de perfil, las medidas Gn-Id, Cd-Go-Gn, Gn-B, Gn-Pg, Go-Gn, Go-Me, Id-Gn-Go, Pg-B, Cd-Go-Gn, Gn-B, Gn-Pg, Go-Gn, Go-Me, Id-Gn-Go y Pg-B obtuvieron coeficientes de 0.95, 0.99, 0.95, 0.84, 0.91, 0.89, 0.93, 0.84, 0.95, 0.93, 0.98, 0.86, 0.84, 0.88, 0.96, 0.96 y 0.92 respectivamente. Las técnicas de aprendizaje automatizado en especial las redes neuronales, demostraron una precisión relevante que podría tener importancia en la reconstrucción facial para el proceso de individualización.

**Palabras clave:** Redes Neuronales Artificiales, Máquinas de Vectores de Soporte, Predicción, Mandíbula, Biometría, Maloclusión Clase I, II, III esquelética.



## Abstract

▪ Learning machine techniques are used primarily to classify and predict data in different applications. The aim of this study was to predict through these techniques mandibular morphology in skeletal malocclusion Class I, Class II and Class III, by using cranio-maxillary measurements. 229 posteroanterior and lateral cephalograms of Colombian young adults of both sexes were collected. Coordinates of landmarks were used to create mandibular and cranio-maxillary attributes. Skeletal malocclusions classification using a support vector machine with a linear kernel was initially performed. An accuracy of 66% was found in posteroanterior cephalograms, with a classification percentage of 71.43%, 70% and 60.87% in Class I, Class II and Class III respectively. An accuracy of 74.51% was found in lateral cephalograms with a classification percentage of 62.50%, 77.78% and 82.35% in Class I, Class II and Class III respectively, defined by ENP-A-Pr, Zm-A-Pr, Te-Pr-A, Pr-A-Te, Rhi-A-Pr, A-Pr-Rhi, A-Te-Pr, A-N-Pr, N-Pr-A and Pr-A-N angles. In prediction, specific mandibular variables from selected craniofacial measurements were used, an artificial neural network was applied, and a ridge regression was employed in order to access the prediction. Cdd-God, Cdd-Me, Cdi-Cdd, Cdi-Me and Goi-God had the biggest coefficient correlations of 0.72, 0.82, 0.77, 0.86 and 0.76 respectively in posteroanterior cephalograms. In lateral cephalograms the best coefficient correlations were 0.95, 0.99, 0.95, 0.84, 0.91, 0.89, 0.93, 0.84, 0.95, 0.93, 0.98, 0.86, 0.84, 0.88, 0.96, 0.96 and 0.92 in the attributes: Gn-Id, Cd-Go-Gn, Gn-B, Gn-Pg, Go-Gn, Go-Me, Id-Gn-Go, Pg-B, Cd-Go-Gn, Gn-B, Gn-Pg, Go-Gn, Go-Me, Id-Gn-Go and Pg-B, respectively. Automated learning techniques especially artificial neural networks demonstrated a significant performance, which could become important in facial reconstruction for the individualization process.

**Key Words:** Artificial Neural Networks, Support Vector Machine, Prediction, Mandible, Biometry, Skeletal Class I, II, III malocclusion.



# Contenido

	Pág.
<b>Resumen</b> .....	<b>IX</b>
<b>Lista de Figuras</b> .....	<b>XIX</b>
<b>Lista de Tablas</b> .....	<b>XXI</b>
<b>Lista de Abreviaturas</b> .....	<b>XXV</b>
<b>Introducción</b> .....	<b>1</b>
<b>1. Aplicación de la Predicción en Odontología y Antropología</b> .....	<b>5</b>
1.1 Predicción de Morfología Facial .....	5
1.2 Reconstrucción Facial en Antropología Forense .....	9
<b>2. Algoritmos de Aprendizaje Automatizado</b> .....	<b>11</b>
2.1 Redes Neuronales .....	11
2.1.1 Generalidades .....	11
2.1.2 Clasificación de las Redes Neuronales .....	12
2.1.3 Aplicaciones de las redes neuronales .....	16
2.2 Máquinas de Vectores de Soporte .....	21
2.2.1 Generalidades .....	21
2.2.2 Clasificación e hiperplano de margen máximo .....	23
2.2.3 Regresión por Vectores de Soporte (SVR) .....	25
<b>3. Metodología</b> .....	<b>29</b>
3.1 Criterios de Inclusión .....	29
3.2 Criterios de Exclusión .....	29
3.3 Consideraciones Éticas .....	30
3.4 Procedimientos .....	31
3.4.1 Recolección de la muestra .....	31
3.4.2 Selección de variables: medidas lineales y angulares en el programa Metronukak .....	32
3.4.3 Medición de las imágenes radiográficas .....	37
3.5 Medición del error intra e interobservador .....	38
3.6 Pruebas con algoritmos de Aprendizaje para clasificación con método de medición Metronukak .....	42
3.7 Pruebas con algoritmos de Aprendizaje con método de coordenadas de landmarks .....	44
3.7.1 Creación de medidas lineales y angulares con software Matlab: nueva clasificación .....	53



3.8	Optimización de parámetros y Clasificación de maloclusiones esqueléticas con medidas creadas a partir de landmarks .....	55
3.9	Predicción de variables mandibulares a partir de variables craneomaxilares .	56
3.9.1	Predicción de coordenadas de landmarks mandibulares.....	56
3.9.2	Predicción de medidas mandibulares seleccionadas en radiografías de perfil	56
3.9.3	Predicción de medidas mandibulares a partir de medidas craneomaxilares seleccionadas en radiografías de perfil.....	58
3.9.4	Predicción de medidas mandibulares seleccionadas en radiografías posteroanteriores .....	60
3.9.5	Predicción de medidas mandibulares a partir de medidas craneomaxilares seleccionadas en radiografías posteroanteriores.....	62
<b>4.</b>	<b>Resultados.....</b>	<b>65</b>
4.1	Pruebas con algoritmos de Aprendizaje para clasificación con método de medición Metronukak .....	65
4.2	Clasificación de maloclusiones esqueléticas con medidas creadas a partir de landmarks .....	67
4.2.1	Clasificación de maloclusiones esqueléticas en radiografías de perfil .	67
4.2.2	Clasificación de maloclusiones esqueléticas en radiografías posteroanteriores .....	68
4.2.3	Optimización y clasificación de maloclusiones esqueléticas en radiografías de perfil y posteroanteriores .....	69
4.2.4	Clasificación de maloclusiones esqueléticas a partir del valor predicho del ángulo ANB en radiografías de perfil .....	70
4.3	Predicción de variables mandibulares a partir de variables craneomaxilares .	72
4.3.1	Predicción de coordenadas mandibulares en radiografía de perfil.....	72
4.3.2	Predicción de coordenadas mandibulares en radiografías posteroanteriores .....	74
4.4	Predicción de medidas mandibulares seleccionadas en radiografías de perfil	76
4.5	Predicción de medidas mandibulares a partir de medidas craneomaxilares seleccionadas en radiografías de perfil .....	78
4.6	Predicción de medidas mandibulares seleccionadas en radiografías posteroanteriores .....	84
4.7	Predicción de medidas mandibulares a partir de medidas craneomaxilares seleccionadas en radiografías posteroanteriores .....	86
<b>5.</b>	<b>Discusión.....</b>	<b>89</b>
<b>6.</b>	<b>Conclusiones y recomendaciones.....</b>	<b>97</b>
6.1	Conclusiones .....	97
6.2	Recomendaciones .....	98
<b>A.</b>	<b>Acuerdo de Confidencialidad .....</b>	<b>99</b>
<b>B.</b>	<b>Consentimiento Informado .....</b>	<b>101</b>
<b>C.</b>	<b>Cartilla Informativa.....</b>	<b>103</b>
<b>D.</b>	<b>Carta de Aprobación de cambio del nombre de la tesis.....</b>	<b>105</b>





---

<b>E. Carta de Aprobación de la Tesis por el Comité de Ética de la Facultad.....</b>	<b>107</b>
<b>Bibliografía .....</b>	<b>109</b>



## Lista de Figuras

	Pág.
<b>Figura 1-1:</b> Clasificaciones del perfil .....	2
<b>Figura 3-1:</b> Variables para radiografía posteroanterior.....	34
<b>Figura 3-2:</b> Variables para radiografía de perfil.....	36
<b>Figura 3-3:</b> Protocolos de uso para software Metronukak.....	37
<b>Figura 3-4:</b> Resultados de medidas del software Metronukak.....	38
<b>Figura 3-5:</b> Software Rapidminer .....	42
<b>Figura 3-6:</b> Esquema de variables mandibulares a predecir en radiografía de perfil.....	57
<b>Figura 3-7:</b> Variables Mandibulares a predecir .....	58
<b>Figura 3-8:</b> Esquema de variables mandibulares a predecir en radiografía posteroanterior .....	61
<b>Figura 3-9:</b> Variables mandibulares a predecir .....	62
<b>Figura 3-10:</b> Variables craneomaxilares seleccionadas en radiografía posteroanterior..	63
<b>Figura 4-1:</b> Detalles del porcentaje de precisión de las redes neuronales .....	66
<b>Figura 4-2:</b> Precisión en clasificación de maloclusiones esqueléticas en radiografías de perfil .....	67
<b>Figura 4-3:</b> Precisión en clasificación de maloclusiones esqueléticas en radiografías posteroanteriores .....	69
<b>Figura 4-4:</b> Precisión en clasificación de maloclusiones esqueléticas en radiografías de perfil y posteroanteriores .....	70
<b>Figura 4-5:</b> Precisión en clasificación de maloclusiones esqueléticas a partir del ángulo ANB predicho .....	71
<b>Figura 4-6:</b> Variables Sintéticas (10 Variables).....	78
<b>Figura 4-7:</b> Variables de la literatura (12 Variables).....	78
<b>Figura 4-8:</b> Combinación variables sintéticas y de literatura (22 Variables) .....	79
<b>Figura 4-9:</b> Combinación variables sintéticas de literatura y distancias de las variables sintéticas (33 Variables) .....	79



## Lista de Tablas

	Pág.
<b>Tabla 3-1:</b> Clasificación según ANB.....	32
<b>Tabla 3-2:</b> Clasificación de los pacientes recolectados en método metronukak. N=216.	33
<b>Tabla 3-3:</b> Variables para radiografía de posteroanterior. ....	33
<b>Tabla 3-4:</b> Variables para radiografía de perfil .....	35
<b>Tabla 3-5:</b> Coeficiente de Dahlberg en radiografías de perfil (N=30).....	38
<b>Tabla 3-6:</b> Prueba T pareada en radiografías de perfil (N=30) .....	39
<b>Tabla 3-7:</b> Coeficiente de Dahlberg en radiografías posteroanteriores (N=30).....	40
<b>Tabla 3-8:</b> Prueba T pareada en radiografías posteroanteriores (N=30) .....	41
<b>Tabla 3-9:</b> Puntos cefalométricos ubicados en radiografía de perfil .....	45
<b>Tabla 3-10:</b> Puntos cefalométricos ubicados en radiografía posteroanterior .....	49
<b>Tabla 3-11:</b> Clasificación de los pacientes recolectados en método de landmarks. N=229. .....	54
<b>Tabla 3-12:</b> Variables mandibulares a predecir en radiografía de perfil.....	57
<b>Tabla 3-13:</b> Variables mandibulares a predecir en radiografía posteroanterior.....	61
<b>Tabla 4-1:</b> Porcentaje de precisión (accuracy) en la clasificación con redes neuronales	65
<b>Tabla 4-2:</b> Porcentaje de precisión (accuracy) en la clasificación con máquinas de vectores de soporte .....	65
<b>Tabla 4-3:</b> Porcentaje de precisión (accuracy) en la clasificación con sólo variables craneomaxilares .....	66
<b>Tabla 4-4:</b> Variables explicativas del modelo de clasificación .....	68
<b>Tabla 4-5:</b> Desempeño del conjunto de datos en predicción de ANB.....	70
<b>Tabla 4-6:</b> Mejor parámetro C.....	71
<b>Tabla 4-7:</b> Desempeño de las coordenadas mandibulares predichas en radiografía de perfil .....	72
<b>Tabla 4-8:</b> Coeficiente de correlación 'r' de las coordenadas mandibulares predichas en radiografías de perfil.....	73
<b>Tabla 4-9:</b> Desempeño de las coordenadas mandibulares predichas en radiografía posteroanterior .....	74
<b>Tabla 4-10:</b> Coeficiente de correlación 'r' de las coordenadas mandibulares predichas.	76
<b>Tabla 4-11:</b> Error cuadrático medio de las variables mandibulares predichas.....	76
<b>Tabla 4-12:</b> Coeficiente de correlación 'r' de las medidas mandibulares predichas.....	77
<b>Tabla 4-13:</b> Coeficiente de correlación 'r' de las medidas mandibulares predichas en máquinas de vectores de soporte.....	79



---

<b>Tabla 4-14:</b> Coeficiente de correlación 'r' de las medidas mandibulares predichas en redes neuronales.....	<b>81</b>
<b>Tabla 4-15:</b> Error cuadrático medio de las variables mandibulares predichas en máquinas de vectores de soporte.....	<b>82</b>
<b>Tabla 4-16:</b> Error cuadrático medio de las variables mandibulares predichas en redes neuronales .....	<b>83</b>
<b>Tabla 4-17:</b> Comparación del error cuadrático medio más bajo entre redes neuronales y máquinas de vectores de soporte.....	<b>83</b>
<b>Tabla 4-18:</b> Error cuadrático medio de las variables mandibulares predichas.....	<b>84</b>
<b>Tabla 4-19:</b> Coeficiente de correlación 'r' de las medidas mandibulares predichas.....	<b>85</b>
<b>Tabla 4-20:</b> Coeficiente de correlación 'r' de las medidas mandibulares predichas.....	<b>86</b>
<b>Tabla 4-21:</b> Error cuadrático medio de las variables mandibulares predichas.....	<b>86</b>





## Lista de Abreviaturas

Abreviatura	Término
<i>CT</i>	Tomografía Computarizada
<i>GPM</i>	Potencial de crecimiento mandibular
<i>MM</i>	Método de Mito y colaboradores
<i>FCC</i>	Componentes craneales funcionales
<i>ANN</i>	Redes neuronales artificiales
<i>PE</i>	Elementos de procesamiento
<i>MSE</i>	Error cuadrático medio
<i>CCR</i>	Tasa correcta de clasificación
<i>LVQ</i>	Aprendizaje por cuantificación vectorial
<i>SOM</i>	Mapas de autorganización.
<i>FFNN</i>	Redes neuronales unidireccionales.
<i>CMAC</i>	Modelo cerebelar de articulación controladora
<i>PCA</i>	Análisis de Componentes principales
<i>SVD</i>	Descomposición de valores singulares
<i>CNT-MOSFET</i>	Nanotubos de carbono metálicos - semiconductores de óxido de transistores de efecto de campo
<i>SR</i>	Regresión por pasos
<i>CR</i>	Algoritmo de clasificación de correlación
<i>ROP</i>	Tasa de penetración
<i>ROC</i>	Curvas del receptor característico del operador
<i>SVM</i>	Máquinas de Vectores de Soporte
<i>a</i>	Atributo
<i>w</i>	Peso
<i>EEG</i>	Electroencefalogramas
<i>SRM</i>	Minimización del <i>riesgo estructural</i>
<i>SVR</i>	Regresión por vectores de soporte
<i>MK-SVM</i>	Máquinas de vectores de soporte con kernel múltiple
<i>RBF</i>	Función de base radial
<i>RCGA</i>	Algoritmos genéticos con codificación real



# Introducción

Los modelos de predicción han sido utilizados en varias situaciones en los que se necesita conocer a futuro el comportamiento de datos complejos altamente relacionados. La predicción de estructuras morfológicas y en especial de la mandíbula a partir de variables craneomaxilares (1, 2), posee grandes utilidades clínicas e investigativas en el campo odontológico, como en traumas (3) o patologías (4) que pueden producir la pérdida parcial o total de éste hueso y donde se hace necesaria la proyección de la forma con fines de cirugía reconstructiva (5), ya que permiten determinar la forma ideal de la cara (3); este mismo principio se lleva a cabo en imágenes predictivas en cirugía ortognática y estética (3-7).

Otro empleo de la predicción se da en crecimiento y desarrollo craneofacial en presencia de maloclusiones clase I, II y III esquelética, en las cuales se desea saber en individuos jóvenes la forma y el tamaño que logrará la mandíbula adulta con fines de proyección del tratamiento temprano (8, 9), para conocer la posible futura configuración esquelética facial completa de un individuo, para tratar de lograr armonía craneofacial (9-11).


Por otro lado tiene un uso considerable en las ciencias forenses (12, 13), en el caso que se quiera realizar reconstrucción facial la cual tiene como principal objetivo individualizar a una persona desaparecida incluso contemplando el crecimiento que esta haya tenido con el tiempo (14). Algunas veces en la antropología forense, se puede encontrar la dificultad del extravío del hueso mandibular (2, 15, 16), ya que es una pieza única unida al complejo craneomaxilar por tejidos blandos que se descomponen post mortem y tiene la posibilidad de extraviarse en restos esqueletizados (2, 15, 16).

Por lo general en la predicción y reconstrucción facial, se utilizan diferentes técnicas de modelamiento tales como la reconstrucción bidimensional por superposición de

imágenes (17), o tridimensional mediante plastilinas, arcillas, cortes de tomografía computarizada, entre otras (18, 19).

Normalmente los estudios de predicción facial contemplan un perfil recto correspondiente a la clase I esquelética, mas no al 20.8% de la clase II esquelética correspondiente a un perfil convexo, ni al 3.7% de la clase III esquelética correspondiente a un perfil cóncavo presentados en una población Colombiana (20).

**Figura 1-1:** Clasificaciones del perfil



La predicción mandibular se ha realizado a través de modelos de regresión lineal univariados y multivariados (9, 21-23), que limitan la búsqueda de relaciones morfológicas craneofaciales en las maloclusiones clase I, clase II y clase III esquelética (2, 24), al manejar una distribución normal (24); situación que puede ser resuelta a través de la interacción de tecnologías aplicadas como las técnicas de aprendizaje supervisado, que son sistemas que permiten resolver situaciones complejas por medio de la presentación de datos para establecer patrones con el fin de modelarlos.

Dentro de una gran variedad de clases, se destacan las redes neuronales y las máquinas de vectores de soporte (25), las cuales juegan un papel importante en la clasificación y predicción de datos bajo diversos escenarios, con una alta dimensionalidad que permitiría un manejo más adecuado de la información obtenida, dando una generalización de las interacciones entre variables convirtiéndolo en un sistema más

robusto; teniendo en cuenta lo anterior, se considera emplear estas herramientas para predecir la morfología mandibular a través de variables maxilares y craneales.

Este documento es en parte la continuación de la tesis titulada 'Uso de redes neuronales en la predicción de la morfología mandibular: aplicación forense', donde se usó una muestra de pacientes clase I esquelética (2); sin embargo, teniendo en cuenta las recomendaciones de ésta, en la presente investigación se hizo necesario el análisis de los otros tipos de maloclusiones, la Clase II y la Clase III esquelética (20), con el fin de generalizar los resultados a la población, para que se pueda clasificar a un individuo nuevo.

Basándose en lo anterior se realizó la siguiente pregunta de investigación:

¿Es posible predecir la morfología mandibular en maloclusión Clase I, Clase II y Clase III esquelética utilizando técnicas de aprendizaje automatizado como las redes neuronales o las máquinas de vectores de soporte?

Para responderla se tuvo como objetivo general predecir la morfología mandibular en maloclusión Clase I, Clase II y Clase III esquelética utilizando máquinas de vectores de soporte y redes neuronales.

Los objetivos específicos eran clasificar individuos en Clase I, II y III esquelética utilizando técnicas de aprendizaje automatizado, estimar la capacidad predictiva de las redes neuronales y las máquinas de vectores de soporte, determinar las relaciones de dependencia funcional de las variables morfológicas mandibulares con respecto a las craneomaxilares y finalmente, comparar las redes neuronales artificiales con las máquinas de vectores de soporte en términos de error cuadrático medio de la predicción.

El impacto logrado con este trabajo fue estructural ya que se obtuvo un método con alta capacidad de predicción mandibular y clasificación de maloclusiones esqueléticas con variables que no se encuentran reportadas en artículos científicos, por lo tanto el aporte de la relación de variables craneomaxilares nuevas con las variables mandibulares da un nuevo enfoque que podría ser utilizado por profesionales en odontología, en áreas como odontopediatría, ortopedia y ortodoncia, en crecimiento y desarrollo y planificación de los

tratamientos, así como en cirugía reconstructiva en caso de fracturas; Así mismo el impacto es institucional pues podría haber un empleo en ciencias forenses para averiguar la forma de la cara de un individuo sin identificar cuando se haya extraviado la mandíbula, lo cual podría aplicarse al Instituto de Medicina Legal y/o laboratorios antropológicos y forenses.

# 1. Aplicación de la Predicción en Odontología y Antropología

## 1.1 Predicción de Morfología Facial

La predicción de la morfología facial ha tenido como principio pronosticar la posición, tamaño y/o forma de una estructura craneofacial a partir de otra. Se ha realizado con estadística univariada y multivariada, a través de métodos paramétricos que han demostrado resultados significativos. Las investigaciones que implicaban evaluación craneofacial, inicialmente utilizaban métodos estadísticos muy sencillos y se consideraba el uso de la estadística multivariada únicamente en casos especiales donde la complejidad de las variables no permitiera resolver la problemática a través de una ecuación lineal simple. Una de las ventajas que representó el uso de la estadística multivariada fue permitir mayor robustez integrando variables y correlacionándolas, aunque la explicación de la misma tendría que estudiarse detalladamente para dar un resultado adecuado y entendible. Muchas de las variables tenían la característica de ser multidimensionales y se implementaron métodos como el  $D^2$  de Mahalanobis, el  $T^2$  de Hotelling y la función discriminante lineal de Fisher, dando resultados importantes aunque su entendimiento fuera complicado (26).

La predicción puede realizarse en casos en que se quiera conocer el crecimiento y desarrollo de un paciente y/o en la determinación de las maloclusiones esqueléticas, en las cuales el fin es observar el tratamiento más adecuado para el paciente; para esto se establecen modelos que intentan disminuir factores aleatorios que los puedan modificar, teniendo en cuenta los conceptos de patrón, crecimiento, armonía y balance (27). Por lo general se calcula el error a través de la fórmula de Dahlberg (28-30) y se estandarizan las variables, se confirma la distribución normal mediante el test de Kolmogorov-Smirnov (31), después al tener los resultados se aplica estadística descriptiva en especial promedios y desviaciones estándar (9, 21, 28, 29, 32-35), continuado de una prueba de t

Student (9, 28, 30, 32), ó estadística no paramétrica con el test de Mann–Whitney U (31, 35), y/o una correlación de Pearson (29, 30, 35, 36), seguido de un análisis de varianza ANOVA (30); en ocasiones se evalúan algunas variables con análisis lineal discriminante con el fin de saber si es un identificador de un grupo específico (28), o para extraer determinantes morfométricos para la distinción de tratamientos efectivos o no efectivos, seguido de un análisis multivariado, clusters y tablas cruzadas dos por dos, calculando los errores de predicción (9), se han utilizado análisis de componentes principales (29); y análisis de regresión múltiple por lo general complementaría los datos para obtener resultados a posteriori de los grupos significativos de los estudios (32).

Tanto en el crecimiento como en las maloclusiones se utilizan puntos anatómicos o landmarks que formarán planos o ángulos que se correlacionarán (28). La base craneal se relaciona con patrones de crecimiento esquelético, debido a que cuando una base craneal es obtusa la cara será divergente, por lo tanto el ángulo de la base craneal se asocia con la posición anteroposterior de los maxilares (29). La angulación de la base del cráneo, un ángulo ANB mayor de 4°, un overjet mayor de 4mm, un perfil facial convexo, una relación molar bilateral Clase II en oclusión céntrica, entre otros, fueron usados para determinar la Clase II división 1 y observar las diferencias con un grupo control clase I y la relación de la divergencia facial con la maloclusión (35).

Para predecir el crecimiento se ha correlacionado la altura vertical inferior (ANS-Menton) y el tamaño y forma del contorno endocraneal tomando medidas desde Silla (S) hasta distintos puntos del contorno craneal (32); otro modo de predicción se hace mediante el potencial de crecimiento mandibular (GPM) a través de radiografías de mano-muñeca como indicador de maduración esquelética y también a través del método de Mito et al (MM) que tiene en cuenta el tamaño y forma de la tercera y cuarta vértebras cervicales, con el objetivo de pronosticar el crecimiento del maxilar inferior en pacientes con clase III esquelética (21). Adicionalmente, se encuentran también el análisis de los componentes craneales funcionales (FCC), los cuales se basan en la hipótesis de la matriz funcional y al analizar estos datos por métodos no paramétricos como el smoothing spline, se determinan curvas de ajuste para diseñar un patrón de crecimiento de cada uno de los FCC (37).



En ocasiones se reconoce una variable identificadora de un grupo, como en el caso de Pogonion a Punto A (Pg-A) que categorizó efectivamente el crecimiento de los pacientes de 6 a 18 años de edad en una población Noruega, además se observó que en muchos pacientes el perfil esquelético se vuelve más recto; sin embargo por lo general en relaciones mandíbula - base del cráneo anterior que se encuentran extremadamente alteradas no mejoran con la edad y muchas de ellas requieren un tratamiento interceptivo ya que reflejarán un crecimiento inadecuado (28), incluso este factor aplica en el caso de la presencia de una desarmonía extrema clase II dento-esquelética, ya que no existe una tendencia a corregirse con el crecimiento (31).

Es por lo anterior que también se ha intentado predecir la posición de estructuras con variables modificadoras de patrones como un tratamiento, por ejemplo en clase III esquelética en pacientes con mordida cruzada anterior, tomando el crecimiento en cuatro tiempos: justo antes del tratamiento, inmediatamente después de la corrección de la mordida cruzada anterior, después de dos años y 6 meses donde se obtiene una sobremordida vertical y horizontal adecuada, y después de completar el crecimiento craneofacial de la pubertad, prediciendo la efectividad o fracaso de un tratamiento convencional teniendo en cuenta características distintivas en un mismo tipo de maloclusión en diferentes pacientes (9). En este caso se analizaron mediante varios modelos de estadística multivariada, como correlación de Pearson en donde los resultados significativos son sometidos a un análisis de regresión y las medidas significativas se someten a análisis de regresión lineal múltiple (36).

También se han analizado datos longitudinales con controles anuales estableciendo curvas de crecimiento para relacionarlos con patrones horizontales y verticales, el modelamiento de estos se dan con métodos estadísticos multinivel y los parámetros del modelo se estiman con mínimos cuadrados, estableciendo que hay mayor precisión de predicción con respecto al movimiento vertical del mentón medido desde Silla (Me-Y) y de la distancia lineal de los movimientos del mentón en relación a la silla (Me-R), confirmando que hay correlaciones positivas entre el tamaño y la velocidad de crecimiento, y que los pacientes con crecimiento extremo vertical empeoran al pasar el tiempo sobre los otros pacientes (8).

Con el tiempo se han ido implementando softwares estadísticos como el MLwiN que maneja datos perdidos y determina una clase de función matemática que describe una curva que se adapte a las medidas y explique las curvas de crecimiento promedio (38), así como herramientas avanzadas de procesamiento de imágenes, que inicialmente son empleados en otras áreas, los cuales paulatinamente se han aplicado en ciencias de la salud, tal es el caso de la morfometría geométrica, que comenzó a implementarse en la predicción de la morfología craneofacial como una hipótesis de puntos que mantienen la misma proporción a medida que una estructura aumenta de tamaño, llamados invariantes que se ubican dentro de una figura geométrica de 3 o 4 lados, y que pueden predecir la forma final de un contorno (39). Esta técnica gradualmente se ha definido más, ya que además de hacer estadística descriptiva, se superimponen los trazos por el método de Procrustes y se aplican análisis de componentes principales (34, 40).

Por lo general para los análisis mencionados y algunos de morfometría geométrica se hacen observaciones y se trazan puntos sobre radiografías (28, 32), sin embargo, la tecnología permite estar en función de este tipo de investigaciones, empleando imágenes obtenidas a partir de resonancia magnética o tomografías computarizadas, que determinan más precisamente el crecimiento craneofacial e incluso tendencias a maloclusiones en el paciente, tienen la ventaja de permitir la identificación de landmarks que son difíciles de encontrar en radiografías convencionales como en el caso de la base del cráneo donde se identifican la fosa anterior, media y posterior que sirven de parámetros en la evaluación y predicción de deformidades craneofaciales, determinado que la fosa anterior crece más rápido en hombres, la posterior en mujeres y la media es similar en ambos sexos, en ocasiones es necesario eliminar factores atípicos a través de la técnica Lowess Smoothing, que produce un efecto promedio de los datos (33), también se ha empleado en modelamiento de crecimiento mandibular las tomografías computarizadas, extrapolar 14851 semilandmarks un algoritmo de difusión geométrica condensada mapeadas a un espacio de Procrustes y examinándolas a través de análisis de componentes principales, extrayendo un subespacio de una dimensión que construyó un modelo satisfactorio, el error promedio más grande fue encontrado en el individuo #4 que fue de 3.7 mm (24).

Aunque una desventaja de la tomografía computarizada sea un alto valor económico puede aplicarse a cuantificar el crecimiento mandibular, más específicamente en una tomografía computarizada helicoidal de multisegmento dando un modelamiento a través de funciones específicas como la de Laplace-Beltrami, algoritmos como marching cubes y heat kernel smoothing, para convertirlo en una estructura tridimensional evaluada por análisis de Fourier y mínimos cuadrados ajustándose a un modelo lineal que permita la predicción del crecimiento mandibular (41)

## 1.2 Reconstrucción Facial en Antropología Forense

La reconstrucción facial es una herramienta útil en antropología forense ya que permite la individualización por medio del análisis de los restos humanos craneofaciales. Se usa frecuentemente en casos donde no se dispone de mucha información acerca de la persona (15, 42).

Existen técnicas que cuentan con procedimientos variados; uno de estos es la reconstrucción con arcilla o plastilina que se van ubicando sobre el cráneo o en un modelo de éste por capas emulando los tejidos blandos, dando como resultado una imagen de lo que pudo ser la persona en vida (16). Otra técnica que se emplea es la cefalometría básica como método de predicción y reconstrucción a través del análisis de forma de Fourier, que aunque no muestra precisión diagnóstica, puede servir de herramienta en ciencias forenses (43).

Por otro lado se ha usado el procesamiento de imágenes, que ha facilitado la reconstrucción. Dentro de estas se encuentra la superimposición, donde toman de los restos óseos craneofaciales ciertos ángulos y puntos y lo orientan sobre una fotografía para observar la coincidencia entre ambos (15, 17).

Así mismo existen técnicas que mejoran la cefalometría tradicional por medio de algoritmos matemáticos para realizar una combinación con el procesamiento de imágenes, a través de puntos antropométricos también conocidos como landmarks (44); se utilizan principalmente para la reconstrucción de tejidos blandos en panoramas

bidimensionales o tridimensionales, dependiendo de las herramientas con las que se dispone (45, 46). En algunos casos se tiene en cuenta la variabilidad en el grosor de los tejidos blandos (18, 47).

Uno de los instrumentos que en los últimos años se ha utilizado y se encuentra en auge es la tomografía computarizada (CT), que ha permitido realizar un trabajo preciso y rápido en cuanto a digitalización tridimensional. La CT acompañada de los algoritmos matemáticos, análisis de superficies, asignación de landmarks, antropología virtual, morfometría geométrica entre otras tecnologías, puede estimar no sólo la forma y grosor de los tejidos blandos sino también otorgarle rasgos individualizantes a la cara e incluso reconstruir estructuras óseas faltantes (18, 19, 48-53). Incluso se pueden establecer relaciones y generar hipótesis de predicción y forma facial con estructuras que normalmente no se estudian como los senos paranasales que al parecer muestran una variación con respecto a los primates y otros homínidos ya extintos, por medio de la morfometría geométrica observando los componentes craneofaciales a nivel ontogénico como parte del trabajo del antropólogo para analizar patrones evolutivos (54).

## **2. Algoritmos de Aprendizaje Automatizado**

### **2.1 Redes Neuronales**

#### **2.1.1 Generalidades**

Las redes neuronales artificiales (ANN) son complejos matemáticos regidos bajo un principio de aprendizaje, el cual se basa en los conceptos de inteligencia artificial (55, 56); se fundamentan en la respuesta biológica neuronal del cerebro humano (2, 57, 58) y están implicadas en procesos de construcción de sistemas que permiten, clasificar, diagnosticar, modelar y predecir información (59-63).

Una de las características principales de las redes neuronales es que son modelos no lineales, semiparamétricos, lo que permite integrar variables continuas, binarias, ordinales y nominales, para lo cual es necesario una muestra grande de datos, convirtiéndose en una alternativa en el análisis de éstos (62, 64-68), debido a la limitación que presentan los modelos de regresión por ser un análisis de tipo lineal (2, 59, 60, 69).

Las redes neuronales están constituidas por unos elementos de procesamiento (PE) o neuronas (70), que son las unidades del sistema que pueden ser ajustadas o entrenadas y tener un proceso de aprendizaje y de generalización, por la atribución de un algoritmo que es una función, variable o conexión entre las neuronas (más conocida como peso, peso sináptico, weight o synaptic weight) que pueden ser positivas (estimuladoras) o negativas (inhibitorias) (13, 57, 71, 72). La información de cada una de esas neuronas se agrupa y se procesa en organizaciones llamadas nodos, la unión de todas las variables de un nodo se llama vector (72). Esos nodos se distribuyen en unas estructuras llamadas capas o matrices.

Por lo general existen tres capas (59): una de entrada (input) donde se ingresan a las redes los datos que se quieren analizar; una capa intermedia o capa oculta (hidden) (66), donde se hace la agrupación de éstos y se les asigna los diferentes pesos, determinando cuáles pueden ser relevantes, aunque en algunos sistemas esta función puede ser dada por la misma capa de entrada (57, 71, 73, 74), y una capa de salida (output) cuyo resultado del análisis es dado a través de funciones de transferencia que pueden ser sigmoideas, gaussianas, lineales, entre otras (64, 70, 75, 76)

El procesamiento de los datos está acompañado por los epoch o ciclos que los vectores tienen en las capas, donde se les asigna pesos clasificatorios para generar la relevancia de la información (13, 59, 65, 70, 77, 78). Los epoch sin embargo cuentan con un número límite de ciclos que son efectivos, donde no es necesario recurrir a más, es decir llegan a un umbral; existen métodos estadísticos que determinan hasta qué punto la red podría predecir o hacer cualquier otra función que se le asigne, estos se denominan criterios de parada (59, 65); dentro de estos se encuentran los mínimos cuadrados del error (MSE), sensibilidad, especificidad, tasa correcta de clasificación (CCR), índice de sensibilidad logarítmica, entre otros (13, 65, 79).

### **2.1.2 Clasificación de las Redes Neuronales**

Las redes neuronales se clasifican de la siguiente manera:

Según el algoritmo de aprendizaje (2, 57, 70, 75, 80):

- **Aprendizaje Supervisado:** En este tipo de red es necesario tener predeterminados los nodos de salida, es decir estos se controlan para dar un resultado deseado. Para esto un supervisor o maestro ajusta sus pesos según las necesidades. Dentro de estos se encuentran:

**Algoritmo de backpropagation:** También llamado algoritmos o redes de retropropagación. Es uno de los más utilizados para entrenar redes neuronales, calcula la diferencia entre la salida obtenida y la salida deseada, con el fin de reducir el rango de error a través de

un descenso de gradiente. Si el error es muy grande, el algoritmo devuelve la información al inicio y el maestro ajusta los pesos hasta que el error sea menor de un nivel preestablecido, cuando esto ocurre se determina que la red ha aprendido la información de entrada (57, 58).

Algoritmos LVQ: Aprendizaje por cuantificación vectorial (Learning vector quantization), sirve para el reconocimiento de patrones, clustering y para herramienta en compresión en imágenes; Principalmente se encarga de dividir el espacio de entrada (input) en un varias regiones de decisión (Células de Voronoi) y para cada una de estas se les asigna un vector codificado, estos se van ajustando en repetidas ocasiones para su entrenamiento (81, 82).

- Aprendizaje No Supervisado: No requiere que los datos de los nodos de salida se conozcan, es decir sólo se le presentan a la red los datos de entrada y esta se encarga de agruparlos por características similares, adaptando los pesos de sus conexiones, por lo tanto no es necesaria la intervención de un maestro.

Red de Kohonen: Denominada también como mapas de autorganización (Self-Organizing Map o SOM), modifica los patrones de entrada en una estructura de salida de 2 dimensiones, manteniendo la topología de los datos y reduciendo la dimensionalidad, convirtiéndose en una herramienta útil en imágenes diagnósticas. Existen los vectores de entrada (datos que entran), cada uno de estos poseen un vector de pesos; cuando existe una neurona de entrada que se asemeja mucho al vector de pesos más que las otras, la red determina que es la neurona ganadora, ya que este es un sistema competitivo, y se ajustarán los vectores de pesos de las neuronas vecinas, cuya señal será similar a la de la ganadora pero será más débil a medida tomen distancia de esta (71, 72, 80).

- Redes Híbridas: Es la combinación de las redes neuronales con otros elementos ya sean estadísticos, de inteligencia artificial, e incluso combinaciones entre sus algoritmos de aprendizaje, la estructura de la red, y su función de transferencia, a continuación se nombrarán algunos:

Sistemas difusos y redes neuronales: Los sistemas difusos, borrosos o Fuzzy system, manejan un lenguaje condicional basado en la frase 'IF X is A, THEN Y is B', donde X y

Y, son variables, A es la premisa y B es la consecuencia y se les asigna atributos o funciones matemáticas; estos sistemas difusos combinados con las redes neuronales hacen que se pueda entender el procesamiento interno de la red (70, 83).

Conjuntos aproximados y redes neuronales: Los conjuntos aproximados manejan información imprecisa, pues reduce conjuntos de información hasta generar una información más concreta, es decir se selecciona información irrelevante y se descarta y la que se considera importante se mantiene en el sistema, de esa manera no hay pérdida de información esencial; las redes neuronales ayudan a facilitar esta acción disminuyendo el tiempo de entrenamiento (84).

Según su estructura (70, 71, 73, 85, 86):

- Unidireccionales (Feedforward neural networks ó FFNN): son las redes que normalmente se agrupan en capas, su conexión va de una capa a otra pero no entre las neuronas de la misma capa, comienza con una entrada y genera una función de salida. A continuación se nombrarán algunas:

Perceptron Multicapa: Es una de las arquitecturas más utilizadas, está constituida por capas de entrada, capas ocultas y capas de salida; inicialmente se determinan el número de los nodos que componen cada capa. Cada nodo de entrada hace contacto con todos los nodos ocultos, por lo tanto estos obtienen toda la información de entrada y la procesan, después todos los nodos ocultos hacen contacto con cada uno de los nodos de salida, dando un resultado o conclusión; en muchas ocasiones el algoritmo de backpropagation acompaña a este tipo de red para ajustar sus pesos (58, 61, 62, 68, 71, 87-93).

CMAC (Cerebellar Model Controller Articulation): Es similar a la perceptron multicapa, se diferencian en que la CMAC permite la generalización de la salida de manera rápida, ahorrando tiempo de entrenamiento; se constituye por una gran cantidad de neuronas de entrada y salida, tiene la capacidad de converger a un ciclo límite o umbral y maneja una tasa de aprendizaje de valores entre 0 y 2. (94, 95).



▪ Redes Neuronales recurrentes (Recurrent neural networks) o Parcialmente recurrentes: al contrario de las unidireccionales existen conexiones entre algunas neuronas de las mismas capas, de las capas anteriores y de las capas posteriores. Algunas de estas son:

Redes recurrentes de Elman: Tienen un número pequeño de unidades en la capa de entrada, tiene una capa oculta, una capa de contexto y una de salida. La información se ingresa en las capas de entrada, pasan a las capas ocultas donde se procesa y pasa a las capas de contexto que memorizan el resultado del análisis de las capas ocultas, después esta información se devuelve a las capas ocultas donde se unen con otros pesos de la capa de entrada y dan un resultado a la capa de salida (86).

Red de Jordan: Tiene un funcionamiento similar a la red de Elman, la diferencia es que en vez que la capa de contexto reciba el análisis de la capa oculta, recibe el análisis de la capa de salida y la lleva a otra capa oculta combinándose con otros pesos de la capa de entrada (85).

Red de Hopfield: Es una red que no tiene sus partes divididas en capas específicas; las neuronas se interconectan en ambas direcciones, la entrada de información se hace en todas las neuronas al mismo tiempo, y no son afectadas por otra información de entrada. Se basa en la memoria asociativa es decir que inicialmente se le muestra a la red una característica determinada y la red la recuerda, cuando se le asigna a la entrada pesos similares, la red los reconoce y los asocia con esta característica dando un resultado. (71, 73).

Según la función de transferencia (75):

Función Lineal: En redes neuronales por lo general se utiliza en la capa de salida acompañada de otras funciones (96), evita restricción de los resultados de la neurona, se usa en la estimación lineal (97).

Función en escalón: Denominada también de umbral o threshold, define la respuesta de la red neuronal en un lenguaje binario (es decir 0 y 1), por medio de un lenguaje condicional (97).

Función sigmoidea: Su ecuación corresponde a  $f(x) = (1 + e^{-x})^{-1}$  (54) y se representa en una gráfica en forma de 'S'. En las redes neuronales permite realizar transformaciones no lineales de las capas de entrada a lineales en las capas ocultas, permitiendo un aprendizaje efectivo con un número reducido de capas ocultas (93, 98).

Función Gaussiana: Hace parte de entre otras de la función de base radial (99), la cual utiliza el principio gaussiano, tiene la capacidad de generalizar los resultados con una cantidad pequeña de nodos (100), son utilizadas en la clasificación de datos (101).

### **2.1.3 Aplicaciones de las redes neuronales**

Las redes neuronales se caracterizan por lograr integrarse con diferentes temáticas, ya que son sistemas fáciles de utilizar, económicas y cuyos conceptos principales de funcionamiento son entendibles (102, 103); Existe una amplia variedad de campos que emplean las redes neuronales artificiales; a continuación se nombrarán algunas:

- Clasificación:

Generalmente, en las redes neuronales se van agrupando los pesos por características similares lo que permite dar una clasificación; es posible hacer que la red catalogue las variables de los datos en grupos específicos predeterminados y que ésta logre retirar los pesos de poca importancia. En ciencias biomédicas este procedimiento se puede dar en varios casos como en la clasificación de masas pancreáticas en imágenes tomadas a través de tomografía computarizada usando una red neuronal unidireccional con 15 unidades de entrada, 15 ocultas y una de salida, con el algoritmo de backpropagation donde 0 indica el carcinoma pancreático y 1 corresponde a masas inflamatorias, los resultados fueron comparables con el análisis de Bayes y el método II de cuantificación de Hayashi (63).

Un uso similar se dio con la clasificación de imágenes mamográficas obtenidas a través de resonancia magnética, utilizando una red perceptron multicapa con 28 nodos en la capa de entrada, 4 en la oculta y 3 en la de salida correspondientes a las categorías carcinoma, lesión benigna y parénquima (104).

También se puede utilizar como soporte para procedimientos en neurocirugía clasificando las características y localización de landmarks en ojos y orejas en imágenes diagnósticas a través de una red neuronal polinomial usando características Gabor o filtro de Gabor como función de transferencia en la capa de entrada, constituyéndose también de una capa oculta y una capa de salida; la expansión dimensional fue controlada por el análisis de componentes principales (PCA) (67).

Por otro lado para determinar anomalías maxilofaciales como la deformidad facial vertical se puede clasificar a través de una red de aprendizaje no supervisada con el algoritmo de Kohonen, determinando categorías como corta, normal y larga, por medio del agrupamiento de las características o clustering (80). Este mismo procedimiento se puede utilizar en antropología para clasificar distintas formas del hueso nasal humano (72).

En ocasiones el proceso de clustering se da por un sistema difuso o fuzzy en combinación con una red neuronal con algoritmo de backpropagation para clasificar inundaciones históricas, haciéndose útil en ingeniería civil para también predecir inundaciones en zonas de alto riesgo (83). La versatilidad en la clasificación se ve reflejada en industria alimentaria en el control de calidad de las carnes, usando imágenes que son inicialmente analizadas por un algoritmo cuaterniónico de descomposición de valores singulares (SVD), que luego se someten a una red neuronal perceptron multicapa con 6 nodos en su capa de entrada, 6 en su capa oculta usando como función de transferencia un algoritmo sigmoideo simétrico de tangente hiperbólica y 4 en su capa de salida para su clasificación dada como A1 alta, A2 y A3 media, y A4 baja; para este fin la red realizó 58 epoch o ciclos (87).

▪ Diagnóstico:

En este proceso la red tiene la capacidad no sólo de clasificar sino de reconocer el problema y en ocasiones la posible solución al mismo. Es común en ciencias biomédicas, ya que es el eje central de estas y las redes permiten que sea más fácil, efectivo y rápido. Sirve para el diagnóstico de diferentes enfermedades urológicas, cardíacas, infecciosas, psiquiátricas, de transmisión sexual, distintos tipos de cáncer y otras, usando principalmente una red perceptron multicapa, con un algoritmo de backpropagation (58, 61, 62, 68, 71).

Las redes pueden servir como ayuda diagnóstica al implementarse dentro de distintos medios para la toma de imágenes como radiografías, resonancia magnética, tomografía computarizada, entre otras (61, 71, 105); existen otras arquitecturas de las redes que pueden cumplir la tarea de diagnosticar; en el estudio de Mario et al., se evaluaron 120 cefalometrías y se trazaron 15 medidas que tenían en cuenta 7 características craneofaciales, la anteroposterior, posición mandibular y maxilar, discrepancias verticales, incisivos superiores e inferiores y posición labial; después se dividieron en tres subcategorías diagnósticas: la unidad I pertenecía a las relaciones anteroposteriores que se diagnosticaron como buena posición, protrusión, retrusión, tendencia a protrusión y tendencia a retrusión; la unidad II pertenecía a la forma de la cara que podía ser normal, vertical y horizontal, y la unidad III correspondía a la posición dental dada como normal, proinclinada, retroinclinada, tendiendo a proinclinada y tendiendo a retroinclinada. Usando una red neuronal paraconsistente se determinaron los índices kappa los cuales se consideraron buenos en 6 regiones menos en la posición labial donde fueron moderados (105). Así mismo se pueden utilizar algoritmos genéticos, de base radial, otras de clase recurrentes (feedback) como la red de Hopfield, sistemas con mapas de autorganización (SOM), teniendo resultados positivos (62, 71).

Este procedimiento puede darse en diversas áreas fuera del contexto de biomedicina como en tecnología ambiental, en el diagnóstico del funcionamiento de las turbinas de microgas para generadores de energía y su control de contaminantes, con un sistema híbrido de redes neuronales perceptron multicapa y sistemas difusos con el algoritmo de backpropagation, usando como criterio de evaluación el método de mínimos cuadrados (106); para el análisis de plantas de energía y monitoreo de su condición, usando también esta arquitectura (107), e incluso se usa en microbiología de alimentos (108).

- Modelamiento:

Permite relacionar los datos de forma robusta, resaltando la información más común y generalizada, situación que es facilitada por las redes neuronales por ser un sistema no lineal; este procedimiento abarca diferentes campos como la ingeniería electrónica en los nanotubos de carbono metálicos - semiconductores de óxido de transistores de efecto de campo (CNT-MOSFET), usados en circuitos de nano escala (88); en ingeniería civil para el modelamiento de fallas de tuberías (89), en tecnología ambiental para el mapeo y modelamiento de la velocidad del viento (90), en botánica para modelamiento de la rizogénesis (91), y para tecnología militar en la realización de prendas protectoras (92), teniendo en común el uso de redes unidireccionales como la perceptron multicapa con un algoritmo de backpropagation.

La arquitectura anteriormente mencionada puede formar redes híbridas con otros compuestos matemáticos, siendo efectivos en el modelamiento y la predicción; un ejemplo es la combinación con el análisis de árbol de fallos usando una función sigmoidea como función de transferencia para determinar las erupciones de gases y carbón de la tierra con fines geológicos (98); otra forma híbrida de esta estructura es cuando se une con el análisis de componentes principales (individuales o combinados) como función de transferencia y se combinan con un algoritmo de regresión por pasos (SR) o con un algoritmo de clasificación de correlación (CR), para analizar la actividad tóxica de algunos compuestos químicos y la capacidad de unión a la albúmina sérica humana (109).

Existe otro tipo de red que cumple con el principio de modelamiento denominada red neuronal dinámica no lineal que utiliza ambos tipos de aprendizaje. En un estudio en psicología se utilizó para la exploración de distintos patrones de conducta, empleando como función de transferencia en la capa de salida la ecuación de Verhulst y como algoritmo de aprendizaje la asociación de Hebbian (110).

- Identificación de un individuo y procesamiento de imágenes:

En ciencias forenses se puede lograr la individualización a través de fotografías mediante superimposición de imágenes o reconocimiento de la red de la imagen facial; este sistema puede llegar a reconocer las variables y determinar el rostro de una persona específica; para esta labor se pueden utilizar redes unidireccionales, redes celulares, redes de Hopfield, y distintos algoritmos de aprendizaje como los de Kohonen, backpropagation, genéticos, entre otros (12, 66, 103). Puede estimar también la edad de muerte de un individuo por medio de restos óseos (sífnisis púbica y superficie auricular del ilion) y precisar la diferencia de edades en sujetos adultos de 20 a 29 años y mayores de 60 años, a través de una red perceptron multicapa con un algoritmo de backpropagation, cuya efectividad fue evaluada con cuadrados medios del error, histogramas de pesos y tasa de buena clasificación (13).

▪ Predicción:

La predicción es uno de los procesos más importantes que realizan las redes neuronales ya que a través del aprendizaje tienen la capacidad de analizar los comportamientos repetitivos de los pesos, permitiendo el pronóstico o la predicción de la información. Para la predicción es necesario conocer a profundidad el problema, las posibles soluciones y la selección de las variables que se le van a asignar a las neuronas, para permitir a la red realizar sus conexiones teniendo en cuenta lo que se considera relevante (60).

Al igual que las aplicaciones de las redes neuronales mencionadas con anterioridad, en la predicción existen empleos muy variados como por ejemplo en ingeniería automotriz para predecir el rendimiento y las emisiones de gases de un motor (79), en ingeniería civil para saber cuánto podría una máquina penetrar una roca (78), o en tecnología industrial para predecir la calidad de una soldadura por láser en la unión térmica de los plásticos (77), principalmente se realiza con una arquitectura multicapa unidireccional con un algoritmo de aprendizaje de backpropagation combinado con otros como el de Widrow – Hoff y el de Leven – Maquard (79); sus funciones de transferencia son la logarítmica sigmoidea u otras como la tasa de penetración (o ROP usada para evaluar las características de la roca en ingeniería civil), y la evaluación de las redes se da por el criterio de los cuadrados medios del error (77-79).

En ciencias de la salud es una herramienta útil para pronosticar la efectividad de un tratamiento usando también la estructura perceptron multicapa con la función de backpropagation (57, 65, 111), con funciones de transferencia como la tangente hiperbólica y criterios de parada específicos (65), o haciendo una acción previa de clustering (111); se usa asimismo para saber el posible número de decesos en un caso clínico especial comparándose con el modelo logístico evaluado por las curvas del receptor característico del operador o curvas ROC (59, 60); Se puede utilizar para el procesamiento de imágenes por ejemplo en la predicción de la forma facial postquirúrgica maxilofacial, ortognática o estética (3), o para la reconstrucción craneomaxilar o cutánea para fines médicos o forenses por medio de una red perceptron autosupervisada con un algoritmo de aprendizaje de Widrow – Hoff, una función de transferencia lineal optoelectrónica (112) o una red ortogonal tridimensional (113).

También se han usado para predecir la morfología y tamaño mandibular a través de variables craneomaxilares, esto se realizó en 50 individuos masculinos y 50 femeninos clase I esquelética de 18 a 25 años, mediante el análisis de radiografías anteroposteriores y de perfil. Se realizaron análisis univariados, medición del error intra e inter observador, análisis de correlación para descartar variables irrelevantes, y análisis de correlación canónica para seleccionar las variables más importantes de los primeros ejes canónicos; esta información se evaluó a través de regresión múltiple multivariada para ser comparada con las redes neuronales con el fin de demostrar su efectividad. La red utilizada fue de aprendizaje supervisado multicapa, que consta de una capa de entrada, dos capas ocultas y una capa de salida, utilizando un software Joone programado con un lenguaje Java, usando como función de transferencia uniones sigmoideas, se efectuaron 10000 epoch, y se usó como criterio de evaluación los mínimos cuadrados medios (2).

## **2.2 Máquinas de Vectores de Soporte**

### **2.2.1 Generalidades**

Las máquinas de vectores de soporte (SVM) son algoritmos de aprendizaje supervisado no paramétrico (114), constituidos de una mezcla de modelos lineales y modelos de aprendizaje (25), se implementan en resolver problemas por medio del reconocimiento de los mismos para clasificación y regresión (114-117); son efectivos en la predicción ya que tienen un conjunto de entrenamiento en el que se etiquetan las clases y se construyen modelos que predigan una nueva muestra (118-121).

Las SVM se basan en el principio de minimización estructural de riesgo, donde se puede definir el error verdadero más bajo para una hipótesis (115). En su forma básica tienen aprendizaje lineal con una función de umbral, pero en presencia de otras funciones como la función kernel, pueden realizar una separación de los datos y no de las características para permitir una medición de la complejidad de las hipótesis (115, 122).

La separación de datos se realiza por medio del hiperplano que es un divisor de un conjunto de datos, que permite definir un límite de decisiones para minimizar los errores durante el entrenamiento, creando de esta manera una función de alta dimensionalidad (114, 117, 123).

En su forma lineal o binaria, el hiperplano se define con la ecuación  $x = w_0 + w_1 a_1 + w_2 a_2$  (25), se compone por los atributos específicos ( $a$ ) con los pesos ( $w$ ) de aprendizaje, que se van agrupando para formar dos conjuntos, en estos existen puntos denominados vectores de soporte que son los puntos más cercanos al hiperplano que lo definen trazándolo como una línea equidistante a éstos, dependiendo del ruido que contengan los datos (25, 115, 117, 124); se dan por la ecuación  $x = b + \sum \alpha_i y_i \mathbf{a}_{(i)} * \mathbf{a}$ , donde  $b$  y  $\alpha_i$  reemplazan a los parámetros dados por los pesos, y los vectores de soporte son representados por  $\mathbf{a}_{(i)}$  y  $\mathbf{a}$ ;  $\alpha_i$  puede ser también un valor negativo en el caso de la predicción (25).

En el proceso donde no se maneja un ejemplo lineal sino que es un espacio transformado de alta dimensionalidad, en casos que lo ameriten como tener que clasificar los datos en más de dos grupos o tener más de dos variables predictoras, se basa en la ecuación  $x = b + \sum \alpha_i y_i (\mathbf{a}_{(i)} * \mathbf{a})^n$ , donde  $n$  es el número de factores en la transformación (25). Para evitar que haya un número de atributos grandes e inmanejables debido a la



exponencialidad de la ecuación anterior, se regulan estos problemas a través de la función de kernel, definida en su forma simple como  $K(x,y) = \Phi(x) * \Phi(y)$ , siendo  $\Phi$  la función que mapea las muestras de entrenamiento desde un espacio de entrada (input) a uno de características (feature) de gran dimensionalidad para construir un hiperplano óptimo, que después dará un resultado o salida (25, 122, 124, 125).

En ocasiones el hiperplano puede ser 'soft margin' o de margen flexible que se usa cuando los datos no son linealmente separables; para lograr la división más adecuada y aproximada de los datos se utiliza un parámetro de costo  $C$  que permite la compensación o equilibrio entre los errores encontrados y los márgenes linealmente separables o márgenes, minimizando las muestras sin catalogar, penalizándolas (25, 124-127).

La envoltura convexa o 'Convex hulls' se encargan principalmente de servir de intersección de los conjuntos que contienen a  $X$  en cualquier dimensión, es decir que es una estructura geométrica que envuelve a la mayoría de datos en común (128); este concepto toma importancia cuando se envuelven los datos según sus atributos y sus pesos facilitando la separación de los mismos y permitiendo de una manera más fácil establecer un hiperplano de separación, así como los vectores de soporte que lo definirán, con la ventaja de adaptarse al margen ya sea rígido o flexible (125, 129).

### **2.2.2 Clasificación e hiperplano de margen máximo**

Las SVM se encargan esencialmente de clasificar debido a que encuentran un hiperplano que separa los datos de entrenamiento con un margen máximo, luego este será formulado como un problema de optimización cuadrática (25, 116, 117), es decir se dará la mayor separación entre las clases (114, 117).

El hiperplano de margen máximo evita la complejidad computacional, el sobreajuste estadístico o reentrenamiento de los algoritmos, facilitando el aprendizaje de las SVM, ya que este proceso se repite hasta encontrar un límite óptimo entre ambos conjuntos (25, 114, 117, 130).

La clasificación se facilita en casos donde la decisión es binaria, pues asigna solo dos características y los vectores de soporte se encargan de ubicar el hiperplano, un ejemplo es si tiene o no controles regulares de cáncer de colon, con el fin de crear un sistema de puntaje que estime la propensión a una condición patológica (123).

También pueden clasificar esquemas de señales de electroencefalogramas (EEG) de una dimensión, en combinación con el principio de minimización del riesgo estructural (SRM) para lograr una generalización adecuada, teniendo un intervalo de confianza y disminuyendo los errores de entrenamiento junto con una correlación cruzada, para realizar un reconocimiento de patrones que permita el diagnóstico preciso de enfermedades que no son fáciles de visualizar como la epilepsia. Se reportaron tres tipos de kernels, el polinomial ( $K(x,y) = (1 + x * y)^m$ ), el perceptron multicapa ( $K(x,y) = \tan h(x * y - \theta)$ ) y el de función de base radial o gaussiano ( $K(x,y) = \exp(-\|x - y\|^2 / 2\sigma^2)$ ) (116), este último siendo el más usado por su gran precisión para resolver problemas de clasificación (25, 116, 122).

Por otro lado, las SVM se pueden aplicar en la categorización de texto, clasificando los documentos en grupos predeterminados, excluyendo las palabras de parada como 'Y' (and), 'O' (or), 'NO' (Not), 'Y NO' (And Not), y teniendo en cuenta las denominadas palabras clave, las cuales cada una representa una característica distinta por lo que se le asigna un peso ( $w_i$ ) clasificadorio, usando un kernel polinomial y un kernel de función de base radial, dando buenos resultados en comparación con otros clasificadores; entre éstos, el mejor fue el de base radial aunque el polinomial tuvo resultados importantes (115).

Otra de las aplicaciones que puede tener es en teledetección remota de imágenes aéreas y satelitales, para usos en diferentes situaciones como en geología, fotogrametría, clasificación vegetal, entre otras; se han intentado varias metodologías combinando algoritmos genéticos, de base radial, sigmoideos, entre otros con resultados satisfactorios. La clasificación puede complementarse con otros sistemas que pueden usarse para tareas de clasificación supervisada y no supervisada, en datos de entrada incompletos, en ejemplos de entrenamiento difíciles y que llevan tiempo, en situaciones binarias o hiperdimensionales; cada vez se intenta realizar esta actividad con elementos

que permitan facilitarle al investigador el uso de las máquinas de soporte, minimizando el tiempo (114).

### 2.2.3 Regresión por Vectores de Soporte (SVR)

La SVR se generaliza de las SVM cuando el reconocimiento de patrones  $y \in \{+1, -1\}$ , se ajusta a la estimación de funciones reales  $y \in \mathbb{R}$ , a través de la función de costo (pérdida)  $\epsilon$ -insensitiva  $|y - f(x)|_{\epsilon} := \max\{0, |y - f(x)| - \epsilon\}$ , que no penaliza los errores que estén por debajo de  $\epsilon \geq 0$  (131).

Así mismo en la SVR se encuentra una minimización del error absoluto de predicción, donde no se maneja un hiperplano de margen máximo, sino que se utiliza un límite superior  $C$  en  $\alpha$ , ajustando los datos o se implementan funciones kernel o el 'truco kernel' (25, 124, 125, 127).

Una aplicación de la SVR está en la evaluación de la calidad de la cilindricidad, que se utiliza en la fabricación de piezas de forma redonda para propósitos tecnológicos e industriales, con el fin de ofrecer una alternativa rápida, eficiente y robusta a los mínimos cuadrados, que normalmente se utilizan en la determinación del error de redondez de estas partes. Se tuvo en cuenta el espacio formado entre dos círculos estándares digitales, uno interno y otro externo, y una cámara especializada que tomaba la imagen del objeto descomponiéndola en puntos y cortes; por medio de la SVR con kernels específicos se evaluó el radio del objeto, la varianza, la altura, número de puntos por corte transversal, y número de cortes transversales, determinando si los puntos del objeto que se estaba viendo estaban dentro del espacio, pues si estaban fuera de este ya era considerado un error. La SVR utilizó algoritmos precisos en la examinación de la forma cilíndrica de cualquier muestra de puntos de datos (130).

Así mismo se podría aplicar en el monitoreo del estado de pacientes posquirúrgicos, teniendo en cuenta datos de alta dimensionalidad, integrando datos numéricos y aspectos cualitativos como la experiencia; con el fin de abstraer, clasificar e inferir

información, para predecir las respuestas del paciente a algunas drogas, teniendo un seguimiento adecuado bajando el potencial de efectos adversos (117).

Las funciones Kernel se asocian con las SVM cuando establecen un modelo que se encarga de seleccionar características, extraer reglas y predecir datos (Máquinas de vectores de soporte con kernel múltiple ó MK-SVM), con aplicación médica, observando datos extraídos a partir de perfiles genéticos de tejidos cancerosos usando técnicas de microarrays para mejorar el diagnóstico y tratamiento del cáncer (Leucemia y cáncer de colon); se tiene en cuenta que muchos datos encontrados poseen altos niveles de ruido que dificulta las acciones linealmente separables, por eso se emplea una función de kernel múltiple que permite un diagnóstico positivo o negativo para cada condición patológica, determinando la extracción de reglas para observar el porcentaje de falsos negativos y niveles de ruido de los datos; previa a la extracción, se seleccionaron los genes relevantes a través del kernel múltiple II para predecir los tipos de muestras más adecuadas que explicarían el diagnóstico de la enfermedad (122).

Los kernels también son efectivos en la predicción de alta dimensionalidad y los más utilizados son los de base radial (RBF) y polinomiales, la idea es que a través de estos se logren tener parámetros óptimos de entrenamiento por medio de la integración con algoritmos genéticos con codificación real (RCGA), que permiten minimizar el error cuadrático medio (RMSE); esto es aplicable para predecir la respuesta afectiva de los consumidores para el diseño de un producto y sus características por medio de formularios, los cuales fueron examinados sistemáticamente y divididos como atributos continuos o discretos. Las respuestas de los consumidores recolectadas de los formularios fueron puestas como datos de entrada y los puntajes obtenidos de los cuestionarios se asignaron como los valores de salida. De ambos kernels el más efectivo sacó un error de predicción de 0.078 que fue el kernel de base radial, mientras el polinomial sacó un error de 0.181 (121).

Uno de los usos más comunes en la SVR está en los movimientos bancarios para evitar las fallas que podrían causar la pérdida de recursos monetarios, prediciendo el riesgo de bancarrota; para esto también se han usado modelos construidos por redes neuronales y métodos estadísticos multivariados; la precisión y generalización de la SVM es mejor que

las redes neuronales con algoritmos de Backpropagation si los datos son pequeños; sin embargo, es importante que en situaciones delicadas como en este tipo de predicción se empleen métodos efectivos y que se comparen los unos con los otros, es decir, que haya una integración de métodos de regresión, ya que en otros datos se pueden encontrar una mayor precisión en cuanto a predicción por parte de las redes neuronales perceptrón multicapa (118); Así mismo también se puede predecir el movimiento del índice del precio de las acciones que se incluye dentro del ámbito financiero teniendo resultados parecidos con respecto a la ventaja de las redes neuronales frente a las SVM (119).

Aunque es bien conocida la ventaja en cuanto a predicción de los algoritmos de aprendizaje con respecto a modelos lineales, por lo general las redes neuronales y las máquinas de vectores de soporte mantienen valores de predicción muy cercanos, y utilizar cualquiera de estos dos métodos es adecuado, como sucede para determinar la capacidad de predicción de los perovskitas, en los radios iónicos de los elementos constitutivos para usarse en el campo de los materiales estructurales en el ámbito industrial (120).

En el campo odontológico son escasos los estudios con las máquinas de vectores de soporte, sin embargo se ha reportado su empleo para identificación de landmarks; tal es el caso de Chakrabarty et.al, que por medio de un clasificador de gran margen con algoritmos gráficos y un kernel Gaussiano, determinaron un 98% de precisión en la clasificación de deformidades dentales y detección de puntos anatómicos, teniendo en cuenta 1 mm de valor de tolerancia (132); también se han usado para la predicción del tratamiento en la maloclusion Clase III, en el caso de Kim, et.al, con un algoritmo de búsqueda secuencial y un kernel polinomial. Con este método se obtuvo una precisión del 97.37% (133).



## **3. Metodología**

En esta investigación aplicada, la población diana fueron personas de ambos sexos, con maloclusión esquelética Clase I, II o III, de nacionalidad colombiana, que participaron en las convocatorias para diagnóstico esquelético craneofacial del proyecto de Biometría de la línea de Crecimiento y Desarrollo de la Maestría en Odontología de la Universidad Nacional de Colombia. El tipo de muestreo fue no probabilístico de conveniencia.

### **3.1 Criterios de Inclusión**

- Buen estado de salud general.
- Dentición permanente completa con o sin terceros molares.
- Padres y abuelos colombianos, con características de patrón ancestral similares.

### **3.2 Criterios de Exclusión**

- Intervención en rehabilitación oral en sector anterior y/o posterior.
- Tratamiento previo de ortodoncia y/o ortopedia.
- Cirugía ortognática y/o estética previa.
- Hábitos parafuncionales severos.
- Malformaciones congénitas o adquiridas.

### 3.3 Consideraciones Éticas

La investigación propuesta fue realizada en seres humanos y se ajustó a principios científicos y éticos, se tuvo en cuenta la resolución número 008430 de 1993 de la Ley 84 de 1989, en donde clasificó al presente estudio como “Investigaciones con riesgo mayor que el mínimo”. La información obtenida de cada individuo fue guardada en absoluta reserva para el cumplimiento del artículo 8 (Título II, capítulo 1) y fue utilizada para los fines estipulados en el estudio.

El manejo de la información resultante de este estudio también se encontró dentro de las legislaciones nacional e internacional sobre investigaciones en el área de la salud. Se utilizaron códigos y no nombres propios, de esta forma se garantizó la confidencialidad y privacidad. Asimismo, la participación de los pacientes fue completamente voluntaria y estuvo dirigida a individuos que acudieron solicitando atención en servicios de ortodoncia.

Para cumplir con el artículo 14 de la resolución mencionada se diligenció un consentimiento informado (Anexo B) y una cartilla de información (Anexo C). El paciente tenía el derecho a retirarse en cualquier momento si así lo decidiera, e igualmente podía conocer el resultado de los análisis.

Con respecto al beneficio que este trabajo produjo directamente a los individuos fue la de una mayor precisión diagnóstica basada en los resultados globales del estudio con un menor costo por este servicio. El riesgo que implicó la investigación se justificó en que de cualquier forma había necesidad de estos registros para la realización del diagnóstico y el plan de tratamiento ortodóntico o quirúrgico correspondiente y los resultados del estudio podían traer beneficios futuros por la posibilidad de predecir la morfología de la mandíbula de un nuevo individuo con mayor precisión, logrando un tratamiento más efectivo.

En cuanto a beneficios para la comunidad, estas técnicas de predicción en un futuro permitirán considerar la variabilidad biológica en las maloclusiones teniendo en cuenta su prevalencia (20), para ser empleadas en el método de identificación, que toma



importancia dentro del marco de violencia que el país ha vivido, donde se han encontrado fosas comunes y se hace necesario para los familiares de las víctimas comenzar con el proceso de duelo (42).

La publicación de los resultados de este estudio se ha realizado a través de conferencias nacionales e internacionales, en los que no se han revelado ni se revelarán datos de identificación de los individuos.

### **3.4 Procedimientos**

Dentro de este estudio se probaron distintas metodologías puesto que los antecedentes de aplicación de las máquinas de vectores de soporte y las redes neuronales para clasificación de maloclusiones esqueléticas y predicción de variables mandibulares a partir de las craneomaxilares son casi inexistentes; a continuación se observan los pasos realizados hacia la primera experimentación que es la clasificación de maloclusiones dadas por el sistema de Metronukak, posteriormente las diferentes metodologías empleadas después de este método se observan en la sección de resultados, debido a que la explicación de los procedimientos se fue efectuando a medida que se iban obteniendo resultados de clasificación y predicción, para establecer una metodología efectiva.

#### **3.4.1 Recolección de la muestra**

La muestra se obtuvo de diferentes lugares como el área de Salud de Bienestar Universitario, Facultad de Odontología y el campus de la Universidad Nacional de Colombia; Fundación Universitaria San José, Instituto Triángulo, Universidad Católica, consultas particulares, entre otros; los pacientes se seleccionaron inicialmente con una rápida visualización de la clasificación de Angle molar y canina y el perfil clínico; al ver que el paciente cumplía con los criterios de inclusión y firmaba el consentimiento informado se remitió al centro radiológico.

La estandarización se llevó a cabo de la siguiente manera:

- Equipo Radiográfico:

Para la toma de las radiografías posteroanteriores y de perfil se utilizó un único equipo de rayos X Veraviewepocs de J Morita; se tuvo en cuenta una distancia estándar de sujeto a película de 15 cm y de cono a película de 150 cm. Este equipo operó a 80 kv, 3mA y 4s, por radiografía. Las radiografías se tomaron con posición natural de cabeza, con testigo métrico, en oclusión habitual e imagen al 100%.

- Software de Digitalización

Este equipo radiográfico contaba con un software que inmediatamente digitalizaba las imágenes ahorrando tiempo y dinero en la impresión y posterior escaneo de las mismas. El software cliniview permitía la adquisición, procesamiento, visualización y almacenamiento de las imágenes en formato jpg de 12 bits.

### **3.4.2 Selección de variables: medidas lineales y angulares en el programa Metronukak**

Después de obtener las radiografías se realizó la clasificación esquelética según el Ángulo ANB a través del software Metronukak, desarrollado por el centro de Telemedicina de la Universidad Nacional de Colombia (2) y se hizo la posterior codificación como compromiso de confidencialidad de nombres de los pacientes; asimismo, se les hacía la retroalimentación de dicha clasificación y de otros aspectos que se encontraran en esas radiografías con sus respectivas sugerencias.

**Tabla 3-1:** Clasificación según ANB

Variable	Valores límites		
	Clase I	Clase II	Clase III
Ángulo ANB	0,1 – 3,9	≥ 4	≤ 0

En total se obtuvieron inicialmente los datos de 216 pacientes, que se distribuyeron según esa clasificación dada por el ángulo ANB de la siguiente manera:

**Tabla 3-2:** Clasificación de los pacientes recolectados en método metronukak. N=216

	Clase I	Clase II	Clase III
<b>Femenino</b>	44	19	24
<b>Masculino</b>	57	33	39
<b>Total</b>	101	52	63


Se seleccionaron las variables correspondientes a medidas cefalométricas craneomaxilares y mandibulares de radiografías posteroanteriores y de perfil (2, 134-139):

**Tabla 3-3:** Variables para radiografía de posteroanterior.

Calib1 – Calib2	Corresponden a puntos predeterminados para confirmar la verosimilitud de las medidas, es decir para verificar que la escala de las radiografías sea 1:1. (Ancho es de 18.5 para que dé escala exacta)  En radiografías con testigo métrico se escogen dos puntos de la reglilla, que correspondan a un centímetro.
<b>Complejo Craneo-maxilar</b>	
<b>Lineales (Medidos en cm)</b>	
<b>Medida</b>	<b>Descripción</b>
Fzd – Fzi	Distancia entre el punto medial de la sutura frontocigomática derecha y de la izquierda
Zyd – Zyi	Ancho bicigomático
Masd – Masi	Distancia entre las apófisis mastoides
Jd – Ji	Plano Yugal

Cr – ENA	Mide altura facial superior. Línea de referencia: Distancia de Crista Galli a ENA, que al prolongarse (LMS) permite saber la línea media y determinar asimetrías
Cr – Jd	Volumen maxilar superior derecho
Cr – Ji	Volumen maxilar superior izquierdo
ENA – Pr	Altura Maxilar Superior
<b>Angulares (Medidos en grados)</b>	
Jd – Cr – Ji	Ángulo yugal derecho crista galli yugal izquierdo
<b>Mandibulares</b>	
<b>Lineales (Medidos en cm)</b>	
Cdd – Cdi	Distancia bicondilar
God – Goi	Distancia Bigoníaca
Cdd – Me	Condilion derecho a menton
Cdi – Me	Condilion izquierdo a menton
Cdd – God	Altura de la rama mandibular derecha
Cdi – Goi	Altura de la rama mandibular izquierda
God – Me	Ancho del cuerpo mandibular derecho
Goi – Me	Ancho del cuerpo mandibular izquierdo
ENA – Me	Altura facial inferior
Id – Me	Altura Mandibular
<b>Angulares (Medidos en grados)</b>	
Cdd – God – Me	Ángulo goníaco derecho
Cdi – Goi – Me	Ángulo goníaco izquierdo
Cdd – Me – Cdi	Angulo bicondilar
Goi – Me – God	Angulo cuerpo mandibular

**Figura 3-1:** Variables para radiografía posteroanterior




**Tabla 3-4:** Variables para radiografía de perfil

Calib1 – Calib2	Corresponden a puntos predeterminados en el testigo métrico, que deben dar un centímetro como resultado para confirmar la verosimilitud de las medidas, es decir para verificar que la escala de las radiografías sea 1:1. (Ancho para calibración 1:1 es de 23 cm).
<b>COMPLEJO CRANEO-MAXILAR</b>	
<b>Lineales (Medidos en cm)</b>	
<b>Medida</b>	<b>Descripción</b>
S – N	Mide longitud de base de cráneo anterior.
S – Ba	Mide longitud de base de cráneo posterior.
N – Ba	Longitud total de base de cráneo
ENA – ENP	Plano palatino
N – ENA	Medición de la dimensión vertical superior facial
Ptm – ENP	Altura Maxilar Superior (Parte Posterior)
ENA – Pr	Altura Maxilar Superior (Parte Anterior)
Ao-Bo (Witts)	Proyección del punto A y del punto B sobre el plano oclusal.
<b>Angulares (Medidos en grados)</b>	

SNA	Indica la posición anteroposterior del hueso maxilar en relación con la parte anterior de la base craneal.
N – S – Ba	Ángulo de la base craneal
<b>MANDIBULARES</b>	
<b>Lineales (Medidos en cm)</b>	
Cd – Go	Altura rama mandibular
Cd – Gn	Longitud total mandibular
Go – Gn	Longitud del cuerpo mandibular
ENA – Gn	Medición de la dimensión vertical inferior facial
Id – Gn	Altura Mandibular
<b>Angulares (Medidos en grados)</b>	
SNB	Posición del maxilar inferior
ANB	Indica clasificación esquelética
S – N / Gn – Go	Determina inclinaciones del maxilar inferior con respecto a base del cráneo
Ba – N / Ptm – Gn	Eje de crecimiento
ENA – ENP / Go – Gn	Determina inclinaciones del maxilar inferior con respecto al plano palatino

**Figura 3-2:** Variables para radiografía de perfil



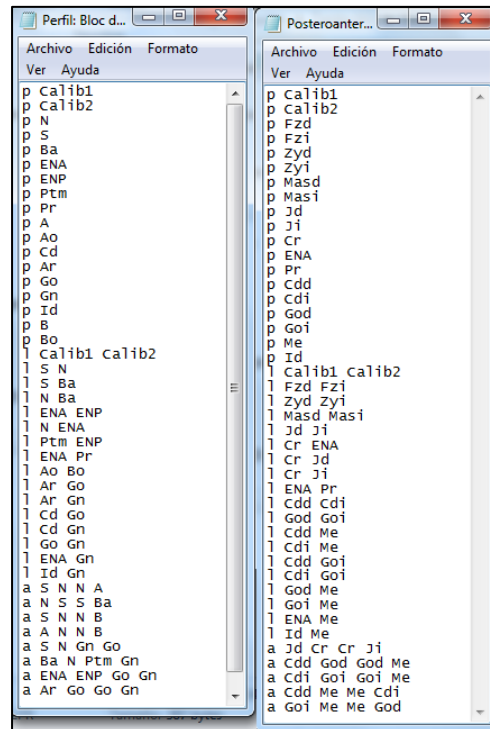
### 3.4.3 Medición de las imágenes radiográficas

Las distancias y ángulos anteriormente mencionados fueron medidos a través del software Metronukak.

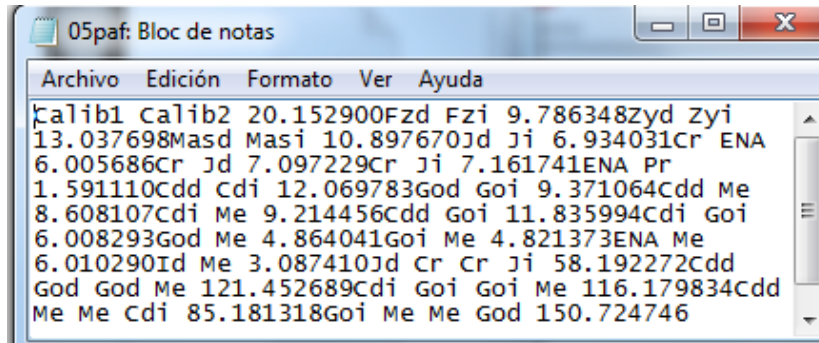
En este software, se realizaron dos protocolos de medición en el programa Notepad, uno para la radiografía frontal y el otro para la radiografía de perfil, donde se usan tres comandos especiales: 'p' para puntos que son las variables mencionadas con anterioridad, 'l' para mediciones lineales entre esos puntos y 'a' para ángulos.

Después de verificar la escala 1:1 mediante la medida de calib1 y calib2, el software se encargó de procesar las medidas lineales y los ángulos.

**Figura 3-3:** Protocolos de uso para software Metronukak



Después el sistema creó un nuevo archivo en el que se encuentran las medidas, en el cual el decimal se representa por un punto, por lo tanto al pasarlo a un archivo en Excel se debía hacer la transformación en comas evitando errores de lectura en el software. En Excel se guarda el archivo con la extensión .csv.

**Figura 3-4:** Resultados de medidas del software Metronukak

### 3.5 Medición del error intra e interobservador

El análisis de repetibilidad intra e inter observador se hizo con la asesoría de estudiantes de pregrado del Departamento de Estadística de la Universidad Nacional de Colombia, en 60 radiografías escogidas al azar, 30 de perfil y 30 posteroanteriores. Se realizó por medio del coeficiente de Dahlberg y la Prueba T Pareada.

Para el análisis inter-observador la medición fue realizada entre 2 personas, el observador 1 (P1), corresponde a aquella persona con experticia en el campo ortodóntico y antropológico; el observador 2 (P2) corresponde a la persona que realizaría las medidas definitivas en los pacientes. La calibración de los puntos se realizó por medio del programa Metronukak, con protocolos de ubicación de landmarks que se observan en la Tabla 3-5 y la Tabla 3-6 para radiografías de perfil y en la Tabla 3-7 y 3-8 para las radiografías posteroanteriores. Así mismo se realizó el análisis intraobservador en dos mediciones (P2 y P3) con intervalos de dos semanas.

**Tabla 3-5:** Coeficiente de Dahlberg en radiografías de perfil (N=30).

Interobservador Perfil (P1-P2)		Intraobservador Perfil (P2-P3)	
AoBo	<u>0,20</u>	AoBo	0,04
SNA	0	SNA	0



SNB	0	SNB	0
ANB	0	ANB	0
ENAENPGoGn	0	ENAENPGoGn	0
SN	0,02	SN	0,01
SBa	0,04	SBa	0,02
NBa	0,02	NBa	0,01
ENAENP	0,03	ENAENP	0,02
NENA	0,03	NENA	0,01
PtmENP	0,04	PtmENP	0,02
ENAPr	0,08	ENAPr	0,02
ArGo	0,05	ArGo	0,02
ArGn	0,02	ArGn	0,00
CdGo	0,04	CdGo	0,02
CdGn	0,02	CdGn	0,01
GoGn	0,02	GoGn	0,01
ENAGn	0,02	ENAGn	0,03
IdGn	0,04	IdGn	0,03
NSBa	0	NSBa	0
SNGnGo	0	SNGnGo	0
BaNptmGn	0	BaNptmGn	0
ArGoGn	0	ArGoGn	0
CdGoGn	0	CdGoGn	0

En la medición del error, para el coeficiente de Dahlberg la mayor diferencia fue en Ao-Bo de 2 mm en el interobservador, mientras que en el intraobservador las diferencias fueron menores del milímetro.

**Tabla 3-6:** Prueba T pareada en radiografías de perfil (N=30)

Medidas	T pareada Interobservador			T pareada Intraobservador		
	t	Media de las diferencias	Sig, (bilateral) p-value	t	Media de las diferencias	Sig, Bilateral
AoBo	-1,014	-0,106	0,319	1,010	0,081	0,321
SNA	0,430	0,084	0,670	-0,510	-0,027	0,614
SNB	0,216	0,042	0,831	-0,564	-0,032	0,577
ANB	0,272	0,042	0,788	0,061	0,005	0,952
ENAENPGoGn	-0,001	0,000	0,999	0,303	0,024	0,764
SN	-0,028	-0,001	0,978	-0,265	-0,003	0,793

<b>SBa</b>	1,430	0,065	0,163	0,581	0,011	0,566
<b>NBa</b>	1,155	0,054	0,258	0,369	0,005	0,715
<b>ENAENP</b>	-2,468	-0,095	<b>0,020</b>	1,134	0,026	0,266
<b>NENA</b>	-0,711	-0,032	0,483	2,164	0,031	<b>0,039</b>
<b>PtmENP</b>	0,660	0,018	0,514	-0,052	-0,001	0,959
<b>ENAPr</b>	-0,890	-0,029	0,381	0,806	0,009	0,427
<b>ArGo</b>	0,717	0,049	0,479	-0,348	-0,010	0,731
<b>ArGn</b>	-0,124	-0,006	0,903	-3,115	-0,026	<b>0,004</b>
<b>CdGo</b>	-0,364	-0,024	0,719	0,218	0,005	0,829
<b>CdGn</b>	-0,333	-0,021	0,741	-0,756	-0,023	0,456
<b>GoGn</b>	-0,112	-0,004	0,911	-1,062	-0,023	0,297
<b>ENAGn</b>	-2,634	-0,083	<b>0,013</b>	-1,156	-0,052	0,257
<b>IdGn</b>	-1,135	-0,036	0,266	-0,710	-0,014	0,483
<b>NSBa</b>	0,449	0,168	0,657	0,079	0,006	0,937
<b>SNGnGo</b>	0,283	0,075	0,779	-2,007	-0,129	0,054
<b>BaNPtmGn</b>	0,740	0,215	0,465	-1,983	-0,126	0,057
<b>ArGoGn</b>	0,403	0,100	0,690	0,037	0,003	0,971
<b>CdGoGn</b>	-0,161	-0,059	0,874	1,226	0,086	0,230

En la prueba T pareada para la evaluación interobservador, los valores con diferencias significativas para un  $p < 0.05$  fueron ENA-ENP (Plano palatino) y ENA-Gn. Para el intraobservador se observó que existían diferencias significativas en N-ENA y Ar-Gn.

**Tabla 3-7:** Coeficiente de Dahlberg en radiografías posteroanteriores (N=30)

Interobservador Posteroanterior (P1-P2)		Intraobservador Posteroanterior (P2-P3)	
<b>Fzd - Fzi</b>	0,05	<b>Fzd - Fzi</b>	0,04
<b>Zyd - Zyi</b>	0,04	<b>Zyd - Zyi</b>	0,04
<b>Masd - Masi</b>	0,05	<b>Masd - Masi</b>	0,06
<b>Jd - Ji</b>	0,05	<b>Jd - Ji</b>	0,03
<b>Cr - ENA</b>	0,11	<b>Cr - ENA</b>	0,06
<b>Cr - Jd</b>	0,08	<b>Cr - Jd</b>	0,04
<b>Cr - Ji</b>	0,08	<b>Cr - Ji</b>	0,06
<b>ENA - Pr</b>	0,09	<b>ENA - Pr</b>	0,05
<b>Cdd - Cdi</b>	0,03	<b>Cdd - Cdi</b>	0,05
<b>God - Goi</b>	0,06	<b>God - Goi</b>	0,06
<b>Cdd - Me</b>	0,04	<b>Cdd - Me</b>	0,03

Cdi - Me	0,03	Cdi - Me	0,02
Cdd - God	0,07	Cdd - God	0,06
Cdi - Goi	0,07	Cdi - Goi	0,04
God - Me	0,05	God - Me	0,06
Goi - Me	0,07	Goi - Me	0,04
ENA - Me	0,00	ENA - Me	0,00
Id - Me	0,06	Id - Me	0,04
Jd - Cr - Ji (Grados)	0	Jd - Cr - Ji (Grados)	0
Cdd - God - Me (Grados)	0	Cdd - God - Me (Grados)	0
Cdi - Goi - Me (Grados)	0	Cdi - Goi - Me (Grados)	0
Cdd - Me - Cdi (Grados)	0	Cdd - Me - Cdi (Grados)	0
Goi - Me - God (Grados)	0	Goi - Me - God (Grados)	0

Para las radiografías posteroanteriores, los resultados muestran un bajo error en general en el coeficiente de Dahlberg, sobretodo en las medidas angulares tanto en el interobservador como en el intraobservador.

**Tabla 3-8:** Prueba T pareada en radiografías posteroanteriores (N=30)

Medidas	T pareada Interobservador			T pareada Intraobservador		
	t	Media de las diferencias	Sig, (bilateral) p-value	t	Media de las diferencias	Sig, (bilateral) p-value
CddCdi	0,335	0,033	0,740	-0,686	-0,094	0,498
CddGod	0,010	0,001	0,992	0,025	0,002	0,980
CddGodMe	-0,072	-0,105	0,943	0,056	0,081	0,956
CddMe	-0,058	-0,005	0,954	0,128	0,011	0,899
CddMeCdi	-0,096	-0,064	0,925	0,036	0,020	0,972
CdiGoi	0,003	0,000	0,997	0,034	0,002	0,973
CdiGoiMe	1,357	2,123	0,185	0,046	0,063	0,964
CdiMe	0,148	0,009	0,884	0,100	0,004	0,921
CrENA	0,211	0,032	0,835	-0,084	-0,007	0,934
CrJd	-0,143	-0,018	0,888	-0,281	-0,020	0,781
CrJi	-0,011	-0,001	0,992	-0,040	-0,004	0,968
ENAMe	-1,641	-0,007	0,112	-1,809	-0,005	0,081
ENAPr	0,119	0,005	0,906	-0,090	-0,002	0,929

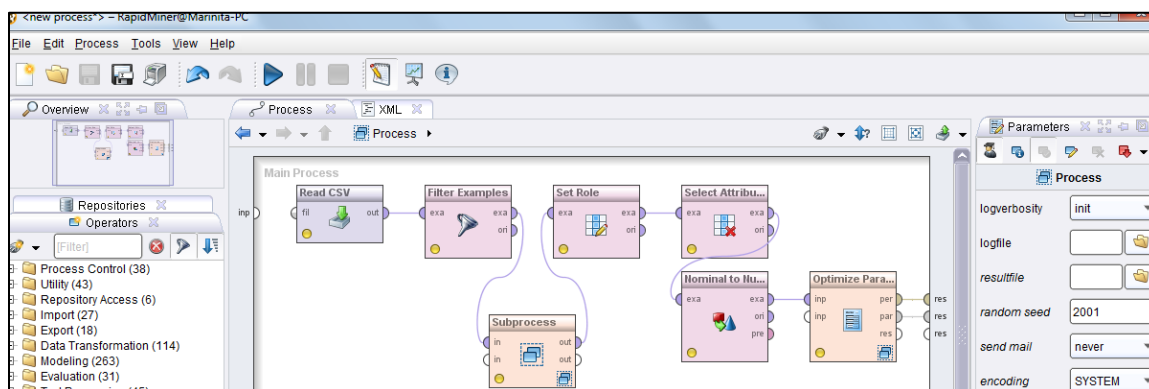
<b>FzdFzi</b>	0,005	0,001	0,996	0,037	0,004	0,971
<b>GodGoi</b>	-0,158	-0,025	0,876	0,063	0,010	0,950
<b>GodMe</b>	-0,258	-0,018	0,798	0,043	0,004	0,966
<b>GoiMe</b>	0,019	0,002	0,985	-0,053	-0,003	0,958
<b>GoiMeGod</b>	-0,029	-0,041	0,977	0,007	0,010	0,995
<b>IdMe</b>	-0,257	-0,012	0,799	0,199	0,006	0,844
<b>JdCrJi</b>	-0,052	-0,063	0,959	-0,390	-0,284	0,699
<b>JdJi</b>	-0,113	-0,009	0,911	-0,112	-0,006	0,912
<b>MasdMasi</b>	-0,113	-0,015	0,911	0,022	0,004	0,982
<b>ZydZyi</b>	-0,058	-0,008	0,954	-0,013	-0,002	0,990

Para la prueba T pareada, tanto en el interobservador como en el intraobservador, no hay valores menores a 0.05, esto se debe posiblemente a la nitidez de las radiografías y la estandarización de las mismas que permiten una buena repetibilidad de los puntos.

### 3.6 Pruebas con algoritmos de Aprendizaje para clasificación con método de medición Metronukak

El software utilizado para las tareas de clasificación y predicción fue el software Rapidminer, que permite la utilización de varios algoritmos entre estos las redes neuronales artificiales y las máquinas de vectores de soporte.

Figura 3-5: Software Rapidminer



Para cumplir con el primer objetivo específico de clasificar individuos en Clase I, II y III esquelética utilizando técnicas de aprendizaje automatizado, fue necesario eliminar el parámetro ANB, el SNA y SNB ya que el programa podría constituir una relación de resta entre estos dos últimos estableciendo el ANB y clasificándolo correctamente con un alto porcentaje.

Inicialmente se elaboró una clasificación por default con redes neuronales y máquinas de vectores de soporte, teniendo en cuenta variables de radiografías de perfil y posteroanteriores, al no obtener resultados satisfactorios se realizó una unión de los datos de ambas radiografías.

Adicionalmente se efectuó un balanceo de clases, debido a las diferencias de muestra entre éstas (por ejemplo: 101 pacientes clase I vs. 52 y 63 pacientes de la clase II y la clase III, respectivamente) y mejoró el resultado aunque no de manera importante en las radiografías de perfil.

Es por eso que se aplicó un método Grid para determinar los parámetros de optimización; en las radiografías de perfil balanceado, el sistema determinó que la mejor precisión (accuracy) se daba con una tasa de aprendizaje (learning rate) de 0.1, un impulso (momentum) de 0.85 en 500 ciclos (cycles).

Para las máquinas de vectores de soporte se realizó lo mismo; el sistema determinó que la mejor precisión para el perfil balanceado y sin balancear se daba con un gamma ( $\gamma$ ) de  $8E-4$  y un C de 90.26; para las radiografías posteroanteriores determinó que era apropiado utilizar un  $\gamma$  de  $1.0E-5$  y un C de 81.019; finalmente para la unión de los datos de ambas radiografías, el  $\gamma$  era de  $1.0E-5$  y el C de 90.0.

De lo anterior se obtuvieron resultados que se pensó que podrían ser mejores, por esta razón se decidió realizar la predicción del ángulo ANB con redes neuronales a partir del resto de variables craneofaciales donde el valor en términos de error cuadrático medio fue de 2.295, con ese valor predicho se realizó la clasificación de maloclusiones esqueléticas; para dicha clasificación, se optimizaron los parámetros en donde se unieron

los datos de radiografías de perfil y posteroanteriores (Todo) con el perfil balanceado; para las redes neuronales se determinó una tasa de aprendizaje de 0.09, un impulso de 0.001 en 1000 ciclos y para las máquinas de vectores de soporte el  $\eta$  era de  $1.0E-4$  y el  $C$  de 90.0. En la Tabla 4-1 y 4-2 se puede observar que tanto para redes neuronales como para las máquinas de vectores de soporte dieron el mismo porcentaje de precisión, mejorando notablemente. En la Figura 4-1 se pueden observar los detalles en la precisión de la clasificación para las redes neuronales.

En la predicción del ángulo ANB en las radiografías posteroanteriores, no hubo resultados importantes y al contrario de las de perfil que tendían a mejorar con el balanceo de clases, en la predicción del ángulo ANB no tuvieron progreso. Para la optimización de parámetros en todos los casos se usó una cross validation y para probar la clasificación de maloclusiones esqueléticas se usó una Split validation, 70% de la muestra fue escogida para entrenamiento y 30% de la muestra fue escogida para probar el modelo.

Ya que en los métodos de clasificación anteriormente mencionados se usaron variables mixtas (que contienen landmarks maxilares y mandibulares), se quiso probar el sistema con sólo variables craneomaxilares con redes neuronales y máquinas de vectores de soporte, por lo tanto se excluyeron todas las variables mixtas y mandibulares. Para las radiografías posteroanteriores se escogieron 9 variables: Cr- ENA, Cr.Jd, Cr-Ji, ENA-Pr, Fzd-Fzi, Jd-Cr-Ji, Jd-Ji, Masd-Masi, Zyd-Zyi y para las radiografías de perfil se escogieron 8 variables: ENA-ENP, ENA-Pr, N-Ba, N-ENA, N-S-Ba, Ptm-ENP, S-Ba, S-N; así mismo, se combinaron las variables de ambos tipos de radiografías para un total de 17 variables craneomaxilares. Los resultados de estas clasificaciones se pueden observar en la Tabla 4-3.



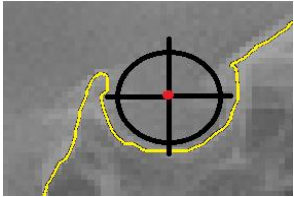
### **3.7 Pruebas con algoritmos de Aprendizaje con método de coordenadas de landmarks**


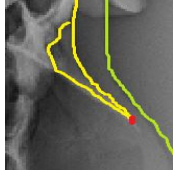

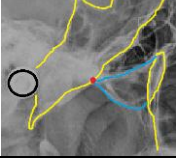



Debido al número limitado en variables por el método de Metronukak, y que la clasificación con sólo variables craneomaxilares no fuera relevante (Tabla 4-3), se

decidió ampliar las posibilidades de aumentar los atributos craneomaxilares no como medidas sino como landmarks que se utilizan en el método de morfometría geométrica.

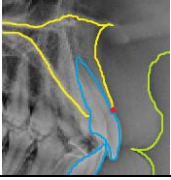
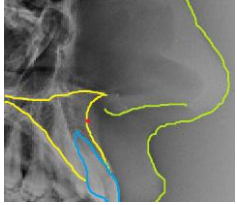
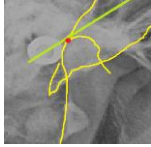
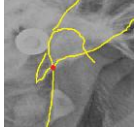
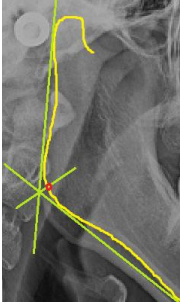

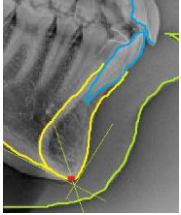
Teniendo en cuenta la base de datos del proyecto de biometría de la línea de crecimiento y desarrollo craneofacial de la Maestría en odontología de la Universidad Nacional de Colombia, se tomaron los protocolos que correspondían a landmarks digitalizados por medio del programa Tpsdig2 medidos por un solo observador ampliamente entrenado quien cumplió las pruebas inter e intraobservador satisfactoriamente (140). Estos landmarks son puntos cefalométricos humanos convencionales de radiografías anteroposteriores y de perfil, con aplicaciones ortodónticas y antropológicas (2, 22, 29, 134-145):

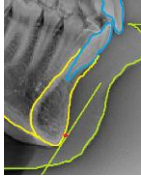
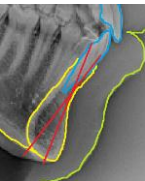


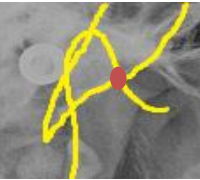
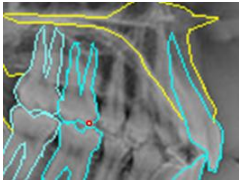
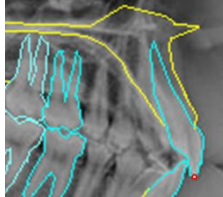
**Tabla 3-9:** Puntos cefalométricos ubicados en radiografía de perfil

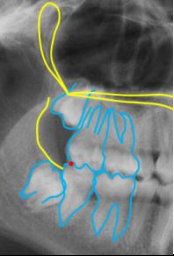
#	Abrev	Landmark	Región craneofacial	Definición	Tipo	Localización
1	N	Nasion	Base de cráneo	Punto anterior de la sutura frontonasal (Solución de continuidad).	I	
2	Te	Temporal	Base de Cráneo	Intersección de la lámina cribosa y la línea Maxilo-zigomatica-temporal.	I	
3	S	Silla Turca	Base del Cráneo	Punto medio de la silla turca de la hipófisis cerebral, punto medio de la fosa pituitaria, un punto radiográfico construido en el plano medio (Guía círculo de la herramienta).	III	

4	Ba	Basion	Base del cráneo	Punto más bajo y anterior del forámen magnum.	II	
5	Rhi	Rhinion	Tercio medio	Punto más inferior de la sutura internasal.	I	
6	Or	Orbital	Tercio medio	Punto más inferior del contorno de la órbita.	II (Slider 1-2)	
7	Zm	Cigomático maxilar	Tercio medio y base del cráneo	Intersección del arco cigomático con la base del cráneo (Embudo).	I	
8	ENP	Espina nasal posterior	Tercio medio	Punto entre la intersección de la pared anterior de la fosa pterigopalatina y el piso nasal, el límite dorsal del maxilar superior.	I	
9	ENA	Espina nasal anterior	Tercio medio	Extremo de la cresta nasal anterior a nivel del plano medio.	I	
10	Poas	Postalverion Superior	Tercio medio	El punto más posterior en la intersección del proceso alveolar con la superficie distal del segundo molar superior. (Cuando hay dos imágenes, se marca la mitad en sentido A-P).	I	



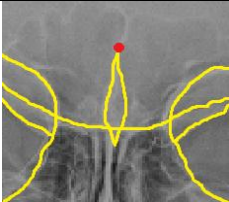
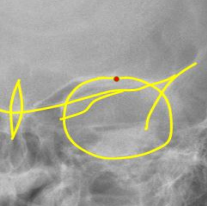
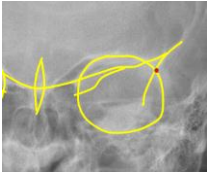
11	Pr	Prostion	Tercio medio	Punto más inferior del reborde alveolar superior sobre el incisivo central.	I	
12	A	Punto A	Tercio medio	Punto más profundo del contorno anterior maxilar entre espina nasal anterior y prostion.	II (Slider 8-10)	
13	Cd	Condilion	Tercio inferior	Punto más superior del contorno posterior del cóndilo mandibular.	II (Slider 13-22)	
14	ArP	Articulare Posterior	Tercio inferior	Intersección del borde posterior de la rama mandibular con la base de cráneo.	I	
15	Go	Goníaco	Tercio inferior	Bisectriz del ángulo formado por la tangente del borde posterior de la rama ascendente con el borde inferior del cuerpo de la rama sobre el contorno mandibular.	II (Slider 13-16)	
16	Me	Menton	Tercio inferior	Punto de intersección entre borde inferior mandibular y cortical externa de la sínfisis mentoniana.	I	
17	Gn	Gnation (Menton construido)	Tercio inferior	Bisectriz entre tangente del cuerpo mandibular y borde anterior de sínfisis proyectada	II Slider 16-20	


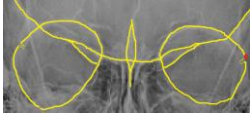
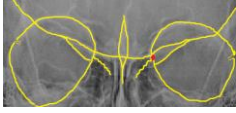
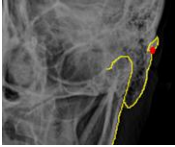
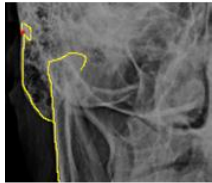
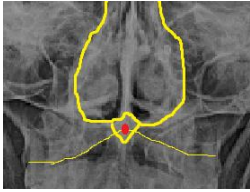
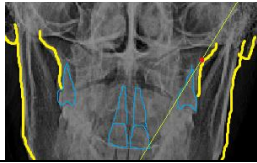
				sobre contorno de la sínfisis.		
18	Pg	Pogonion	Tercio inferior	Punto más anterior y prominente del contorno anterior de la mandíbula.	II Slider 16 – 20	
19	B	Punto B o supramental	Tercio inferior	Punto más profundo del contorno anterior mandibular entre infradental y pogonion.	II Slider 16 – 20	
20	Id	Infradental	Tercio inferior	Punto más anterior y superior del proceso alveolar sobre el incisivo central inferior.	I	
21	Poam	Posterior alveolar mandibular (Postalverion inferior)	Tercio inferior	El punto más posterior en la intersección del proceso alveolar con la superficie distal del segundo molar inferior.	I	
22	ArA	Articulare Anterior	Tercio inferior	Intersección del borde anterior del cóndilo mandibular con la base de cráneo.	I	
23	U6M BC	Cúspide mesial primer molar superior	Tercio superior	El punto más bajo de la convexidad de la cúspide mesial del primer molar superior.	II	
24	UIE	Borde incisal del incisivo superior	Tercio superior	Borde incisal del incisivo superior mejor posicionado respecto a la relación con el incisivo inferior.	II	

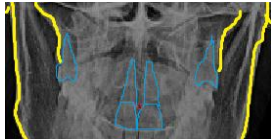
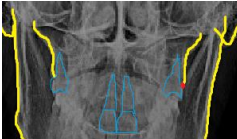
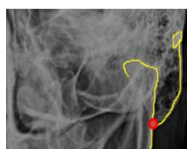
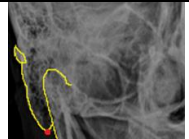
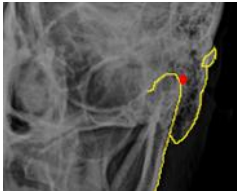
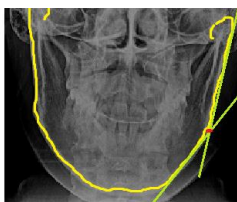
25	NGM BC		Dental	Punto de contacto en el plano oclusal por distal de los segundos molares superior e inferior.	I	
----	-----------	--	--------	---	---	---

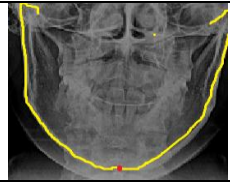
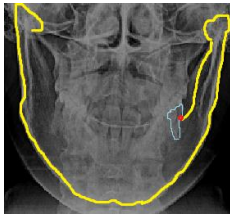
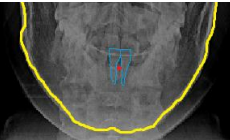
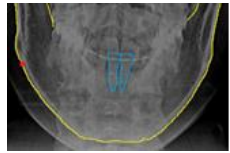
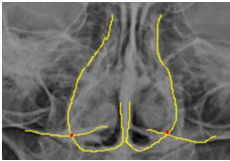
Los puntos ArA y ArP fueron excluidos pues son líneas de contacto entre la base de cráneo y mandíbula, por lo tanto se considerarían puntos mixtos ya que su ubicación depende de la mandíbula; asimismo, fueron excluidos los puntos U6MBC, UIE y N6MBC ya que son puntos dentales y el enfoque del estudio está dirigido únicamente a estructuras óseas craneofaciales

**Tabla 3-10:** Puntos cefalométricos ubicados en radiografía posteroanterior

#	Abrev	Landmark	Región craneofacial	Definición	Tipo	Localización
1	Cr	Cristagalli	Base de Cráneo	Punto más superior de la apófisis Crista Galli.	II	
2	SO	Supraorbital	BC	Punto más alto en el contorno del techo de la órbita.	II	
3	FO	Frontoorbital	BC	Punto de intersección de la línea oblicua de la órbita, con el contorno externo de la órbita (Línea Oblicua de la órbita hacia la proyección del ala mayor del esfenoides).	I	

4	N	Nasion	BC Tercio Medio	Punto sobre el plano medio siguiendo la proyección de la cortical superior de las alas menores del esfenoides sobre la sutura nasofrontal. Localización de la sutura.	I	
5	Fz	Frontozigomático	BC	Intersección de la sutura frontomaxilar y el margen medial de la órbita.	I	
6	Mf	Maxilofrontal	Or, NsR, UpF	Punto interno de la sutura frontocigomática, que limita con la órbita, hacia el tabique nasal.	I	
7	ZgN	Zygion	Ancho UpF	El punto lateral del contorno del arco cigomático en la intersección con la cortical externa.	II	
	ZgT			El punto más externo del contorno del arco cigomático.		
8	ENA	Espina nasal anterior	Paladar, Tercio medio, altura anterior del maxilar	Punto ubicado en la línea media a la altura de la proyección de la cortical de la bóveda palatina.	II	
9	J	Yugal	UpF	Punto de mayor concavidad del contorno maxilar.	II (Slider 7-11)	

10	Pr	Prostion	PI, UpF	Punto que corresponde al reborde alveolar entre los incisivos superiores en el plano medial. Localización de la zona más radiopaca.	I	
11	Poas	Postalverion Superior	PI (paladar)	El punto más posterior en la intersección del proceso alveolar con la superficie distal del segundo molar superior que coincide con la sutura pterigoalveolar del maxilar.	I	
12	MasN	Mastoideo	Base cranial posterior	Punto más inferior del proceso mastoideo sobre la intersección con la cortical externa da la rama.	II	
	MasT			Punto más inferior del proceso mastoideo.		
13	Cd	Condilion	Tercio inferior	Punto más latero-superior de la cabeza del cóndilo. El punto en la altura máxima visible de la rama.	II	
14	Go	Goníaco	Tercio inferior	Punto de unión de la tangente del borde posterior de la rama ascendente y la base del maxilar inferior. Señala el ángulo de la mandíbula.	II (Slider 12-15)	

15	Me	Menton	Tercio inferior	Punto medial más inferior del contorno de la sínfisis mandibular.	I	
16	Poam	Posterior alveolar mandibular (Postalverion inferior)	Tercio inferior	El punto más posterior en la intersección del proceso alveolar con la superficie distal del segundo molar inferior.	I	
17	Id	Infradental	Tercio inferior	Punto que corresponde al reborde alveolar entre los incisivos inferiores en el plano medial.	I	
18	Ag	Antegonial	Tercio inferior	El punto más alto en la escotadura antegonial de la mandíbula.	II (Slider 13-14)	
19	Nas	Ancho nasal	Tercio Medio Ancho nasal	La mayor distancia entre la pared lateral ósea de la cavidad nasal derecha e izquierda medida en la apertura nasal anterior sobre cortical interna.		

Los puntos que no son de la línea media tienen su respectiva ubicación en el lado izquierdo (i) y en el derecho (d), a diferencia de varios casos de morfometría geométrica donde sólo se usa un solo lado; los puntos Zg y Mas en el protocolo de la bases de datos se les modificó la ubicación ya que se reportó que tienen alta variabilidad (140), para diferenciarlos están acompañados de una N, sin embargo los puntos Zg y Mas que se utilizaron en el presente estudio tienen la ubicación original debido a que el MasN y el ZgN dependen de intersecciones con otras estructuras cercanas mas no relacionadas, esta ubicación original está acompañada de una T.

Por otro lado las unidades utilizadas por el programa son de magnitud a-dimensional debido a que se refieren a puntos en el espacio. El resultado final de la medición es un archivo en block de notas. Cada coordenada (ubicación del punto en X y Y) de cada landmark por paciente fue pasada al programa Microsoft Excel para la creación de una base de datos y luego ese archivo fue transformado con la extensión .csv.

### **3.7.1 Creación de medidas lineales y angulares con software**

#### **Matlab: nueva clasificación**

A diferencia del trabajo realizado en morfometría geométrica (140), en esta metodología se exploraron nuevas medidas lineales y angulares para la creación de muchas variables que tuvieran significado a nivel biológico, es por eso que las coordenadas en X y Y se unieron en puntos y esos puntos se unieron con otros para formar medidas lineales y angulares. Esto se realizó mediante el programa Matlab, donde se cargó dicho archivo .csv los cuales tenían que estar en pares, teniendo en cuenta el número de filas que se iban a cargar que correspondían a 229 ya que finalmente ese fue el número de pacientes que se utilizaron para los análisis y que cumplían los criterios de exclusión e inclusión.

Después del análisis y de establecer todas las combinaciones posibles se determinaron 29254 atributos por paciente, 22052 para las radiografías posteroanteriores y 7202 para las radiografías de perfil. Luego se etiquetaron los nombres de los atributos dispuestos como por ejemplo en las líneas A-N y en los ángulos N-A-B-1, N-A-B-2 y N-A-B-3, correspondientes al ángulo ANB, NBA y BAN, que formarían un triángulo.

Teniendo en cuenta esta nueva metodología aplicada al trabajo se decidió confirmar la clasificación realizada en los 216 pacientes antes analizados por el método de Metronukak y hacer la clasificación para los pacientes que faltaban (Tabla 3-1), es por eso que se tuvo en cuenta el ángulo ANB (N-A-B-1) cuya medida fue transformada de radianes a grados para saber precisamente su clasificación esquelética, teniendo en cuenta la Tabla 3.1. Así mismo se restó el ángulo SNA y SNB para saber si los valores

eran negativos confirmando si los pacientes pertenecían a la Clase III. Los detalles de la clasificación definitiva se encuentran en la Tabla 3-11.

**Tabla 3-11:** Clasificación de los pacientes recolectados en método de landmarks. N=229.

	Clase I	Clase II	Clase III
Femenino	45	24	26
Masculino	58	31	45
Total	103	55	71

Los pacientes cuya clasificación cambió fueron 35 en total y correspondían a aquellos que estaban en los límites de la clasificación, 11 pacientes clase II y 6 pacientes clase III fueron clasificados como clase I por el sistema y 18 pacientes clase I fueron clasificados 8 como clase II y 10 como clase III. Se escogieron al azar 18 pacientes para realizar medidas de ANB sobre las imágenes con los landmarks que se ubicaron para confirmar que el método de Matlab estuviera midiendo de forma adecuada por medio de la herramienta Metronukak y se observó que las medidas son muy parecidas a lo arrojado en el Matlab cuando se transforman a grados.

Para determinar cuál era la mejor clasificación se excluyeron todas las variables que tuvieran puntos mandibulares, dejando 8126 para radiografías posteroanteriores y 727 para perfil, es decir son atributos que corresponden a medidas lineales y angulares con medidas craneomaxilares; se corrieron los archivos correspondientes a radiografías de perfil con una máquina de vectores de soporte con un kernel lineal con parámetros en default (C de 0.0 y epsilon de 0.0010) dando una precisión del 50.1% para la clasificación inicial hecha por el método de Metronukak y 64.34% para el método de reclasificación por Matlab.

Teniendo en cuenta este proceso se hizo necesario realizar una nueva codificación de los pacientes según su más reciente clasificación.



### **3.8 Optimización de parámetros y Clasificación de maloclusiones esqueléticas con medidas creadas a partir de landmarks**

Usando máquinas de vectores de soporte y un kernel lineal, se seleccionó el mejor parámetro C aplicando una cross-validation; utilizando este parámetro se procedió a balancear las clases, 55 pacientes para la clase II, 58 para clase I y 57 para clase III, dando un total de 170 pacientes escogidos aleatoriamente por el sistema. De esos 170 pacientes por medio de una Split validation se dividió la muestra en un 70% para entrenamiento y un 30% para prueba. Asimismo, se escogieron las variables más discriminantes dadas por los pesos de las máquinas de vectores de soporte, es decir aquellas que mejor explicaban el modelo (selection by weights.k). Esto se realizó en radiografías de perfil (Figura 4-2 y Tabla 4-4), posteroanteriores (Figura 4-3) y combinación de radiografías de perfil y posteroanteriores (Figura 4-4).

Adicionalmente, se realizó la predicción del ángulo ANB en radiografías de perfil, este valor se expresó en términos de error cuadrático medio (Tabla 4-5), posteriormente se usó dicho valor para clasificar las maloclusiones esqueléticas (Figura 4-5), seleccionando previamente el mejor parámetro C (Tabla 4-6).

En los cuatro casos usados para clasificación se intentó realizar la misma actividad con las redes neuronales sin embargo el manejo de los datos era muy grande para esta y la memoria no era suficiente.

## **3.9 Predicción de variables mandibulares a partir de variables craneomaxilares**

### **3.9.1 Predicción de coordenadas de landmarks mandibulares**


Para cumplir los otros tres objetivos específicos de estimar la capacidad predictiva de las redes neuronales y las máquinas de vectores de soporte, determinar las relaciones de dependencia funcional de las variables morfológicas mandibulares con respecto a las craneomaxilares y comparar las redes neuronales artificiales con las máquinas de vectores de soporte en términos de error cuadrático medio de la predicción, se decidió experimentar la posibilidad de encontrar la ubicación de los landmarks mandibulares, por medio de la predicción de las coordenadas en X y Y de cada punto, a partir de variables craneomaxilares, ya que sería relevante encontrar su ubicación y así poder construir medidas ilimitadas que demuestren tamaño y forma mandibular.

Usando un kernel lineal, se realizó la predicción y se determinó el error cuadrático medio por landmark mandibular en radiografías de perfil (Tabla 4-7) y en radiografías posteroanteriores (Tabla 4-9); posteriormente, se realizó un coeficiente de correlación entre el valor predicho y el valor original, por medio de una regresión de arista o ridge regression, debido a que las unidades a-dimensionales daban valores del RMSE (error cuadrático medio) difíciles de interpretar; en la regresión, los valores cercanos al 1 (correlación:  $r$ ) son los que presentaban un mejor modelo de predicción y de esta manera se estimó la capacidad predictiva de las máquinas de vectores de soporte en radiografías de perfil (Tabla 4-8) y posteroanteriores (Tabla 4-10).

### **3.9.2 Predicción de medidas mandibulares seleccionadas en radiografías de perfil**

Al no tener resultados relevantes con la predicción de coordenadas (Tablas 4-8 y 4-10), se tuvo en cuenta la predicción de medidas lineales y angulares mandibulares seleccionadas, obtenidas por la unión de landmarks, que se pueden observar en la Figura 3- 6 y se detallan en la Tabla 3-12.

**Figura 3-6:** Esquema de variables mandibulares a predecir en radiografía de perfil



**Tabla 3-12:** Variables mandibulares a predecir en radiografía de perfil

Nombre Rapidminer	Ángulo Real	Nombre Rapidminer	Ángulo Real	Nombre Rapidminer	Ángulo Real
<b>B-Id-Poam-1</b>	Poam-B-Id	<b>Cd-Id-Poam-1</b>	Poam-Cd-Id	<b>Go-Gn-Id-1</b>	Gn-Go-Id
<b>B-Id-Poam-2</b>	B-Id-Poam	<b>Cd-Id-Poam-2</b>	Poam-Id-Cd	<b>Go-Gn-Id-2</b>	Go-Id-Gn
<b>B-Id-Poam-3</b>	B-Poam-Id	<b>Cd-Id-Poam-3</b>	Cd-Poam-Id	<b>Go-Gn-Id-3</b>	Id-Gn-Go
<b>Cd-Go-Gn-1</b>	Go-Cd-Gn	<b>Gn-Id-Poam-1</b>	Id-Gn-Poam	<b>Me-Gn-Pg-1</b>	Pg-Me-Gn
<b>Cd-Go-Gn-2</b>	Cd-Go-Gn	<b>Gn-Id-Poam-2</b>	Gn-Id-Poam	<b>Me-Gn-Pg-2</b>	Me-Gn-Pg

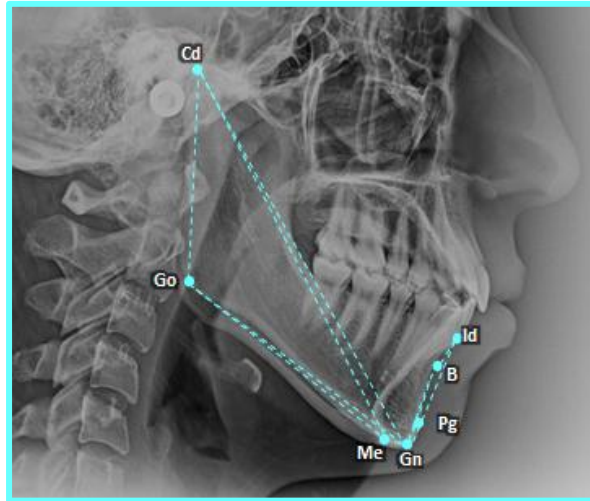
<b>Cd-Go-Gn-3</b>	Go-Gn-Cd	<b>Gn-Id-Poam-3</b>	Gn-Poam-Id	<b>Me-Gn-Pg-3</b>	Gn-Pg-Me
<b>Cd-Go-Me-1</b>	Go-Cd-Me	<b>Go-Gn-B-1</b>	Gn-Go-B	<b>Pg-B-Id-1</b>	B-Pg-Id
<b>Cd-Go-Me-2</b>	Cd-Go-Me	<b>Go-Gn-B-2</b>	Go-Gn-B	<b>Pg-B-Id-2</b>	Pg-B-Id
<b>Cd-Go-Me-3</b>	Go-Me-Cd	<b>Go-Gn-B-3</b>	Gn-B-Go	<b>Pg-B-Id-3</b>	Pg-Id-B

Estas medidas mandibulares fueron predichas a partir de todas las **727** variables craneomaxilares determinadas en las radiografías de perfil por medio de una máquina de vectores de soporte con un kernel lineal; se expresaron en términos de error cuadrático medio (Tabla 4-11) y en coeficientes de correlación por medio de una ridge regression (Tabla 4-12).

### 3.9.3 Predicción de medidas mandibulares a partir de medidas craneomaxilares seleccionadas en radiografías de perfil

Dada la mejoría de los resultados con la metodología de selección de atributos mandibulares (Tabla 4-12), se planteó la idea de también escoger variables craneomaxilares. Igualmente se excluyeron las variables que contuvieran al punto Poam debido a que depende más de la parte dental que de la esquelética, por lo tanto las variables a predecir fueron: B-Id, Cd-Gn, Cd-Go, Cd-Go-Gn, Cd-Go-Me, Cd-Me, Gn-B, Gn-Id, Gn-Pg, Go-Gn, Go-Gn-B, Go-Me, Id-Gn-Go, Me-Gn, Me-Gn-Pg, Pg-B y Pg-B-Id (Figura 3-7).

**Figura 3-7:** Variables Mandibulares a predecir



Después se seleccionaron 4 conjuntos de características de entrada o variables craneomaxilares para predicción las cuales fueron:

- **Variables Sintéticas**

La primera metodología consistió en escoger las **10** variables más discriminantes dadas por los pesos de las máquinas de vectores de soporte en el proceso de clasificación en radiografías de perfil que se pueden observar en la Tabla 4-4 y cuya descripción gráfica se encuentra en la Figura 4-6.

- **Variables de la literatura**

Teniendo en cuenta el protocolo usado en el método de Metronukak y una revisión más profunda de otras variables craneomaxilares (2, 22, 29, 134-139, 141-145), se escogieron **12** trazos de variables estandarizadas usadas en ortodoncia y antropología las cuales fueron: ENA-Pr, ENP-ENA, N-Ba, N-ENA, N-S, S-N-A, A-S-N, N-A-S, N-S-Ba, S-Ba-N, Ba-N-S y S-Ba (Figura 4-7).

- **Combinación de Variables sintéticas y de literatura**

En este caso se usaron las **22** variables dadas a partir de la combinación de las 10 variables más discriminantes, más las 12 variables estándares (Figura 4-8).

- **Combinación de Variables sintéticas, de literatura y distancias de las variables sintéticas**

En la Tabla 4-4 se puede observar que las variables que determinan la mejor clasificación son angulares, por lo tanto, además de tener en cuenta las variables sintéticas y las de la literatura, se agregaron las medidas lineales que se obtienen de los ángulos de las variables sintéticas, siendo 11 en total, dando **33** variables craneomaxilares (ENP-A-Pr, Zm-A-Pr, Te-Pr-A, Pr-A-Te, Rhi-A-Pr, A-Pr-Rhi, A-Te-Pr, A-N-Pr, N-Pr-A y Pr-A-N, ENP-A, ENP-Pr, A-Pr, Zm-A, Zm-Pr, Te-Pr, Te-A, Rhi-A, Rhi-Pr, A-N, N-Pr, ENA-Pr, ENP-ENA, N-Ba, N-ENA, N-S, S-N-A, A-S-N, N-A-S, N-S-Ba, S-Ba-N, Ba-N-S y S-Ba), se pueden ver gráficamente en la Figura 4-9.


Estas variables de entrada, permitieron usar tanto las máquinas de vectores de soporte como las redes neuronales, cuyos coeficientes de correlación se pueden observar en las Tablas 4-13 y 4-14 respectivamente. Los valores de los parámetros para los análisis fueron en default para las redes neuronales (500 ciclos, tasa de aprendizaje de 0.3 y momentum de 0.2), y para las máquinas de vectores de soporte ( $C=0.0$ ), donde se usaron kernels lineales en todas las pruebas y adicionalmente para los conjuntos de características de entrada de combinación de Variables sintéticas y de literatura (22 variables craneomaxilares) y éstas más las distancias de las variables sintéticas (33 variables craneomaxilares), se hicieron pruebas también con kernels de función de base radial (RBF) y polinomiales.

En la Tabla 4-15 se observa el error cuadrático medio de las variables mandibulares predichas en máquinas de vectores de soporte y en la Tabla 4-16 se encuentra el error cuadrático medio dado con las redes neuronales. En la Tabla 4-17 se observa la comparación de los RMSE entre redes neuronales y máquinas de vectores de soporte.

### **3.9.4 Predicción de medidas mandibulares seleccionadas en radiografías posteroanteriores**

Realizando los mismos pasos de predicción de medidas mandibulares en radiografías de perfil (Ítem 3.9.2) se seleccionaron líneas y ángulos mandibulares para predicción en radiografías posteroanteriores que se observan gráficamente en la Figura 3-8 y se describen en la Tabla 3-13. Estas se predijeron a partir de las **8126** variables craneomaxilares de las radiografías posteroanteriores y se usó una máquina de vectores de soporte con un kernel lineal.

**Figura 3-8:** Esquema de variables mandibulares a predecir en radiografía posteroanterior



**Tabla 3-13:** Variables mandibulares a predecir en radiografía posteroanterior

Agi-Agd	Cdi-Poami
Cdd-God	God-Me
Cdd-God-Me	Goi-God
Cdd-Me	Goi-Me-God
Cdd-Agd-Me	Goi-Me
Cdd-Poamd	Me-Agd
Cdi-Agi	Me-Agi
Cdi-Cdd	Agi- Me -Agd
Cdi-Me-Cdd	Me-Id
Cdi-Goi	Poamd-Id


Cdi-Goi-Me	Poami-Id
Cdi-Me	Poami-Id-Poamd
Cdi- Agi -Me	Cdd-Agd
Poami-Poamd	

De la misma manera el error cuadrático medio y los coeficientes de correlación fueron determinados y se observan en las Tablas 4-18 y 4-19 respectivamente.


### 3.9.5 Predicción de medidas mandibulares a partir de medidas craneomaxilares seleccionadas en radiografías posteroanteriores

Las variables mandibulares anteriormente mencionadas exceptuando aquellas que contienen los puntos postalverion mandibular (Poam) y antegonial (Ag) fueron usadas para predecirse (Figura 3-9). Se seleccionaron medidas craneomaxilares estándar, después de realizar una revisión de literatura más profunda, encontrando 17 variables craneomaxilares, las cuales son: Fzd-Fzi, ZgTd-ZgTi, MasTd-MasTi, Jd-Ji, Cr-ENA, Cr-Jd, Cr-Ji, ENA-Pr, N-Nasi, N-Nasd, Nasd-Nasi, Jd-Cr-Ji, Jd-Ji-Cr, Cr-Jd-Ji, Nasd-N-Nasi, Nasi-Nasd-N y N-Nasi-Nasd. (Figura 3-10).

**Figura 3-9:** Variables mandibulares a predecir





**Figura 3-10:** Variables craneomaxilares seleccionadas en radiografía posteroanterior

Se predijeron con redes neuronales y máquinas de vectores de soporte con un kernel lineal, con un kernel de función de base radial y con un kernel polinomial. El resultado de los coeficientes de correlación se observa en la Tabla 4-20 y la comparación entre las máquinas de vectores de soporte y las redes neuronales en términos de error cuadrático medio se encuentra en la Tabla 4-21.



## 4. Resultados

### 4.1 Pruebas con algoritmos de Aprendizaje para clasificación con método de medición Metronukak

**Tabla 4-1:** Porcentaje de precisión (accuracy) en la clasificación con redes neuronales

ANN		Perfil	Posteroanterior	Todo
Sin predicción del ángulo ANB	Sin Balancear	63.08%	44.62%	64.24%
	Balanceado	64.62%*	40.92%	62.92%
Con predicción del ángulo ANB	Sin Balancear	75.38%	38.3%	76.90%
	Balanceado	78.72%	38.3%	85.11%*

\* Optimización de parámetros

**Tabla 4-2:** Porcentaje de precisión (accuracy) en la clasificación con máquinas de vectores de soporte

SVM	Perfil	Posteroanterior	Todo
-----	--------	-----------------	------

Sin predicción del ángulo ANB	Sin Balancear	61.54%*	50.77%*	46.21%*
	Balanceado	57.71%*	32.71%*	51.9%*
Con predicción del ángulo ANB	Sin Balancear	75.38%	27.66%	78.75%
	Balanceado	78.72%	27.66%	85.11%*

\* Optimización de parámetros

**Figura 4-1:** Detalles del porcentaje de precisión de las redes neuronales

accuracy: 85.11%				
	true Clase I	true Clase II	true Clase III	class precision
pred. Clase I	13	2	1	81.25%
pred. Clase II	3	14	0	82.35%
pred. Clase III	1	0	13	92.86%
class recall	76.47%	87.50%	92.86%	

**Tabla 4-3:** Porcentaje de precisión (accuracy) en la clasificación con sólo variables craneomaxilares

n=216	Perfil		Posteroanterior		Todo	
	SVM	ANN	SVM	ANN	SVM	ANN
<b>Balanceado</b>	29.79%	42.55%	28.26%	45.65%	42.55%	51.06%

El valor más alto obtenido fue dado con las redes neuronales con las variables combinadas de las radiografías de perfil y posteroanteriores, estos datos no son muy relevantes, por lo tanto se hizo necesaria la aplicación de una nueva metodología.

## 4.2 Clasificación de maloclusiones esqueléticas con medidas creadas a partir de landmarks

### 4.2.1 Clasificación de maloclusiones esqueléticas en radiografías de perfil

Para las radiografías de perfil el sistema determinó que el mejor parámetro C era de 225 con una precisión de 0.823, al probar el sistema con las mejores variables discriminantes dadas por los pesos de las máquinas de vectores de soporte con el kernel lineal se obtuvo una precisión de 72.55% con dos modelos. En el primer modelo se clasificó en 57.89%, 86.6%, y 76.47% en las maloclusiones clase I, II, y III respectivamente, explicado por 9 variables angulares: Pr-N-A, A-Pr-N, N-A-Pr, Pr-Te-A, A-Pr-Te, Te-A-Pr, A-Pr-Rhi, Rhi-A-Pr, Zm-A-Pr; mientras que el otro modelo presentaba un porcentaje de 58,8%, 75% y 83,3% en la Clase I, II y III respectivamente, explicado por 6 ángulos que son: Pr-N-A, A-Pr-N, N-A-Pr, Pr-Te-A, A-Pr-Rhi, Rhi-A-Pr.

A pesar de lo anteriormente mencionado, el parámetro C de 225 resulta ser un número grande y muy flexible por lo tanto se probó con uno de los parámetros C más pequeños que contuviera un valor relativamente grande en la precisión de la optimización, el parámetro C de 9.0 cumplía con estas características con una precisión de 0.7058, al realizar las pruebas con este parámetro la precisión aumentó a un 74.51%, clasificando en un 62.50%, 77.78% y 82.35% a la clase I, II y III respectivamente como se observa en la Figura 4-2, explicada por 7, 8, 9, y/o 10 variables, donde no hubo cambio en los porcentajes de precisión; estas variables se muestran en la Tabla 4-4 con su respectivo peso.

**Figura 4-2:** Precisión en clasificación de maloclusiones esqueléticas en radiografías de perfil

accuracy: 74.51%				
	true Clase II	true Clase I	true Clase III	class precision
pred. Clase II	14	4	0	77.78%
pred. Clase I	2	10	4	62.50%
pred. Clase III	0	3	14	82.35%
class recall	87.50%	58.82%	77.78%	

**Tabla 4-4:** Variables explicativas del modelo de clasificación

Attribute	Weight
N-Pr-A-3 (Pr-A-N)	1.0
N-Pr-A-2 (N-Pr-A)	0.9992825974392485
N-Pr-A-1 (A-N-Pr)	0.9381866135837863
Te-Pr-A-1 (A-Te-Pr)	0.9312172763658201
Rhi-Pr-A-2 (A-Pr-Rhi)	0.9234872813143992
Rhi-Pr-A-3 (Rhi-A-Pr)	0.8916160403329001
Te-Pr-A-3 (Pr-A-Te)	0.8878987731197967
Te-Pr-A-2 (Te-Pr-A)	0.8676857371403237
Zm-Pr-A-3 (Zm-A-Pr)	0.82792865086668
ENP-Pr-A-3 (ENP-A-Pr)	0.8068279727005031

Estas fueron las variables sintéticas seleccionadas como conjunto de características de entrada o variables craneomaxilares para la predicción de morfología mandibular descrita en el ítem 3.9.3, así mismo con estas variables se combinaron las variables de la literatura, y finalmente, las distancias o medidas lineales de estos ángulos fueron las 11 variables adicionales para el conjunto de características de 33 variables craneomaxilares.

#### 4.2.2 Clasificación de maloclusiones esqueléticas en radiografías posteroanteriores

Se seleccionó el mejor parámetro C, dando como resultado un C de 279.0 que daba una precisión de 0.7058. No obstante teniendo en cuenta los resultados de las

radiografías de perfil, el C de 3.0 fue finalmente escogido ya que daba una precisión de 0.64 y no era un parámetro tan grande.

La precisión arrojada fue del 66%, clasificando 71.43%, 70% y 60.87% para la Clase I, II y III respectivamente (Figura 4-3) explicado por 17 variables, sin embargo al probar el modelo con las 17 variables dio como resultado una precisión de 38%. Esto se debió a una falla en la selección de atributos donde todos los pesos asignados para las variables craneomaxilares fueron de 1, por lo tanto al seleccionar las 17 variables el sistema las escogió arbitrariamente y dio dicho valor bajo.

**Figura 4-3:** Precisión en clasificación de maloclusiones esqueléticas en radiografías posteroanteriores

accuracy: 66.00%				
	true Clase II	true Clase I	true Clase III	class precision
pred. Clase II	14	4	2	70.00%
pred. Clase I	0	5	2	71.43%
pred. Clase III	3	6	14	60.87%
class recall	82.35%	33.33%	77.78%	

Una de las características que presenta esta clasificación es que no supo discriminar la Clase II de la III y viceversa, por lo tanto no es confiable su uso en términos de clasificación.

### 4.2.3 Optimización y clasificación de maloclusiones esqueléticas en radiografías de perfil y posteroanteriores

Ya que en la metodología de clasificación por Metronukak los resultados fueron más relevantes al combinar las variables de las radiografías de perfil con las posteroanteriores, se procedió a determinar el mejor parámetro C el cual fue de 222.0

que daba una precisión de 0.8235, el mejor de los parámetros C más pequeños fue de 3.0 que daba una precisión de 0.7647.

68% de precisión dio como resultado (Figura 4-4) definido por 8765 variables, clasificando en 80%, 50% y 76.47% a la Clase I, II y III respectivamente. Al usar este número para confirmar los resultados del modelo dio un 54%. Al aplicar un número menor de variables (19 variables) que dio en la optimización un valor de precisión teórico similar de 0.64, el sistema no respondió como se esperaba y tuvo una precisión del 40%. Esto fue debido a la falla en la selección de variables por pesos similar a lo que ocurrió en las radiografías posteroanteriores. En este caso el sistema tampoco pudo discriminar entre la clase II y la clase III y viceversa.

**Figura 4-4:** Precisión en clasificación de maloclusiones esqueléticas en radiografías de perfil y posteroanteriores

accuracy: 68.00%				
	true Clase II	true Clase I	true Clase III	class precision
pred. Clase II	9	6	3	50.00%
pred. Clase I	2	12	1	80.00%
pred. Clase III	3	1	13	76.47%
class recall	64.29%	63.16%	76.47%	

#### 4.2.4 Clasificación de maloclusiones esqueléticas a partir del valor predicho del ángulo ANB en radiografías de perfil

En la predicción del ángulo ANB en las radiografías de perfil el error cuadrático medio fue de 0.034 (Tabla 4-5) y al optimizar los parámetros el sistema con un kernel lineal detectó que el mejor C correspondía a -1.0 (Tabla 4-6).

**Tabla 4-5:** Desempeño del conjunto de datos en predicción de ANB



Raíz del error cuadrático medio	0.034 + / - 0.000
Error absoluto	0.028 + / - 0.020
Error relativo	81.28% + / - 145.15%
Raíz del error cuadrático relativo	0.923
Error cuadrático	0.001 + / - 0.001
Promedio de predicción	0.063 + / - 0.037

**Tabla 4-6:** Mejor parámetro C

C	Abs_err	Predict_avg	Squ_error	Relative_error
-1.0	0.02787	0.06346	0.00116	0.81279

Al usar el parámetro de -1.0, el sistema no lo pudo tener en cuenta ya que el límite inferior es a partir de 0.0, por eso en el modelo se implementó ese parámetro de 0.0 dando una precisión de 70.59%, clasificando en 55%, 70.59% y 92.86% a la clase I, II, y III respectivamente (Figura 4-5).

**Figura 4-5:** Precisión en clasificación de maloclusiones esqueléticas a partir del ángulo ANB predicho

accuracy: 70.59%				
	true Clase I	true Clase II	true Clase III	class precision
pred. Clase I	11	5	4	55.00%
pred. Clase II	4	12	1	70.59%
pred. Clase III	1	0	13	92.86%
class recall	68.75%	70.59%	72.22%	

Este tipo de clasificación aunque no fue superior a la metodología de radiografías de perfil, resulta ser muy importante en la Clase III esquelética ya que obtuvo un valor muy alto y la discriminó de la Clase II esquelética.

## 4.3 Predicción de variables mandibulares a partir de variables craneomaxilares

### 4.3.1 Predicción de coordenadas mandibulares en radiografía de perfil

**Tabla 4-7:** Desempeño de las coordenadas mandibulares predichas en radiografía de perfil

	root mean squared error	absolute error	relative error	relative error lenient	relative error strict	
<b>Cdx</b>	36.918 +/- 0.000	22.816 +/- 29.024	3.17% +/- 4.63%	2.95% +/- 3.79%	3.22% +/- 4.65%	
<b>Cdy</b>	39.291 +/- 0.000	28.756 +/- 26.773	3.26% +/- 3.22%	3.12% +/- 2.91%	3.32% +/- 3.26%	
<b>Gox</b>	44.985 +/- 0.000	31.711 +/- 31.907	4.18% +/- 4.81%	3.90% +/- 3.96%	4.25% +/- 4.83%	
<b>Goy</b>	47.110 +/- 0.000	37.493 +/- 28.523	7.84% +/- 6.32%	7.25% +/- 5.37%	8.20% +/- 6.64%	
<b>Mex</b>	63.237 +/- 0.000	49.558 +/- 39.280	4.03% +/- 3.42%	3.85% +/- 3.06%	4.11% +/- 3.48%	
<b>Mey</b>	51.090 +/- 0.000	41.033 +/- 30.439	18.34% +/- 16.54%	14.89% +/- 10.67%	19.62% +/- 17.12%	
<b>Gnx</b>	62.241 +/- 0.000	48.670 +/- 38.796	3.78% +/- 3.24%	3.62% +/- 2.90%	3.86% +/- 3.28%	
<b>Gny</b>	53.733 +/- 0.000	43.324 +/- 31.786	19.05% +/- 18.47%	15.24% +/- 11.03%	20.40% +/- 18.88%	
<b>Pgx</b>	60.268 +/- 0.000	46.853 +/- 37.908	3.60% +/- 3.12%	3.45% +/- 2.80%	3.67% +/- 3.16%	
<b>Pgy</b>	53.090 +/- 0.000	42.434 +/- 31.904	14.47% +/- 13.03%	12.38% +/- 9.07%	15.52% +/- 13.58%	
<b>Bx</b>	56.285 +/- 0.000	41.903 +/- 37.578	3.24% +/- 3.15%	3.11% +/- 2.80%	3.30% +/- 3.18%	
<b>By</b>	47.644 +/- 0.000	37.287 +/- 29.658	9.70% +/- 8.49%	8.67% +/- 6.78%	10.15% +/- 8.81%	
<b>Idx</b>	53.168 +/- 0.000	39.277 +/- 35.835	2.95% +/- 2.90%	2.84% +/- 2.60%	3.00% +/- 2.94%	
<b>Idy</b>	46.750 +/- 0.000	36.284 +/- 29.480	8.11% +/- 7.22%	7.43% +/- 5.93%	8.50% +/- 7.52%	
	normalized absolute error	root relative squared error	squared error	correlation	squared correlation	prediction average
<b>Cdx</b>	0.942	0.988	1362.968	0.275	0.076	757.793 +/- 37.367

			+/- 4292.622			
<b>Cdy</b>	0.949	0.981	1543.747 +/- 2751.857	0.326	0.107	901.586 +/- 40.053
<b>Gox</b>	0.961	0.998	2023.612 +/- 4814.669	0.267	0.071	791.822 +/- 45.090
<b>Goy</b>	0.951	0.960	2219.339 +/- 3072.407	0.483	0.233	489.710 +/- 49.097
<b>Mex</b>	0.962	0.972	3998.962 +/- 6383.849	0.508	0.258	1253.550 +/- 65.073
<b>Mey</b>	0.936	0.943	2610.215 +/- 3526.535	0.611	0.373	248.917 +/- 54.161
<b>Gnx</b>	0.953	0.965	3873.911 +/- 6346.988	0.544	0.296	1311.586 +/- 64.474
<b>Gny</b>	0.944	0.952	2887.275 +/- 3855.994	0.556	0.309	257.136 +/- 56.470
<b>Pgx</b>	0.954	0.964	3632.204 +/- 6129.227	0.543	0.295	1324.929 +/- 62.517
<b>Pgy</b>	0.952	0.957	2818.552 +/- 3831.924	0.520	0.270	315.024 +/- 55.456
<b>Bx</b>	0.949	0.967	3167.995 +/- 6336.072	0.512	0.262	1320.568 +/- 58.218
<b>By</b>	0.949	0.971	2269.951 +/- 3129.705	0.437	0.191	402.905 +/- 49.064
<b>Idx</b>	0.941	0.949	2826.856 +/- 5962.670	0.573	0.328	1354.107 +/- 56.036
<b>Idy</b>	0.956	0.970	2185.597 +/- 3215.900	0.381	0.145	462.787 +/- 48.188

**Tabla 4-8:** Coeficiente de correlación 'r' de las coordenadas mandibulares predichas en radiografías de perfil

Variable	R	Variable	R
Cdx	0,02388406	Cdy	0,03773104
Gox	0,00467488	Goy	0,07931749
Mex	0,05562793	Mey	0,11017454
Gnx	0,06808338	Gny	0,09457891
Pgx	0,07065528	Pgy	0,0834909
Bx	0,06530454	By	0,05703395
Idx	0,09974782	Idy	0,05875873

El mejor valor de r fue dado por la coordenada en Y del punto mentón (Me) con 0.11, sin embargo ninguno de estos valores resulta ser relevante para la predicción.

### 4.3.2 Predicción de coordenadas mandibulares en radiografías posteroanteriores

**Tabla 4-9:** Desempeño de las coordenadas mandibulares predichas en radiografía posteroanterior

	root mean squared error	absolute error	relative error	relative error lenient	relative error strict
<b>Cdix</b>	29.807 +/- 0.000	21.023 +/- 21.129	1.92% +/- 2.04%	1.86% +/- 1.88%	1.94% +/- 2.05%
<b>Cdiy</b>	72.788 +/- 0.000	54.502 +/- 48.246	6.94% +/- 6.92%	6.23% +/- 5.61%	7.06% +/- 6.92%
<b>Cddx</b>	25.752 +/- 0.000	19.191 +/- 17.172	8.01% +/- 8.69%	7.17% +/- 6.46%	8.33% +/- 8.86%
<b>Cddy</b>	72.446 +/- 0.000	54.429 +/- 47.811	6.98% +/- 6.95%	6.27% +/- 5.60%	7.10% +/- 6.96%
<b>Goix</b>	34.337 +/- 0.000	26.621 +/- 21.687	2.60% +/- 2.19%	2.53% +/- 2.06%	2.64% +/- 2.22%
<b>Goiy</b>	75.315 +/- 0.000	59.640 +/- 45.993	15.69% +/- 15.48%	12.73% +/- 10.03%	16.36% +/- 15.56%
<b>Godx</b>	30.744 +/- 0.000	23.720 +/- 19.559	7.36% +/- 7.04%	6.70% +/- 5.59%	7.61% +/- 7.12%
<b>Gody</b>	76.348 +/- 0.000	61.203 +/- 45.642	16.51% +/- 16.15%	13.32% +/- 10.18%	17.24% +/- 16.20%
<b>Mex</b>	25.872 +/- 0.000	18.911 +/- 17.656	2.80% +/- 2.77%	2.69% +/- 2.52%	2.84% +/- 2.79%
<b>Mey</b>	73.987 +/- 0.000	60.541 +/- 42.530	33.09% +/- 43.50%	21.16% +/- 15.70%	34.92% +/- 43.18%

<b>Idx</b>	24.825 +/- 0.000	17.129 +/- 17.969	2.57% +/- 2.88%	2.46% +/- 2.59%	2.60% +/- 2.89%	
<b>Idy</b>	72.297 +/- 0.000	54.330 +/- 47.697	12.80% +/- 13.99%	10.43% +/- 9.40%	13.09% +/- 13.96%	
<b>Agix</b>	29.958 +/- 0.000	22.466 +/- 19.819	2.28% +/- 2.09%	2.22% +/- 1.95%	2.31% +/- 2.12%	
<b>Agiy</b>	73.968 +/- 0.000	60.665 +/- 42.320	17.21% +/- 15.71%	14.01% +/- 9.98%	18.11% +/- 15.80%	
<b>Agdx</b>	30.518 +/- 0.000	22.110 +/- 21.036	6.00% +/- 5.92%	5.59% +/- 5.11%	6.27% +/- 6.31%	
<b>Agdy</b>	76.136 +/- 0.000	60.781 +/- 45.852	17.83% +/- 18.04%	14.10% +/- 10.88%	18.68% +/- 18.12%	
	<b>normalized absolute error</b>	<b>root relative squared error</b>	<b>squared error</b>	<b>correlation</b>	<b>squared correlation</b>	<b>prediction average</b>
<b>Cdix</b>	0.860	0.927	888.428 +/- 2009.382	0.657	0.431	1114.776 +/- 32.160
<b>Cdiy</b>	0.946	1.024	5298.105 +/- 8171.878	0.307	0.094	839.994 +/- 71.085
<b>Cddx</b>	0.914	0.944	663.189 +/- 1198.616	0.520	0.270	254.358 +/- 27.292
<b>Cddy</b>	0.939	1.015	5248.397 +/- 8245.390	0.291	0.085	833.842 +/- 71.370
<b>Goix</b>	0.927	0.951	1178.996 +/- 1792.868	0.484	0.234	1033.976 +/- 36.119
<b>Goiy</b>	0.967	1.007	5672.275 +/- 7539.144	0.349	0.122	429.782 +/- 74.828
<b>Godx</b>	0.952	0.979	945.175 +/- 1496.197	0.378	0.143	338.636 +/- 31.413
<b>Gody</b>	0.970	1.002	5829.006 +/- 7716.954	0.396	0.157	421.382 +/- 76.176
<b>Mex</b>	0.945	0.983	669.377 +/- 1242.811	0.360	0.130	689.970 +/- 26.324
<b>Mey</b>	0.954	0.978	5474.031 +/- 7195.111	0.420	0.176	252.479 +/- 75.685
<b>Idx</b>	0.922	0.982	616.301 +/- 1349.428	0.462	0.214	684.455 +/- 25.288
<b>Idy</b>	0.914	1.006	5226.792 +/- 8124.077	0.401	0.161	486.412 +/- 71.859
<b>Agix</b>	0.915	0.941	897.502 +/- 1643.182	0.574	0.329	998.030 +/- 31.827
<b>Agiy</b>	0.975	0.994	5471.224 +/- 6667.298	0.300	0.090	396.309 +/- 74.409
<b>Agdx</b>	0.958	0.979	931.379 +/- 1912.451	0.326	0.106	376.461 +/- 31.164
<b>Agdy</b>	0.970	0.998	5796.718 +/- 7784.528	0.398	0.158	393.430 +/- 76.298

**Tabla 4-10:** Coeficiente de correlación 'r' de las coordenadas mandibulares predichas

Variable	R	Variable	R
Cdix	0,14101085	Cdiy	0,071096
Cddx	0,10964578	Cddy	0,06151
Goix	0,09624766	Goiy	0,044759
Godx	0,04215927	Gody	0,03846871
Mex	0,03405333	Mey	0,04437172
Idx	0,03621679	Idy	0,1033357
Agix	0,11399379	Agiy	0,01182559
Agdx	0,04098421	Agdy	0,031918

Los datos observados en la Tabla 4-10 demostraron que al igual que las radiografías de perfil (Tabla 4-8) no hay ningún resultado relevante en la predicción de landmarks, por lo tanto fue necesario considerar otra metodología para establecer un modelo de predicción.

#### 4.4 Predicción de medidas mandibulares seleccionadas en radiografías de perfil

**Tabla 4-11:** Error cuadrático medio de las variables mandibulares predichas

<b>727 Variables craneomaxilares</b>			
<b>Variable</b>	<b>RMSE</b>	<b>Variable</b>	<b>RMSE</b>
<b>B-Id</b>	12,124 +/- 0,000	<b>Cd-Gn</b>	48,201 +/- 0,000
<b>Poam-B-Id</b>	0,132 +/- 0,000	<b>Gn-Pg</b>	6,788 +/- 0,000
<b>B-Id-Poam</b>	0,126 +/- 0,000	<b>Go-Gn</b>	32,410 +/- 0,000
<b>B-Poam-Id</b>	0,033 +/- 0,000	<b>Gn-Go-B</b>	0,025 +/- 0,000
<b>Cd-Go</b>	36,646 +/- 0,000	<b>Go-Gn-B</b>	0,083 +/- 0,000
<b>Go-Cd-Gn</b>	0,051 +/- 0,000	<b>Gn-B-Go</b>	0,092 +/- 0,000
<b>Cd-Go-Gn</b>	0,108 +/- 0,000	<b>Gn-Go-Id</b>	0,030 +/- 0,000
<b>Go-Gn-Cd</b>	0,047 +/- 0,000	<b>Go-Id-Gn</b>	0,081 +/- 0,000
<b>Go-Cd-Me</b>	0,048 +/- 0,000	<b>Id-Gn-Go</b>	0,089 +/- 0,000
<b>Cd-Go-Me</b>	0,090 +/- 0,000	<b>Go-Me</b>	32,213 +/- 0,000
<b>Go-Me-Cd</b>	0,049 +/- 0,000	<b>Id-Poam</b>	16,544 +/- 0,000
<b>Poam-Cd-Id</b>	0,031 +/- 0,000	<b>Me-Gn</b>	9,545 +/- 0,000
<b>Poam-Id-Cd</b>	0,048 +/- 0,000	<b>Pg-Me-Gn</b>	0,130 +/- 0,000

<b>Cd-Poam-Id</b>	0,076 +/- 0,000	<b>Me-Gn-Pg</b>	0,196 +/- 0,000
<b>Cd-Poam</b>	35,292 +/- 0,000	<b>Gn-Pg-Me</b>	0,116 +/- 0,000
<b>Gn-B</b>	16,607 +/- 0,000	<b>Pg-B</b>	15,572 +/- 0,000
<b>Gn-Id</b>	21,475 +/- 0,000	<b>B-Pg-Id</b>	0,054 +/- 0,000
<b>Id-Gn-Poam</b>	0,059 +/- 0,000	<b>Pg-B-Id</b>	0,120 +/- 0,000
<b>Gn-Id-Poam</b>	0,085 +/- 0,000	<b>Pg-Id-B</b>	0,078 +/- 0,000
<b>Gn-Poam-Id</b>	0,048 +/- 0,000		

**Tabla 4-12:** Coeficiente de correlación 'r' de las medidas mandibulares predichas

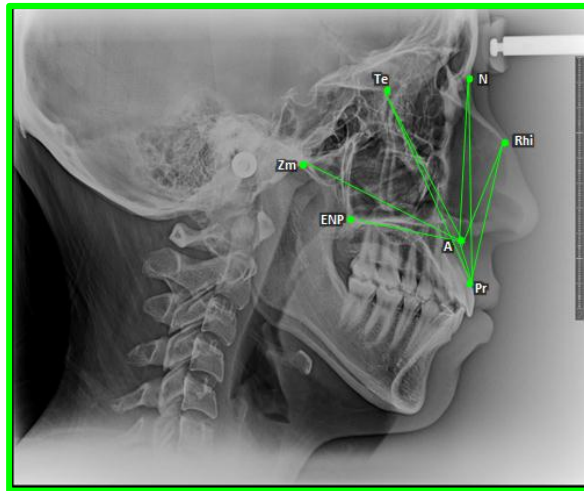
<b>727 Variables craneomaxilares</b>			
<b>Variable</b>	<b>R</b>	<b>Variable</b>	<b>R</b>
<b>B-Id</b>	0,20998208	<b>Cd-Gn</b>	0,23149664
<b>Poam-B-Id</b>	0,30067	<b>Gn-Pg</b>	0,18792051
<b>B-Id-Poam</b>	0,38275	<b>Go-Gn</b>	0,20342029
<b>B-Poam-Id</b>	0,40300968	<b>Gn-Go-B</b>	0,4275
<b>Cd-Go</b>	0,22914484	<b>Go-Gn-B</b>	0,34549
<b>Go-Cd-Gn</b>	0,29775	<b>Gn-B-Go</b>	0,31399
<b>Cd-Go-Gn</b>	0,66551	<b>Gn-Go-Id</b>	0,40758
<b>Go-Gn-Cd</b>	0,26889	<b>Go-Id-Gn</b>	0,40959
<b>Go-Cd-Me</b>	0,33952504	<b>Id-Gn-Go</b>	0,72559
<b>Cd-Go-Me</b>	0,25444	<b>Go-Me</b>	0,20371497
<b>Go-Me-Cd</b>	0,21969031	<b>Id-Poam</b>	0,15696477
<b>Poam-Cd-Id</b>	0,36672	<b>Me-Gn</b>	0,10196329
<b>Poam-Id-Cd</b>	0,3915	<b>Pg-Me-Gn</b>	0,18929
<b>Cd-Poam-Id</b>	0,36472	<b>Me-Gn-Pg</b>	0,74227
<b>Cd-Poam</b>	0,29257392	<b>Gn-Pg-Me</b>	0,19468
<b>Gn-B</b>	0,25992475	<b>Pg-B</b>	0,1864443
<b>Gn-Id</b>	0,28431979	<b>B-Pg-Id</b>	0,25014
<b>Id-Gn-Poam</b>	0,55877	<b>Pg-B-Id</b>	0,18857
<b>Gn-Id-Poam</b>	0,43533	<b>Pg-Id-B</b>	0,17909
<b>Gn-Poam-Id</b>	0,54844401		

Los resultados más altos fueron: el ángulo Cd-Go-Gn con un r de 0.665, el ángulo Id-Gn-Go con un r de 0.725 y el ángulo Me-Gn-Pg con un r de 0.742. La capacidad predictiva de las redes neuronales no se pudo establecer en el presente modelo, ya que las redes tuvieron dificultad por la gran cantidad de variables de entrada, por lo tanto los objetivos no se pudieron cumplir y se hizo necesario un cambio de metodología.


## 4.5 Predicción de medidas mandibulares a partir de medidas craneomaxilares seleccionadas en radiografías de perfil

- Conjuntos de características de entrada o variables craneomaxilares seleccionadas:



**Figura 4-6:** Variables Sintéticas (10 Variables)



**Figura 4-7:** Variables de la literatura (12 Variables)





**Figura 4-8:** Combinación variables sintéticas y de literatura (22 Variables)**Figura 4-9:** Combinación variables sintéticas de literatura y distancias de las variables sintéticas (33 Variables)**Tabla 4-13:** Coeficiente de correlación 'r' de las medidas mandibulares predichas en máquinas de vectores de soporte

Variable	R				
	10 Variables	12 Variables	22 Variables		
			Lineal		RBF
B-Id	0,033618	0,157659	0,159511	0,103277	0,075729
Cd-Gn	0,092541	0,357428	0,330469	0,029349	0,074929
Cd-Go	0,010277	0,267096	0,221982	0,038487	0,072787
Cd-Go-Gn	0,092560	0,102580	0,112466	0,502360	0,059384

Cd-Go-Me	0,103580	0,124130	0,135445	0,496968	0,065831
Cd-Me	0,083439	0,315990	0,319640	0,028897	0,069306
Gn-B	0,000870	0,343712	0,301947	0,069666	0,088399
Gn-Id	0,011093	0,381962	0,320916	0,060460	0,100238
Gn-Pg	0,004230	0,145725	0,135018	0,179537	0,065438
Go-Gn	0,087287	0,320291	0,333862	0,035634	0,054950
Go-Gn-B	0,132950	0,222280	0,265630	0,476161	0,143956
Go-Me	0,087756	0,247697	0,306537	0,043023	0,060265
Id-Gn-Go	0,290990	0,233110	0,335000	0,532435	0,202902
Me-Gn	0,005310	0,086049	0,101994	0,122580	0,000910
Me-Gn-Pg	0,040129	0,077040	0,084946	0,833912	0,044472
Pg-B	0,001300	0,248500	0,219532	0,083079	0,062967
Pg-B-Id	0,024390	0,042370	0,044390	0,636022	0,020903
<b>33 Variables</b>					
	<b>Lineal</b>	<b>RBF</b>	<b>Polinomial</b>		
B-Id	0,279120	0,103261	0,098342		
Cd-Gn	0,531272	0,029359	0,075064		
Cd-Go	0,381854	0,038501	0,071844		
Cd-Go-Gn	0,105853	0,502384	0,049177		
Cd-Go-Me	0,187450	0,497025	0,061957		
Cd-Me	0,476466	0,028902	0,068889		
Gn-B	0,392533	0,069673	0,098448		
Gn-Id	0,491729	0,060464	0,113640		
Gn-Pg	0,157826	0,179493	0,066851		
Go-Gn	0,365943	0,035639	0,052368		
Go-Gn-B	0,291109	0,476264	0,056570		
Go-Me	0,308331	0,043023	0,053210		
Id-Gn-Go	0,316717	0,532360	0,138670		
Me-Gn	0,102954	0,122612	0,005951		
Me-Gn-Pg	0,136002	0,833932	0,017848		
Pg-B	0,295717	0,083091	0,061018		
Pg-B-Id	0,171158	0,635963	0,006509		

Los coeficientes dados por la regresión son poco significativos en su gran mayoría. El comportamiento del kernel de función de base radial fue muy similar en los conjuntos de características de entrada de 22 y 33 variables craneomaxilares donde se encontraron algunos valores superiores al 0.5; los valores más altos se dieron en el ángulo Pg-B-Id con un coeficiente de 0.636 y en el ángulo Me-Gn-Pg con un coeficiente

de 0.833, este último superó al kernel lineal usado en la predicción de medidas mandibulares a partir de todas las variables craneomaxilares (Tabla 4-12), ya que en esa metodología el valor de Me-Gn-Pg fue de 0.745.

**Tabla 4-14:** Coeficiente de correlación 'r' de las medidas mandibulares predichas en redes neuronales

Ridge Regression				
Variable	10 Variables	12 Variables	22 Variables	33 Variables
B-Id	0,21493	0,4894	0,80864	0,95887
Cd-Gn	0,16578	0,79083	0,89634	0,93417
Cd-Go	0,26007	0,86145	0,93094	0,98976
Cd-Go-Gn	0,27658	0,30916	0,99043	0,97580
Cd-Go-Me	0,16335	0,4155	0,66291	0,86807
Cd-Me	0,21476	0,78952	0,83066	0,84191
Gn-B	0,16624	0,81824	0,95333	0,86424
Gn-Id	0,20273	0,95764	0,85914	0,93104
Gn-Pg	0,04382	0,5755	0,84817	0,72744
Go-Gn	0,23509	0,51106	0,91832	0,67469
Go-Gn-B	0,22613	0,47111	0,78032	0,88976
Go-Me	0,20297	0,38935	0,89558	0,16680
Id-Gn-Go	0,35484	0,5348	0,93827	0,93297
Me-Gn	0,08103	0,53474	0,89880	0,96299
Me-Gn-Pg	0,1782	0,35237	0,75576	0,96771
Pg-B	0,16933	0,54867	0,84527	0,618775348
Pg-B-Id	0,09046	0,17073	0,79254	0,92876

En el conjunto de características de 10 variables craneomaxilares (variables sintéticas) no hubo ningún valor mayor a 0.5. La mejor dependencia funcional de la variable Gn-Id ocurrió en el conjunto de características de 12 variables craneomaxilares con un coeficiente r de 0,957; los mejores coeficientes r de las variables Cd-Go-Gn, Gn-B, Gn-Pg, Go-Gn, Go-Me, Id-Gn-Go y Pg-B se dieron en la combinación de variables sintéticas y las de la literatura con valores de 0.99, 0.95, 0.84, 0.91, 0.89, 0.93 y 0.84 respectivamente. En el conjunto de características de 33 variables craneomaxilares se obtuvo la mayoría de coeficientes más altos, estos fueron dados en las variables B-Id,

Cd-Gn, Cd-Go, Cd-Go-Me, Cd-Me, Go-Gn-B, Me-Gn, Me-Gn-Pg y Pg-B-Id con coeficientes de 0.95, 0.93, 0.98, 0.86, 0.84, 0.88, 0.96, 0.96 y 0.92 respectivamente.

**Tabla 4-15:** Error cuadrático medio de las variables mandibulares predichas en máquinas de vectores de soporte

RMSE					
Variable	10 Variables	12 Variables	22 Variables		
	Lineal	Lineal	Lineal	RBF	Polinomial
B-Id	13,409 +/- 0,000	12,519 +/- 0,000	12,505 +/- 0,000	12,917 +/- 0,000	13,114 +/- 0,000
Cd-Gn	52,377 +/- 0,000	44,075 +/- 0,000	44,990 +/- 0,000	54,170 +/- 0,000	52,883 +/- 0,000
Cd-Go	41,523 +/- 0,000	35,732 +/- 0,000	36,816 +/- 0,000	40,927 +/- 0,000	40,191 +/- 0,000
Cd-Go-Gn	0,098 +/- 0,000	0,100 +/- 0,000	0,097 +/- 0,000	0,073 +/- 0,000	0,100 +/- 0,000
Cd-Go-Me	0,097 +/- 0,000	0,098 +/- 0,000	0,095 +/- 0,000	0,073 +/- 0,000	0,099 +/- 0,000
Cd-Me	52,654 +/- 0,000	45,486 +/- 0,000	45,365 +/- 0,000	54,198 +/- 0,000	53,058 +/- 0,000
Gn-B	19,314 +/- 0,000	15,639 +/- 0,000	16,129 +/- 0,000	18,620 +/- 0,000	18,432 +/- 0,000
Gn-Id	25,243 +/- 0,000	19,956 +/- 0,000	20,918 +/- 0,000	24,605 +/- 0,000	24,078 +/- 0,000
Gn-Pg	7,579 +/- 0,000	6,962 +/- 0,000	7,005 +/- 0,000	6,823 +/- 0,000	7,282 +/- 0,000
Go-Gn	34,692 +/- 0,000	29,938 +/- 0,000	29,638 +/- 0,000	35,661 +/- 0,000	35,302 +/- 0,000
Go-Gn-B	0,092 +/- 0,000	0,090 +/- 0,000	0,090 +/- 0,000	0,071 +/- 0,000	0,091 +/- 0,000
Go-Me	34,479 +/- 0,000	31,311 +/- 0,000	30,061 +/- 0,000	35,314 +/- 0,000	34,995 +/- 0,000
Id-Gn-Go	0,099 +/- 0,000	0,099 +/- 0,000	0,095 +/- 0,000	0,077 +/- 0,000	0,100 +/- 0,000
Me-Gn	10,125 +/- 0,000	9,629 +/- 0,000	9,545 +/- 0,000	9,435 +/- 0,000	10,081 +/- 0,000
Me-Gn-Pg	0,208 +/- 0,000	0,207 +/- 0,000	0,203 +/- 0,000	0,086 +/- 0,000	0,207 +/- 0,000
Pg-B	17,259 +/- 0,000	14,966 +/- 0,000	15,252 +/- 0,000	16,531 +/- 0,000	16,711 +/- 0,000
Pg-B-Id	0,124 +/- 0,000	0,124 +/- 0,000	0,124 +/- 0,000	0,075 +/- 0,000	0,123 +/- 0,000

33 Variables			
	Lineal	RBF	Polinomial
B-Id	11,581 +/- 0,000	12,917 +/- 0,000	12,952 +/- 0,000
Cd-Gn	37,644 +/- 0,000	54,170 +/- 0,000	52,879 +/- 0,000
Cd-Go	32,816 +/- 0,000	40,927 +/- 0,000	40,211 +/- 0,000
Cd-Go-Gn	0,097 +/- 0,000	0,073 +/- 0,000	0,100 +/- 0,000
Cd-Go-Me	0,096 +/- 0,000	0,073 +/- 0,000	0,099 +/- 0,000
Cd-Me	39,794 +/- 0,000	54,198 +/- 0,000	53,070 +/- 0,000
Gn-B	15,046 +/- 0,000	18,620 +/- 0,000	18,330 +/- 0,000
Gn-Id	18,097 +/- 0,000	24,605 +/- 0,000	23,898 +/- 0,000
Gn-Pg	6,912 +/- 0,000	6,823 +/- 0,000	7,276 +/- 0,000

<b>Go-Gn</b>	28,916 +/- 0,000	35,660 +/- 0,000	35,350 +/- 0,000
<b>Go-Gn-B</b>	0,090 +/- 0,000	0,071 +/- 0,000	0,096 +/- 0,000
<b>Go-Me</b>	30,022 +/- 0,000	35,314 +/- 0,000	35,126 +/- 0,000
<b>Id-Gn-Go</b>	0,095 +/- 0,000	0,077 +/- 0,000	0,104 +/- 0,000
<b>Me-Gn</b>	9,540 +/- 0,000	9,435 +/- 0,000	10,042 +/- 0,000
<b>Me-Gn-Pg</b>	0,207 +/- 0,000	0,086 +/- 0,000	0,210 +/- 0,000
<b>Pg-B</b>	14,488 +/- 0,000	16,531 +/- 0,000	16,729 +/- 0,000
<b>Pg-B-Id</b>	0,126 +/- 0,000	0,075 +/- 0,000	0,124 +/- 0,000

**Tabla 4-16:** Error cuadrático medio de las variables mandibulares predichas en redes neuronales

Variable	RMSE			
	10 Variables	12 Variables	22 Variables	33 Variables
<b>B-Id</b>	12,398 +/- 0,000	11,195 +/- 0,000	11,002 +/- 0,000	5,825 +/- 0,000
<b>Cd-Gn</b>	74,109 +/- 0,000	32,407 +/- 0,000	22,579 +/- 0,000	24,377 +/- 0,000
<b>Cd-Go</b>	39,146 +/- 0,000	29,011 +/- 0,000	25,490 +/- 0,000	17,781 +/- 0,000
<b>Cd-Go-Gn</b>	0,098 +/- 0,000	0,094 +/- 0,000	0,099 +/- 0,000	0,057 +/- 0,000
<b>Cd-Go-Me</b>	0,094 +/- 0,000	0,089 +/- 0,000	0,077 +/- 0,000	0,061 +/- 0,000
<b>Cd-Me</b>	49,288 +/- 0,000	31,629 +/- 0,000	28,600 +/- 0,000	21,868 +/- 0,000
<b>Gn-B</b>	18,843 +/- 0,000	13,365 +/- 0,000	13,365 +/- 0,000	8,656 +/- 0,000
<b>Gn-Id</b>	23,404 +/- 0,000	26,250 +/- 0,000	14,690 +/- 0,000	11,186 +/- 0,000
<b>Gn-Pg</b>	9,238 +/- 0,000	6,428 +/- 0,000	6,623 +/- 0,000	3,932 +/- 0,000
<b>Go-Gn</b>	33,967 +/- 0,000	29,292 +/- 0,000	27,551 +/- 0,000	20,712 +/- 0,000
<b>Go-Gn-B</b>	0,096 +/- 0,000	0,076 +/- 0,000	0,089 +/- 0,000	0,050 +/- 0,000
<b>Go-Me</b>	39,917 +/- 0,000	28,833 +/- 0,000	20,945 +/- 0,000	32,951 +/- 0,000
<b>Id-Gn-Go</b>	0,108 +/- 0,000	0,100 +/- 0,000	0,069 +/- 0,000	0,053 +/- 0,000
<b>Me-Gn</b>	11,355 +/- 0,000	8,490 +/- 0,000	7,205 +/- 0,000	9,138 +/- 0,000
<b>Me-Gn-Pg</b>	0,197 +/- 0,000	0,229 +/- 0,000	0,196 +/- 0,000	0,108 +/- 0,000
<b>Pg-B</b>	18,829 +/- 0,000	16,081 +/- 0,000	10,824 +/- 0,000	10,659 +/- 0,000
<b>Pg-B-Id</b>	0,162 +/- 0,000	0,118 +/- 0,000	0,100 +/- 0,000	0,109 +/- 0,000

**Tabla 4-17:** Comparación del error cuadrático medio más bajo entre redes neuronales y máquinas de vectores de soporte

	ANN	SVM
<b>B-Id</b>	5,825 +/- 0,000	11,581 +/- 0,000

<b>Cd-Gn</b>	22,579 +/- 0,000	37,644 +/- 0,000
<b>Cd-Go</b>	17,781 +/- 0,000	32,816 +/- 0,000
<b>Cd-Go-Gn</b>	0,057 +/- 0,000	0,073 +/- 0,000
<b>Cd-Go-Me</b>	0,061 +/- 0,000	0,073 +/- 0,000
<b>Cd-Me</b>	21,868 +/- 0,000	39,794 +/- 0,000
<b>Gn-B</b>	8,656 +/- 0,000	15,046 +/- 0,000
<b>Gn-Id</b>	11,186 +/- 0,000	18,097 +/- 0,000
<b>Gn-Pg</b>	3,932 +/- 0,000	6,823 +/- 0,000
<b>Go-Gn</b>	20,712 +/- 0,000	28,916 +/- 0,000
<b>Go-Gn-B</b>	0,050 +/- 0,000	0,071 +/- 0,000
<b>Go-Me</b>	20,945 +/- 0,000	30,022 +/- 0,000
<b>Id-Gn-Go</b>	0,053 +/- 0,000	0,077 +/- 0,000
<b>Me-Gn</b>	7,205 +/- 0,000	9,435 +/- 0,000
<b>Me-Gn-Pg</b>	0,108 +/- 0,000	0,086 +/- 0,000
<b>Pg-B</b>	10,659 +/- 0,000	14,488 +/- 0,000
<b>Pg-B-Id</b>	0,100 +/- 0,000	0,075 +/- 0,000

Con respecto a la comparación de las redes neuronales artificiales con las máquinas de vectores de soporte en términos de error cuadrático medio, se puede observar que en la mayoría de variables fue más bajo en las redes neuronales, no obstante en las variables Me-Gn-Pg y Pg-B-Id el error fue más bajo para las máquinas de vectores de soporte; este valor no se refleja en las correlaciones ya que para Me-Gn-Pg y Pg-B-Id los valores de correlación de las ANN fueron de 0.96 y 0.92 respectivamente y los valores de correlación de las SVM fueron de 0.83 y 0.63

## 4.6 Predicción de medidas mandibulares seleccionadas en radiografías posteroanteriores

**Tabla 4-18:** Error cuadrático medio de las variables mandibulares predichas

Variable	RMSE	Variable	RMSE
Agi-Agd	35,683 +/- 0,000	Cdi-Poami	28,907 +/- 0,000
Cdd-God	37,688 +/- 0,000	God-Me	32,167 +/- 0,000
Cdd-God-Me	0,077 +/- 0,000	Goi-God	45,553 +/- 0,000
Cdd-Me	41,948 +/- 0,000	Goi-Me-God	0,119 +/- 0,000

Cdd-Agd-Me	0,123 +/- 0,000	Goi-Me	31,937 +/- 0,000
Cdd-Poamd	29,498 +/- 0,000	Me-Agd	28,410 +/- 0,000
Cdi-Agi	35,074 +/- 0,000	Me-Agi	27,075 +/- 0,000
Cdi-Cdd	38,028 +/- 0,000	Agi- Me -Agd	0,132 +/- 0,000
Cdi-Me-Cdd	0,033 +/- 0,000	Me-Id	19,589 +/- 0,000
Cdi-Goi	33,798 +/- 0,000	Poamd-Id	18,572 +/- 0,000
Cdi-Goi-Me	0,073 +/- 0,000	Poami-Id	14,929 +/- 0,000
Cdi-Me	41,103 +/- 0,000	Poami-Id-Poamd	0,110 +/- 0,000
Cdi- Agi -Me	0,069 +/- 0,000	Cdd-Agd	38,373 +/- 0,000
Poami-Poamd	23,419 +/- 0,000		

**Tabla 4-19:** Coeficiente de correlación 'r' de las medidas mandibulares predichas

Variable	R	Variable	R
Agi-Agd	0,1176415	Cdi-Poami	0,23135006
Cdd-God	0,11800427	God-Me	0,12473234
Cdd-God-Me	0,55517915	Goi-God	0,09434929
Cdd-Me	0,1952037	Goi-Me-God	0,6050273
Cdd-Agd-Me	0,28681668	Goi-Me	0,11315787
Cdd-Poamd	0,23624311	Me-Agd	0,13690599
Cdi-Agi	0,15050473	Me-Agi	0,11038288
Cdi-Cdd	0,16243176	Agi- Me -Agd	0,58018863
Cdi-Me-Cdd	0,82091194	Me-Id	0,26579511
Cdi-Goi	0,148971	Poamd-Id	0,10957633
Cdi-Goi-Me	0,59037086	Poami-Id	0,09795319
Cdi-Me	0,19507976	Poami-Id-Poamd	0,65100544
Cdi- Agi -Me	0,58465631	Cdd-Agd	0,12258984
Poami-Poamd	0,09505870		

El resultado más significativo fue un r de 0.82 en el ángulo Cdi-Me-Cdd, las medidas lineales al igual que el método en las radiografías de perfil no fueron satisfactorias. No se pudieron usar las redes neuronales por tener muchas variables de entrada.

## 4.7 Predicción de medidas mandibulares a partir de medidas craneomaxilares seleccionadas en radiografías posteroanteriores

**Tabla 4-20:** Coeficiente de correlación 'r' de las medidas mandibulares predichas

R en Radiografías posteroanteriores				
Variable	ANN	Lineal	RBF	Polinomial
Cdd-God	0,72363	0,293578589	0,033753516	0,02853648
Cdd-God-Me	0,46807	0,26044	0,588754476	0,10493911
Cdd-Me	0,82533	0,359805647	0,032402293	0,02941411
Cdi-Cdd	0,77391	0,555103416	0,036224742	0,06830001
Cdi-Goi	0,64353	0,317234884	0,029743953	0,03868287
Cdi-Goi-Me	0,57634	0,32010	0,553809467	0,12524775
Cdi-Me	0,86908	0,465312864	0,033710987	0,04524007
Cdi-Me-Cdd	0,6252	0,410654138	0,353333591	0,21747926
God-Me	0,54597	0,146717606	0,040598034	0,0083961
Goi-God	0,7626	0,276820943	0,030741131	0,02761002
Goi-Me	0,53732	0,227637984	0,040232696	0,02089815
Goi-Me-God	0,6204	0,404966141	0,796120207	0,1717763
Me-Id	0,42017	0,342711387	0,068784799	0,06180366

En esta metodología, en las máquinas de vectores de soporte los resultados fueron mayores en varias medidas lineales con respecto a la metodología de predicción a partir de todas las medidas craneomaxilares; el coeficiente más alto se dio en la medida Cdd-God-Me con 0.588, el cual fue mayor incluso comparado a las redes neuronales. Exceptuando por la variable God-Me, las ANN tuvieron valores de coeficientes más altos que las SVM, no obstante, esta metodología de las redes neuronales con variables craneomaxilares seleccionadas no logró superar al coeficiente del ángulo Cdi-Me-Cdd que fue de 0.82 (Tabla 4-19).

**Tabla 4-21:** Error cuadrático medio de las variables mandibulares predichas



RMSE Radiografías posteroanteriores				
Variable	ANN	Lineal	RBF	Polinomial
<b>Cdd-God</b>	26,581 +/- 0,000	40,229 +/- 0,000	39,617 +/- 0,000	39,724 +/- 0,000
<b>Cdd-God-Me</b>	0,088 +/- 0,000	0,111 +/- 0,000	0,074 +/- 0,000	0,109 +/- 0,000
<b>Cdd-Me</b>	26,464 +/- 0,000	46,632 +/- 0,000	45,942 +/- 0,000	46,013 +/- 0,000
<b>Cdi-Cdd</b>	22,469 +/- 0,000	41,533 +/- 0,000	40,861 +/- 0,000	40,176 +/- 0,000
<b>Cdi-Goi</b>	24,172 +/- 0,000	36,809 +/- 0,000	36,302 +/- 0,000	36,134 +/- 0,000
<b>Cdi-Goi-Me</b>	0,089 +/- 0,000	0,109 +/- 0,000	0,076 +/- 0,000	0,106 +/- 0,000
<b>Cdi-Me</b>	23,479 +/- 0,000	45,786 +/- 0,000	45,095 +/- 0,000	44,825 +/- 0,000
<b>Cdi-Me-Cdd</b>	0,050 +/- 0,000	0,071 +/- 0,000	0,063 +/- 0,000	0,069 +/- 0,000
<b>God-Me</b>	28,749 +/- 0,000	34,405 +/- 0,000	33,682 +/- 0,000	34,243 +/- 0,000
<b>Goi-God</b>	46,688 +/- 0,000	47,714 +/- 0,000	47,036 +/- 0,000	47,112 +/- 0,000
<b>Goi-Me</b>	25,914 +/- 0,000	33,793 +/- 0,000	33,126 +/- 0,000	33,458 +/- 0,000
<b>Goi-Me-God</b>	0,144 +/- 0,000	0,180 +/- 0,000	0,085 +/- 0,000	0,172 +/- 0,000
<b>Me-Id</b>	19,851 +/- 0,000	22,755 +/- 0,000	22,003 +/- 0,000	22,085 +/- 0,000

Por otro lado, comparando las máquinas de vectores de soporte y las redes neuronales en radiografías posteroanteriores en términos de RMSE, el error es más pequeño en las redes neuronales en las variables Cdd-God, Cdd-Me, Cdi-Cdd, Cdi-Goi, Cdi-Goi-Me, Cdi-Me-Cdd, Goi-God y Goi-Me-God. La variable Cdd-God-Me tiene un error más bajo en las SVM de kernel de función de base radial, coincidiendo con el coeficiente más alto (de esa variable) dado por la ridge regression.



## 5. Discusión

La predicción y clasificación en odontología y antropología han sido un tema de interés de muchos investigadores a través del tiempo incluso antes del inicio del empleo de las radiografías en estos campos (147). Muchas de las investigaciones de predicción son estudios longitudinales donde pretenden pronosticar el éxito de un tratamiento en una maloclusión específica (32, 148-151) o la conformación craneofacial que el paciente tomará debido a las condiciones de crecimiento y desarrollo (9, 10, 32, 152-154). En muchos de estos estudios se han tenido en cuenta estadísticas paramétricas que se enfocan en establecer estándares funcionales y estéticos, aunque existe la tendencia de etiquetar al paciente como normal y anormal, pero no se tiene en cuenta lo anormal como una variedad biológica y genética (155).

Existen publicaciones que correlacionan estructuras óseas para predicción de crecimiento, tal es el caso de Pileski et al. que relacionaron los picos de crecimiento mandibulares con la aparición del hueso sesamoideo, por medio de estadística descriptiva y curvas de crecimiento donde los resultados más altos eran una correlación de 0.42 y 0.36 no siendo muy satisfactorios (156). Sin embargo hay muy pocos estudios de corte transversal que pretenden relacionar esas estructuras óseas para fines reconstructivos, más aun para la reconstrucción de la mandíbula a pesar de su justificación forense (2) e incluso quirúrgica (3).

En el presente estudio se pretendió predecir la morfología mandibular y realizar una previa clasificación de maloclusiones esqueléticas a partir de variables únicamente craneomaxilares de forma automatizada usando sistemas semiparamétricos como las redes neuronales y sistemas no paramétricos como las máquinas de vectores de soporte, las cuales son diseñadas principalmente para estos fines en otras aplicaciones (25).

Para la realización del primer objetivo específico que era clasificar individuos en Clase I, II y III esquelética utilizando técnicas de aprendizaje automatizado, se emplearon medidas lineales y angulares estandarizadas en protocolos ortodónticos y antropológicos (2, 134-139), se eliminaron los ángulos ANB, SNA y SNB, y se clasificaron con SVM y ANN, al ver que los resultados no eran tan satisfactorios se balancearon las clases y también se predijo con la red neuronal para después clasificar con dicha predicción; este análisis se realizó en radiografías de perfil, posteroanteriores y combinación de perfil y posteroanteriores; el valor más alto obtuvo una precisión del 85.11% en la clasificación con el ángulo ANB predicho con variables de ambos tipos de radiografías (Tabla 4-1 y Tabla 4-2).

Para el enfoque del estudio la metodología presentaba dos falencias relevantes, la primera fue el no haber excluido a la variable Ao-Bo correspondiente a Witts ya que es una proyección en el plano oclusal de los puntos A y B que son esenciales para la clasificación, además muchas veces se usa como clasificador principal o para confirmar la clasificación dada por el ángulo ANB (135).

A pesar de esto los datos son relevantes si se les aplican otros enfoques por ejemplo para diferenciación de características esqueléticas con fines de diagnóstico ortodóntico en pacientes, ya que el sistema clasificó correctamente a la Clase I, II y III en 81.25%, 82.35%, 92.86% respectivamente (Figura 4-1) y supo diferenciar de manera adecuada la Clase II de la III y viceversa ya que no hubo pacientes mal clasificados entre estas clases.

En muchos casos esa diferenciación de clases se han hecho incluso sin excluir al ángulo ANB, tal es el caso de Harris et al., que comparó pacientes Clase I y Clase II por medio de estadística descriptiva y análisis de función discriminante determinando al ángulo ANB como mejor discriminante aunque era distinto en comparación a los valores reportados por Steiner. Para la Clase I se clasificó con 81% y para la Clase II con un 88.6% (157), que resultan ser valores similares a los proporcionados en la primera experimentación de este estudio. En casos como diferenciación de características raciales (158), patrones

familiares (159), predicción de tratamientos (151), relación con patrones faciales (160), entre otros, sería útil esta metodología realizada.

La segunda falencia fue utilizar medidas mixtas debido a que había un número muy limitado tanto de medidas propiamente mandibulares como de medidas propiamente maxilares, en respuesta a dicha problemática se decidió ampliar los atributos mediante el uso de landmarks y realizar combinaciones lineales y angulares excluyendo las variables mixtas y dentales. A partir de esas medidas se determinó el ángulo ANB para reclasificar a los pacientes y realizar una posterior clasificación definitiva de maloclusiones.

Con esta metodología se pretendió cumplir de manera definitiva el primer objetivo específico. En la radiografía de perfil usando una optimización de parámetros por el método GRID se escogió el mejor parámetro C que fue de 225 y se hizo la experimentación con 6 y 9 variables explicativas dando una precisión de 72.55% en cada una, a pesar que el optimizador decía que tenía una precisión de 82.3%; esto fue debido a que el parámetro C no debe ser tan grande ya que resulta ser muy flexible como clasificador permitiendo errores (25); debido a esto se escogió un parámetro C más pequeño como el 9.0 con una precisión alta de 70,50%. La precisión aumentó a un 74.51% con una clasificación del 62.50%, 77.78% y 82.35% en la Clase I, II y III (Figura 4-2), los pacientes Clase I que fueron mal clasificados pertenecían aquellos pacientes que se encuentran en los límites de clasificación como medidas hacia 4° ó hacia 0°, sin embargo diferenció adecuadamente la Clase II de la Clase III.

Las variables explicativas de la mejor clasificación (ENP-A-Pr, Zm-A-Pr, Te-Pr-A, Pr-A-Te, Rhi-A-Pr, A-Pr-Rhi, A-Te-Pr, A-N-Pr, N-Pr-A y Pr-A-N) no son medidas convencionales, todas son angulares e incluyen a los puntos Pr y A demostrando una gran importancia de estos dos landmarks en la clasificación (Tabla 4-4). Sin embargo la importancia del Pr es escasa en la literatura y del punto A es relevante en combinación con N y con S en el complejo craneomaxilar, para la formación del ángulo SNA debido a que este determina la posición del maxilar superior con respecto a la base craneal anterior (161).

Adicionalmente Rhinion (Rhi) se considera importante en el área forense en la relación entre landmarks nasales y craneofaciales siendo también base para el punto Rhinion de

tejidos blandos, según los hallazgos reportados por Inada et al., aunque no se le da valor en clasificación esquelética, ni en predicción de estructuras craneofaciales (162); así mismo el punto zgomáticomaxilar (Zm), toma importancia en la alta correlación con landmarks maxilares y mandibulares, según el estudio de Adams et al., sin embargo el método además de usarse en coordenadas se hizo en cráneos secos comparando la precisión en la ubicación de estas entre métodos tridimensionales (Tomografía computarizada) y bidimensionales (cefalometría tradicional), no obstante no se tuvieron en cuenta la formación de medidas, ni una metodología de predicción, ni de clasificación (163).

Usando la reclasificación por el ángulo ANB y optimizando parámetros, se realizaron tareas de clasificación en radiografías posteroanteriores determinando un parámetro C de 3.0 que daba una precisión de 64%, la precisión dada por el sistema fue del 66%, clasificando 71.43%, 70% y 60.87% para la Clase I, II y III respectivamente (Figura 4-3), la clasificación resulta ser muy buena teniendo en cuenta que las clasificaciones de maloclusiones se hacen a través de radiografías de perfil y sus respectivas variables y no por medio de radiografías posteroanteriores, por lo tanto es normal que el modelo no pueda distinguir entre las Clases II y III, aunque sorprendentemente no hubo en la Clase I pacientes mal clasificados como Clase II.

En la metodología de clasificación de Metronukak los valores más altos en la precisión se dieron combinando las variables de las radiografías posteroanteriores y de perfil; usando un C de 3.0 que daba un 76% de precisión en la optimización, se procedió a clasificar dando un 68% de precisión que fue más bajo que en la clasificación en radiografías de perfil, este resultado fue definido por 8765 variables, clasificando en 80%, 50% y 76.47% a la Clase I, II y III respectivamente (Figura 4-4), a pesar que el sistema es bueno para la Clase I y la III, el sistema confundió a la Clase II y a la Clase III debido a los atributos de las radiografías posteroanteriores.

La optimización de parámetros del sistema tuvo varias fallas, aunque funcionó bien para las radiografías de perfil, para las radiografías posteroanteriores y las variables de radiografías combinadas no fueron muy satisfactorias; en la primera el sistema indicaba que la clasificación era definida por 17 variables, pero al probar el programa con dichas

variables dio una precisión del 38%, además al observar los pesos, todas las variables tenían el mismo valor de 1 (el cual es el máximo valor); en la segunda al aplicar las 8765 variables para probar el modelo, dio un 54% y al aplicar un número más bajo de variables (19 atributos) con una precisión relativamente cercana a la dada (64%) tuvo una precisión del 40%. Aunque no se sabe con seguridad cuál es el problema, es necesario probar otros optimizadores para confirmar si es algún inconveniente del optimizador del Rapidminer ó existe un comportamiento de los datos que hace que el optimizador permita dichos errores.

Finalmente, se hizo una predicción del ángulo ANB en radiografías de perfil dando un error cuadrático medio de la predicción de 0.034 (Tabla 4-5), con ese valor predicho se optimizaron los parámetros de clasificación determinando que el C de -1.0 era el más adecuado (Tabla 4-6), sin embargo el sistema no lo tuvo en cuenta debido a que el límite inferior que permitía era un C de 0.0. Usando ese parámetro dio una precisión de clasificación de 70.59%, clasificando en 55%, 70.59% y 92.86% a la clase I, II, y III respectivamente (Figura 4-5); este modelo en la Clase II clasificó erróneamente a un individuo como Clase III, lo que da para pensar en su efectividad en tan sólo la Clase III.

Se observó con las tareas de clasificación que las precisiones dadas con el método de landmarks fueron mayores al método de clasificación del Metronukak con sólo variables craneomaxilares (Tabla 4-3) debido a que el mayor valor obtenido con este último fue de 51.06% que resulta ser un valor de clasificación bajo.

Por otro lado para cumplir los objetivos de predicción que fueron estimar la capacidad predictiva de las redes neuronales y las máquinas de vectores de soporte, determinar las relaciones de dependencia funcional de las variables morfológicas mandibulares con respecto a las craneomaxilares y comparar las redes neuronales artificiales con las máquinas de vectores de soporte en términos de error cuadrático medio de la predicción, se consideró inicialmente determinar la ubicación de los landmarks por medio de las coordenadas en X y Y y de esa manera poder construir medidas ilimitadas para explicar la morfología mandibular. Se estableció el error cuadrático medio y se realizó una Ridge Regression. Los coeficientes arrojados por el sistema no fueron relevantes ni para las radiografías de perfil ni para las radiografías posteroanteriores (Tablas 4-7, 4-8, 4-9 y 4-10). Para este tipo de predicción se ha tomado una tendencia en varios estudios de

determinar los landmarks tanto en máquinas de vectores de soporte (118-121) como en las redes neuronales (164-170) mediante combinaciones de algoritmos de imágenes y escala de grises, los cuales a comparación de lo visto en este trabajo, muestran resultados satisfactorios.

Teniendo en cuenta lo anterior se pensó en la alternativa de predicción de medidas mandibulares seleccionadas a partir de todas las medidas craneomaxilares (727 variables) en la radiografía de perfil, usando una metodología similar a la anterior. Usando máquinas de vectores de soporte se detectó el error cuadrático medio y se determinaron los coeficientes de correlación siendo importantes el ángulo Cd-Go-Gn, Id-Gn-Go y Me-Gn-Pg con  $r$  de 0.665, 0.725 y 0.742 respectivamente (Tabla 4-11), los cuales son valores relevantes. En cuanto a las radiografías posteroanteriores el coeficiente más significativo se dio en el ancho bicondilar (Cdi-Me-Cdd) que fue de 0.82 (Tabla 4-19).

Sin embargo no se podían cumplir los objetivos específicos debido a que las redes neuronales estaban manejando datos de entrada muy grandes, por lo cual el sistema no podía concluir sus tareas por falta de memoria, representando una ventaja para las máquinas de vectores de soporte.

En respuesta a esto se diseñó un método donde se seleccionaron conjuntos de características de entrada o variables craneomaxilares. Para la estimación de la capacidad predictiva de ambas técnicas de aprendizaje, se usó la ridge regression. Para determinar las relaciones de dependencia funcional se usaron los coeficientes de la regresión, explicando a cada variable mandibular mediante un grupo de variables craneomaxilares específico. Y teniendo resultados con redes neuronales fue posible comparar ambas técnicas en términos de error cuadrático medio.

En radiografías de perfil se tuvieron en cuenta 4 conjuntos de características de entrada, la primera correspondía a las mejores variables craneomaxilares obtenidas con la clasificación o variables sintéticas (10 variables), la segunda correspondía a variables estándar contenidas en protocolos ortodónticos y antropológicos (12 variables), la tercera correspondía a la combinación de las variables sintéticas y de literatura (22 variables) y



la cuarta correspondía a la adición de 11 variables correspondientes a las distancias de los ángulos de las variables sintéticas (33 variables).

La capacidad predictiva de las redes neuronales (Tabla 4-14) fue mucho mejor que en las máquinas de vectores de soporte ya que el valor más alto en las SVM fue en la variable Me-Gn-Pg con un coeficiente de 0.83 en el kernel de función de base radial (Tabla 4-13), que respondió mucho mejor que el kernel lineal y el polinomial, aunque la mayoría de resultados no fueron tan relevantes.

En las radiografías posteroanteriores se escogieron solamente variables craneomaxilares estándar, debido a que en el proceso de clasificación no se pudieron determinar las variables más relevantes, los mejores coeficientes se dieron en las redes neuronales menos en el ángulo Cdd-God-Me que fue mejor en el kernel de función de base radial aunque su relevancia es moderada ( $r=0.588$ ). Los mejores coeficientes fueron dados en las medidas Cdd-Me y Cdi-Me con un 0.82 y 0.86 respectivamente con redes neuronales (Tabla 4-20); a pesar de esto en el ángulo Cdi-Me-Cdd no se logró superar el coeficiente de 0.82 determinado a partir de todas las medidas craneomaxilares, es decir las 8126 variables (Tabla 4-19), al parecer existen datos en las radiografías posteroanteriores que responden mejor con una mayor cantidad de datos de entrada, sin embargo resulta complicado comprobarse con las redes neuronales.

Con estos resultados se refuta que las máquinas de vectores de soporte responden mejor que las redes neuronales si los datos son pequeños, y se confirma que al aplicar un método de análisis detallado donde haya una integración de métodos de regresión, existe una ventaja de las redes neuronales con respecto a las máquinas de vectores de soporte, como ocurrió en el estudio de Boyacioglu et al. en la predicción de fallas financieras (118), o en el caso de Kara et al. para la predicción de movimientos de cotización de precios donde se encontraron ventajas de las redes neuronales frente a las máquinas de vectores de soporte (119).

Por otro lado, comparando las máquinas de vectores de soporte y las redes neuronales en términos de RMSE, tanto para las radiografías de perfil (Tabla 4-17) como para las radiografías posteroanteriores (Tabla 4-21), la mayoría fueron más bajas en las redes

neuronales, sin embargo, en algunas variables fueron más bajas para las máquinas de vectores de soporte en el kernel de función de base radial, lo cual coincide sólo en algunos coeficientes de la regresión, lo que indica que además de presentar valores no estándares (entre 0 y 1) para una evaluación en términos de error cuadrático medio debido al comportamiento de las unidades a-dimensionales, son más confiables y entendibles los valores dados por la regresión.

En el estudio realizado por Guevara et.al, se predijeron variables mandibulares con redes neuronales y se evaluaron a través del error cuadrático medio donde los valores eran cercanos al 0 y no superaban al 1, el ángulo SNB fue relevante en pacientes Clase I a pesar de ser una medida mixta y la medida Cod-Coi también fue importante (2), esta corresponde a la medida Cdd- Cdi que fue relevante en el presente estudio, aunque evaluado por medio de una ridge regression.

Siguiendo con las medidas mandibulares y su predicción, en el estudio de Sato et al., la longitud mandibular (Cd-Gn) fue relevante para probar dos métodos de predicción del potencial de crecimiento (171), en el caso de la tesis fue uno de los puntos que mejor respondió al modelo.

Infante y López clasificaron estructuras óseas en radiografías de perfil como en posteroanteriores dando una buena relación de las medidas craneomaxilares con la medida Go-Gn (1). Halazonetis al usar morfometría geométrica y determinar por un análisis de componentes principales observó que el ángulo goníaco (Cd-Go-Gn) hacía parte de los tres principales componentes que mejoraban el diagnóstico ortodóntico (34).

Teniendo en cuenta lo anterior se puede decir que se confirmó la relevancia de muchos puntos establecidos y se observaron las combinaciones de otros puntos para formar medidas que no se encuentran en la literatura, asimismo se prueban las ventajas de los sistemas automatizados semi y no paramétricos que permiten tener una visión alternativa en el análisis de datos, rápida y efectiva.

## 6. Conclusiones y recomendaciones

### 6.1 Conclusiones

- La clasificación de maloclusiones esqueléticas a partir de medidas craneomaxilares en radiografías de perfil resultó tener una mejor precisión comparada con los otros métodos de clasificación.
- En la clasificación de radiografías de perfil se lograron determinar nuevas variables que no son comúnmente utilizadas, indicando un aporte importante para fines de clasificación de maloclusiones esqueléticas.
- Al seleccionar variables craneomaxilares y predecir variables mandibulares, se obtuvieron mejores resultados con las redes neuronales artificiales, obteniendo coeficientes de correlación mayores a 0.8.
- En las SVM de los tres kernel aplicados el que mejor respondió fue el de función de base radial, aunque los datos no fueron muy relevantes comparados con los obtenidos con las ANN.
- En radiografías posteroanteriores las medidas de Cdd-God, Cdd-Me, Cdi-Me, Cdi-Cdd y Goi-God respondieron mejor con las redes neuronales, mientras que los ángulos Goi-Me-God y Cdi-Me-Cdd respondieron mejor con las máquinas de vectores de soporte.

## 6.2 Recomendaciones

Es de vital importancia darle continuidad a esta tesis con fines de reconstrucción mandibular en aspectos forenses y realizar la representación gráfica de las variables predichas por medio de softwares gráficos bi y/o tridimensionales, es decir, es necesario encontrar la morfología mandibular a través de variables craneomaxilares en cráneos de restos esqueléticos; asimismo sería interesante aplicar la metodología para predicción de tratamientos, predicciones de crecimiento o predicciones de otras estructuras craneofaciales.

Se debe considerar el uso de otros optimizadores para confirmar los problemas del método GRID si es por el comportamiento de los datos o una falla en el software Rapidminer.

Finalmente se debe aumentar la muestra para alimentar la base de datos del Proyecto de Biometría de la Maestría en Odontología de la Universidad Nacional de Colombia y de esa manera realizar más estudios en el futuro sin necesidad de balancear las clases y también para analizar el dimorfismo sexual.

# A. Acuerdo de Confidencialidad



**Facultad de Odontología  
Maestría en Odontología**

## ACUERDO DE CONFIDENCIALIDAD

Yo, Tania Camila Niño Sandoval, mayor de edad y vecina de Bogotá, identificada con cédula de ciudadanía No.1018407476 expedida en Bogotá, en mi condición de estudiante de Maestría en Odontología, he aceptado formalmente trabajar en el proyecto “Uso de Redes Neuronales en predicción de Morfología Mandibular en clase I, II y III esquelética” desarrollando y/o apoyando el tema de “predicción morfológica craneofacial”, declaro que conozco que este tema de trabajo se circunscribe dentro del proyecto de investigación “Crecimiento y desarrollo craneofacial” formulado como parte del programa general de investigación de la Maestría en Odontología dentro del “Grupo de Investigación en Crecimiento y Desarrollo Craneofacial” en la Universidad Nacional de Colombia. Por tal razón, conciente de que en el desarrollo de mi trabajo podré usar información privilegiada previamente lograda, propiedad de la Universidad y con características y usos potenciales promisorios, y que igualmente, es posible que en mi trabajo se alcancen resultados e informaciones de interés para el futuro del proyecto de investigación, me comprometo a manejar de manera confidencial los resultados y demás información relativa a mi trabajo de grado, atendiendo especialmente lo consignado en las siguientes cláusulas:

1. Aplicar el manejo confidencial a toda la información que se me suministre con esas características como insumo para el desarrollo del trabajo y extender ese tratamiento a los resultados alcanzados, reportándolos solamente al director del trabajo.
2. No emplear la información relacionada con mi trabajo, o cualquiera otra referida al proyecto de investigación, en beneficio propio o de terceros mientras conserve sus características de confidencialidad o mientras sea manejada como un secreto empresarial.


3. Informar clara y lealmente si en cualquier momento en el desarrollo del trabajo surgen intereses de mi parte que riñan con el interés de la Universidad. Se entiende por tal cualquiera intención más allá del ámbito académico que entre en conflicto con los intereses económicos o sociales que pudieren derivarse de la aplicación de los resultados de investigación. El acatamiento de este punto no implica necesariamente rompimiento del acuerdo si no reordenamiento de la relación.
4. Aceptar que cualquier publicación relacionada con el trabajo de investigación requiere autorización que deberé tramitar ante el director del trabajo, presentando el texto a publicar con un mes de antelación a la fecha en que se desea enviar a edición. Las anotaciones o correcciones del director y/o del comité revisor deberán ser atendidas sin objeciones y se relacionarán exclusivamente con información confidencial o susceptible de protección. Esta previsión deberá aplicarse igualmente al texto que constituirá el trabajo o tesis de grado.
5. Informar inmediatamente al director sobre cualquiera hallazgo o innovación alcanzada en el desarrollo de mi trabajo, y a colaborar con mi mayor diligencia en la documentación y declaración de lo hallado y a mantener sobre todo ello los compromisos de confidencialidad requeridos y necesarios.
6. Fijar como vigencia del presente acuerdo el tiempo de ejecución del trabajo y cinco años más después de concluido. No obstante, si la Universidad requiriese ampliar ese plazo sobre alguna de la información que llegue a conocer, aceptaré una ampliación por el mismo término con tan sólo se me notifique por correo electrónico.

Los compromisos y derechos aquí previstos se encuentran regulados por la legislación, los reglamentos y la doctrina vigente en Colombia, como es posible confrontar en: la Ley 23 de 1982, Decisión 351 CAN, Circular 06 de 2002 DNDA, artículo 308, Ley 599 de 2000, Ley 256 de 1996, Decisión 486 de la CAN, Tit. XVI, Acuerdo 035 de 2003 C.A.

En constancia y refrendación de lo declarado suscribo libremente el presente acuerdo, a los 8 días del mes de Noviembre de 2010, en la ciudad de Bogotá.

Nombre: Tania Camila Niño Sandoval  
Cédula: 1018407476 de Bogotá

## B. Consentimiento Informado

	<p><b>UNIVERSIDAD NACIONAL DE COLOMBIA</b> <b>FACULTAD DE ODONTOLOGÍA</b> <b>MAESTRÍA EN ODONTOLOGÍA</b></p> <p><b>CONSENTIMIENTO INFORMADO</b></p>
<p>Yo, _____, identificado (a) como aparece al pie de mi firma, en pleno uso de mis facultades mentales, libre y conscientemente declaro que:</p>	
<p>Autorizo a las estudiantes de Maestría en Odontología, Tania Camila Niño Sandoval y Nancy Esperanza Castro Guevara de la Universidad Nacional de Colombia, para que analice los registros radiográficos y fotográficos que requiero y han sido solicitados por el profesional tratante al cual acudí de forma voluntaria.</p>	
<p>Se me ha informado que dichos registros que consisten en fotografías y radiografías frontales y de perfil se realizarán en una sola sesión, y que las radiografías son clasificadas como 'riesgo mayor al mínimo' puesto que me expongo a una cantidad controlada de radiación. Lo anterior, se hará con el fin de desarrollar las investigaciones pertenecientes al proyecto de biometría craneofacial de la Maestría en odontología, que han sido explicadas previamente en una cartilla informativa.</p>	
<p>En estos estudios se me garantiza la confidencialidad y privacidad de los datos que proporcione. En cuanto a beneficios para mí, sé que habrá precisión diagnóstica que permitirá la planificación de un tratamiento más adecuado.</p>	
<p>La información obtenida será únicamente utilizada para fines de estudios científicos y hará parte de la base de datos de la Universidad Nacional de Colombia.</p>	
<p>Fecha: ____/____/____.</p>	
<p>Firma: _____.</p>	
<p>Documento de Identidad N°: _____ de _____.</p>	





# C. Cartilla Informativa

## Lado 1

✓ Uso de técnicas de aprendizaje automatizado para predicción de morfología mandibular en Clase I, II y III esquelética



Las redes neuronales artificiales y las máquinas de vectores de soporte son algoritmos de aprendizaje automatizado que tienen la capacidad de procesar varios datos, relacionarlos y predecir la forma, tamaño y posición de la mandíbula.



**Objetivo:** Predecir la morfología mandibular en maloclusión Clase I, Clase II y Clase III esqueléticas utilizando máquinas de vectores de soporte y redes neuronales.

**Estudiante Encargada:**  
**Tania C Niño Sandoval**  
**tcninos@unal.edu.co**


Para participar en el estudio se requiere:

Autorización por parte del paciente para utilizar esos datos para el estudio, por medio del consentimiento informado

La información obtenida se mantendrá en confidencialidad y hará parte de la bases de datos de la UNIVERSIDAD NACIONAL DE COLOMBIA, se utilizará únicamente para fines de estudios científicos.



UNIVERSIDAD NACIONAL DE COLOMBIA  
FACULTAD DE ODONTOLOGÍA  
MAESTRÍA EN ODONTOLOGÍA



CARTILLA INFORMATIVA PARA LA PARTICIPACIÓN DENTRO DE ESTUDIOS DE INVESTIGACIÓN DE BIOMETRÍA CRANEOFACIAL

Lado 2

Al solicitar atención quirúrgica u ortodóntica, es necesario un diagnóstico para planear el mejor Tratamiento



Para el diagnóstico se Requiere:



Radiografías



Lateral

En las tomas radiográficas se recibirá una cantidad de radiación pero esta es controlada



Fotografías




Frontal

De Perfil

Si usted permite el análisis de esos registros en el estudio:

Se harán medidas sobre estos.



Se determinará un diagnóstico más preciso.



Se evaluarán según el método de cada tesis:

Modelo de identificación de patrones para predicción morfométrica del tercio medio facial en Clase I, II y III esquelética.



La Morfometría Geométrica fusiona la geometría y la biología: estudia la forma en un espacio bio tridimensional permitiendo investigar en profundidad los cambios morfológicos de las estructuras craneofaciales.



Objetivo: Crear un modelo de identificación de patrones craneofaciales, para predicción del tercio medio utilizando Morfometría geométrica en maloclusiones esqueléticas de clase I, II y III.

Estudiante Encargada:

Nancy E Castro G

necastrog@unal.edu.co

# D. Carta de Aprobación de cambio del nombre de la tesis



UNIVERSIDAD NACIONAL DE COLOMBIA  
SEDE BOGOTÁ  
FACULTAD DE ODONTOLOGÍA  
SECRETARÍA DE FACULTAD

SA-CF 672  
Bogotá, 23 de junio de 2011

Doctora  
**MYRIAM PASTORA ARIAS AGUDELO**  
Directora Área Curricular  
Facultad de Odontología  
Universidad Nacional de Colombia  
Sede Bogotá

Respetada doctora Myriam,

De manera atenta informo a usted, que el Consejo de Facultad en su sesión del día 22 de junio de 2010 Acta 015, teniendo en cuenta la recomendación del Comité Asesor de Programas Curriculares de Posgrado en su sesión del día 13 de junio de 2011 Acta 10, aprobó el cambio del título del anteproyecto de tesis de la estudiante del programa de Maestría en Odontología, Tania Camila Niño Sandoval DNI 1018407476 así:

Título de trabajo	USO DE REDES NEURONALES EN PREDICCIÓN DE MORFOLOGÍA MANDIBULAR EN CLASES I, II, III ESQUELÉTICA		
Nuevo título	USO DE TÉCNICAS DE APRENDIZAJE AUTOMATIZADO PARA PREDICCIÓN DE MORFOLOGÍA MANDIBULAR EN CLASE I, II y III ESQUELÉTICA.		
Director	Sonia Victoria Guevara Pérez	Codirector	Fabio González

Por ultimo y de acuerdo a lo reglamentado en el artículo 6° de la Resolución No 003 de 2009 de la Secretaría General y la Resolución No 44 de 2010 del Consejo de Facultad, amablemente le solicito realizar la modificación en el modulo de administración de graduandos del aplicativo UNIVERSITAS XXI.

Cordialmente

**JIMMY MATIZ CUERVO**  
Secretario de Facultad

C.C Doctora Clementina Infante Contreras, Coordinadora Maestría en Odontología.  
C.C Tania Camila Niño Sandoval, estudiante Maestría en Odontología.

Preparado por: Andrea Monroy

ciencia, tecnología e innovación para el país  
Carrera 30 No. 45-03, FACULTAD DE ODONTOLOGÍA, Edificio 210, Oficina 207  
Conmutador: (57-1) 316 5000 Ext. 16003 Fax: ext. 16004  
Correo electrónico: secreacad\_fobog@unal.edu.co  
Bogotá, Colombia, Sur América



# E. Carta de Aprobación de la Tesis por el Comité de Ética de la Facultad



UNIVERSIDAD NACIONAL DE COLOMBIA  
SEDE BOGOTÁ  
FACULTAD DE ODONTOLOGÍA  
CENTRO DE INVESTIGACIÓN Y EXTENSIÓN

CIE-0009-10

Bogotá D.C., jueves, 27 de enero de 2011

Señora  
TANIA CAMILA NIÑO SANDOVAL  
Estudiante  
Maestría en Odontología  
Universidad Nacional de Colombia  
Sede Bogotá

Respetada señora:

Con toda atención me permito informarle que el Comité de Ética de la Facultad de Odontología, en su sesión del lunes 17 de enero de 2011, Acta 01, después de haberse realizado la revisión de las modificaciones sugeridas, con anterioridad, aprobó el proyecto titulado "Uso de redes neuronales en predicción de morfología mandibular en clase I, II y III esquelética", dirigido por la Dra. Sonia Victoria Guevara.

Cordialmente,

MARIA CLAUDIA CASTRO ZÁRATE  
Directora

200 COLOMBIA  
ANIVERSARIO 1810-2010

Carrera 30 No. 45-03, FACULTAD DE ODONTOLOGÍA, Edificio 210 piso 3º, Oficina 311  
Teléfono: 57 (1) 3165606 directo Conmutador: 57 (1) 3165000 ext. 16011 - 16012 - 16057  
Telefax: 57 (1) 3165000 Ext. 16057  
Correo electrónico: ceninvest\_fobog@unal.edu.co  
Bogotá Colombia, Sur América



# Bibliografía

1. Infante C, López L. Uso de Técnicas multivariadas para la clasificación de estructuras óseas craneanas: una aplicación en medicina forense. Bogotá: Universidad Nacional de Colombia; 2003.
2. Guevara S, Infante C, González F. Uso de Redes Neuronales En La Predicción De La Morfología Mandibular: Aplicación Forense. Bogotá: Universidad Nacional De Colombia; 2006.
3. Lu C-H, Ko EW-C, Liu L. Improving the video imaging prediction of postsurgical facial profiles with an artificial neural network. J Dent Sci [Internet]. 2009; 4(3):[118-29 pp.]. Available from: <http://www.sciencedirect.com/science/article/B9863-4XDFPFS-3/2/4b43ec2cb48a14586d99298d813b4bb1>.
4. Pathak KA, Agarwal R, Deshpande MS. Marginal mandibulectomy for lateral sulcus tumours. Eur J Surg Oncol [Internet]. 2004; 30(7):[804-6 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6WF4-4CSG3MK-2/2/0a01273ff39796c5376973f4668b9cf9>.
5. Pohlenz P, Blessmann M, Blake F, Gbara A, Schmelzle R, Heiland M. Major Mandibular Surgical Procedures as an Indication for Intraoperative Imaging. J Oral Maxillofac Surg [Internet]. 2008; 66(2):[324-9 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6WKF-4RKJMT-W/2/d59b44ccd948d28e031c723d7db6ebde>.
6. Schwab RA, Genners K, Robinson WA. Clinical predictors of mandibular fractures. Am J Emerg Med [Internet]. 1998; 16(3):[304-5 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6W9K-4D0SP9B-G/2/5bb3117263b31cd34ba1e5bea50b9650>.
7. Velásquez M, Ortiz G. Prevalencia de fracturas mandibulares en el Hospital General de Medellín. Un estudio prospectivo. 2006 – 2007 CES Odontología [Internet]. 2008; 21(2):[25-32 pp.]. Available from: [http://www.ces.edu.co/PDF\\_Revistas/Pag25\\_32V21N2ODO.pdf](http://www.ces.edu.co/PDF_Revistas/Pag25_32V21N2ODO.pdf).
8. Chvatal BA, Behrents RG, Ceen RF, Buschang PH. Development and testing of multilevel models for longitudinal craniofacial growth prediction. Am J Orthod Dentofacial Orthop [Internet]. 2005; 128(1):[45-56 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6W9R-4GN9WHY-X/2/e3a11e4069ee2883179ba3731525e088>.
9. Tahmina K, Tanaka E, Tanne K. Craniofacial morphology in orthodontically treated patients of Class III malocclusion with stable and unstable treatment outcomes. Am J Orthod Dentofacial Orthoped [Internet]. 2000; 117(6):[681-90 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6W9R-4HPDJJ9-7/2/ba0d5407f0fe116c1c1efaf03b056397>.

10. Rudolph DJ, White SE, Sinclair PM. Multivariate prediction of skeletal Class II growth. *Am J Orthod Dentofacial Orthoped* [Internet]. 1998; 114(3):[283-91 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6W9R-4HPDFSN-6/2/b6fe9b7760d5e56ad5a55ac5d8012332>.
11. Zentner A, Doll GM, Peylo SM. Morphological parameters as predictors of successful correction of Class III malocclusion. *Eur J Orthod* [Internet]. 2001 23 (4):[383-92. pp.]. Available from: <http://ejo.oxfordjournals.org/content/23/4/383.short>.
12. Sinha P. A symmetry perceiving adaptive neural network and facial image recognition. *Forensic Sci Int* [Internet]. 1998; 98(1-2):[67-89 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T6W-3VCK488-8/2/b95dea5bf9504faffbb10ab1bbd912cc>.
13. Corsini M-M, Schmitt A, Bruzek J. Aging process variability on the human skeleton: artificial network as an appropriate tool for age at death assessment. *Forensic Sci Int* [Internet]. 2005; 148(2-3):[163-7 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T6W-4CVV8RB-4/2/79e810ef6268d9b6465ed6bef5de3f9b>.
14. Coughlan KM. *Simulating Craniofacial Growth*. Ottawa: Université d'Ottawa; 1992.
15. Bilge Y, Kedici PS, Alakoç YD, Ülküer KÜ, Ilkyaz YY. The identification of a dismembered human body: a multidisciplinary approach. *Forensic Sci Int* [Internet]. 2003; 137(2-3):[141-6 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T6W-49KH1KX-1/2/d8c77b5da64d86a018eaa9a95ff5183f>.
16. Benazzi S, Fantini M, De Crescenzo F, Mallegni G, Mallegni F, Persiani F, et al. The face of the poet Dante Alighieri reconstructed by virtual modelling and forensic anthropology techniques. *J Archaeol Sci* [Internet]. 2009; 36(2):[278-83 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6WH8-4TFW9FT-2/2/fbed02addf1afc1165f8e76146dd0d9c>.
17. Aulsebrook WA, Iscan MY, Slabbert JH, Becker P. Superimposition and reconstruction in forensic facial identification: a survey. *Forensic Sci Int* [Internet]. 1995; 75(2-3):[101-20 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T6W-409W433-3/2/b51e069907a63bca190b4726c30d86a0>.
18. De Greef S, Claes P, Vandermeulen D, Mollemans W, Suetens P, Willems G. Large-scale in-vivo Caucasian facial soft tissue thickness database for craniofacial reconstruction. *Forensic Sci Int* [Internet]. 2006; 159(Supplement 1):[S126-S46 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T6W-4JJ87WY-5/2/32767c1d753f7915d54ba449524ea7bd>.
19. Benazzi S, Bertelli P, Lippi B, Bedini E, Caudana R, Gruppioni G, et al. Virtual anthropology and forensic arts: the facial reconstruction of Ferrante Gonzaga. *J Archaeol Sci* [Internet]. 2010; 37(7):[1572-8 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6WH8-4Y70CBW-4/2/28496be977931f6af3c071ebbc69d502>.
20. Ávila F, Bayona A, Bernal M, Calvo M, Estrada M, Flórez M, et al. Estudio epidemiológico de salud y maloclusión dental en niños de Bogotá, Colombia. Bogotá: Universidad Nacional de Colombia; 2002.
21. Chen F, Terada K, Hanada K. A Special Method of Predicting Mandibular Growth Potential for Class III Malocclusion Angle Orthod [Internet]. 2005; 75:[191–5 pp.].
22. Bastir M, Rosas A. Correlated variation between the lateral basicranium and the face: A geometric morphometric study in different human groups. *Arch Oral Biol* [Internet]. 2006; 51(9):[814-24 pp.]. Available from:



<http://www.sciencedirect.com/science/article/B6T4J-4JX378K-1/2/3e78d381b785ce8a96720e11da1a2922>.

23. Baccetti T, Stahl F, McNamara Jr JA. Dentofacial growth changes in subjects with untreated Class II malocclusion from late puberty through young adulthood. *Am J Orthod Dentofacial Orthoped* [Internet]. 2009; 135(2):[148-54 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6W9R-4VJCVRW-F/2/6761fd0547c45d86688d97c27e3efed2>.
24. Andresen PR, Bookstein FL, Conradsen K, Ersboll BK, Marsh JL, Kreiborg S. Surface-bounded growth modeling applied to human mandibles. *IEEE Trans Med Imaging* [Internet]. 2000 Nov; 19(11):[1053-63 pp.]. Available from: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.28.6451&rep=rep1&type=pdf>.
25. Witten IH, Frank E, Hall MA. *Data Mining: Practical Machine Learning Tools and Techniques Third Edition* ed. Burlington: Morgan Kaufmann Publishers; 2011. 630 p.
26. Kowalski CJ. A commentary on the use of multivariate statistical methods in anthropometric research. *Am J Phys Anthropol*. 1972 Jan;36(1):119-32. PubMed PMID: 5057727. Epub 1972/01/01. eng.
27. Moyers RE, Bookstein FL, Guire KE. The concept of pattern in craniofacial growth. *Am J Orthod*. 1979;76(2):136-48. eng.
28. Karlsen AT, Krogstad O. Morphology and growth in convex profile facial patterns: a longitudinal study. *Angle Orthod*. 1999 Aug;69(4):334-44. PubMed PMID: 10456601. Epub 1999/08/24. eng.
29. El-Batran M, Soliman N, El-Wakil K. The relationship between cranial base and maxillo-facial morphology in Egyptian children. *J Comp Hum Biol* [Internet]. 2008; 59(4):[287-300 pp.]. Available from: <http://www.sciencedirect.com/science/article/B7GW4-4T719Y5-1/2/78f7c210746b5cda1bd2c936bb767ed4>.
30. Endo T, Abe R, Kuroki H, Kojima K, Oka K, Shimooka S. Cephalometric evaluation of maxillary sinus sizes in different malocclusion classes. *Odontology* [Internet]. 2010 Feb 01; 98(1):[65-72 pp.]. Available from: <http://www.springerlink.com/content/9060lv857x646671/fulltext.pdf>.
31. Stahl F, Baccetti T, Franchi L, McNamara Jr JA. Longitudinal growth changes in untreated subjects with Class II Division 1 malocclusion. *Am J Orthod Dentofacial Orthoped* [Internet]. 2008; 134(1):[125-37 pp.]. Available from: <http://www.sciencedirect.com/science/article/pii/S0889540608001157>.
32. Richardson A, Krayachich A. The Prediction of Facial Growth. *Angle Orthod*. 1980;50(2):135 – 8.
33. Sgouros S, Natarajan K, Hockley AD, Goldin JH, Wake M. Skull base growth in childhood. *Pediatr Neurosurg* [Internet]. 1999; 31(5):[259-68 pp.]. Available from: <http://content.karger.com/ProdukteDB/produkte.asp?Aktion=ShowPDF&ArtikelNr=28873&Ausgabe=226502&ProduktNr=224273&filename=28873.pdf>.
34. Halazonetis DJ. Morphometrics for cephalometric diagnosis. *Am J Orthod Dentofacial Orthop* [Internet]. 2004; 125(5):[571-81 pp.]. Available from: <http://www.sciencedirect.com/science/article/pii/S0889540604000319>.
35. Sayin M, Türkkahraman H. Cephalometric evaluation of nongrowing females with skeletal and dental Class II, division 1 malocclusion. *Angle Orthod* [Internet]. 2005; 75(4):[656-60 pp.]. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/16097237>.
36. Zentner A, Doll GM, Peylo SM. Morphological parameters as predictors of successful correction of Class III malocclusion. *Eur J Orthod* [Internet]. 2001 August 1, 2001; 23(4):[383-92 pp.]. Available from: <http://ejo.oxfordjournals.org/content/23/4/383.abstract>.

- 
37. Sardi MI Fau - Ramirez Rozzi FV, Ramirez Rozzi FV. A cross-sectional study of human craniofacial growth. *Ann Hum Biol* [Internet]. (0301-4460 (Print)). Available from: <http://www.evolhum.cnrs.fr/ramrozzi/tap/sardinewgrowth.pdf>.
38. van Diepenbeek AF, Buschang PH, Pahl-Andersen B. Age-dependant cephalometric standards as determined by multilevel modeling. *Am J Orthod Dentofacial Orthop* [Internet]. 2009; 135(1):[79-87 pp.]. Available from: <http://www.sciencedirect.com/science/article/pii/S0889540608007208>.
39. Bookstein FL. The geometry of craniofacial growth invariants. *Am J Orthod*. 1983 Mar;83(3):221-34. PubMed PMID: 6572474. Epub 1983/03/01. eng.
40. Bastir M, Rosas A, O'Higgins P. Craniofacial levels and the morphological maturation of the human skull. *J Anat* [Internet]. 2006; 209(5):[637-54 pp.]. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/17062021>.
41. Seo S, Chung MK, Whyms BJ, Vorperian HK. Mandible shape modeling using the second eigenfunction of the Laplace-Beltrami operator. *SPIE Proc* [Internet]. 2011; 7962:[79620Z-Z-6 pp.]. Available from: <http://www.stat.wisc.edu/~mchung/papers/seo.2010.SPIE.pdf>.
42. (EQUITAS) ECIdTFyAP. Apreciaciones a las exhumaciones e investigaciones forenses realizadas por la Unidad Nacional de Justicia y Paz de la Fiscalía General de la Nación. 2006. Available from: <http://www.equitas.org.co/docs/27.pdf>.
43. Rose AD, Woods MG, Clement JG, Thomas CD. Lateral facial soft-tissue prediction model: analysis using Fourier shape descriptors and traditional cephalometric methods. *Am J Phys Anthropol* [Internet]. 2003 Jun; 121(2):[172-80 pp.]. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/12740960>.
44. Douglas TS. Image processing for craniofacial landmark identification and measurement: a review of photogrammetry and cephalometry. *Comput Med Imag Graph* [Internet]. 2004; 28(7):[401-9 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T5K-4CYPYMJ-1/2/f5cc489de50eeaf4c3842beab54c5b18>.
45. Ibáñez O, Ballerini L, Cordon O, Damas S, Santamaría J. An experimental study on the applicability of evolutionary algorithms to craniofacial superimposition in forensic identification. *Inform Sci* [Internet]. 2009; 179(23):[3998-4028 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V0C-4VF56YN-1/2/fa10188ce8a1d9843574e87f38aab48e>.
46. Claes P, Vandermeulen D, De Greef S, Willems G, Clement JG, Suetens P. Computerized craniofacial reconstruction: Conceptual framework and review. *Forensic Sci Int* [Internet]. 2010; 201(1-3):[138-45 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T6W-4YRGJC4-2/2/42b1f13917ef4161184c67167207742f>.
47. Starbuck JM, Ward RE. The affect of tissue depth variation on craniofacial reconstructions. *Forensic Sci Int* [Internet]. 2007; 172(2-3):[130-6 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T6W-4N7Y8B3-1/2/099dab3aba37a1a471cfc6efc80e2ddb>.
48. Turner W Fau - Tu P, Tu P Fau - Kelliher T, Kelliher T Fau - Brown R, Brown R. Computer-aided forensics: facial reconstruction; (0926-9630 (Print)). Available from: <http://www.ncbi.nlm.nih.gov/pubmed/16404119>.
49. Tilotta F, Richard F, Glaunès J, Berar M, Gey S, Verdeille S, et al. Construction and analysis of a head CT-scan database for craniofacial reconstruction. *Forensic Sci Int* [Internet]. 2009; 191(1-3):[112.e1-e12 pp.]. Available from:

<http://www.sciencedirect.com/science/article/B6T6W-4WYCT4N-1/2/b155ab4de39230b93c40c626f1b41409>.

50. Pohlenz P, Blessmann M, Oesterhelweg L, Habermann CR, Begemann PGC, Schmidgunst C, et al. 3D C-arm as an alternative modality to CT in postmortem imaging: Technical feasibility. *Forensic Sci Int* [Internet]. 2008; 175(2-3):[134-9 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T6W-4P7FHMW-1/2/4a4f235a8e9eee82a3d252a16693a134>.

51. Gunz P, Mitteroecker P, Neubauer S, Weber GW, Bookstein FL. Principles for the virtual reconstruction of hominin crania. *J Hum Evol* [Internet]. 2009; 57(1):[48-62 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6WJS-4WDFC6X-1/2/8fae2826ec536a9b8137143ab2b3ee6a>.

52. Claes P, Vandermeulen D, De Greef S, Willems G, Suetens P. Craniofacial reconstruction using a combined statistical model of face shape and soft tissue depths: Methodology and validation. *Forensic Sci Int* [Internet]. 2006; 159(Supplement 1):[S147-S58 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T6W-4JGJJ88-5/2/e7fc4814fd4896ca333267f1573916a3>.

53. Benazzi S, Stansfield E, Milani C, Gruppioni G. Geometric morphometric methods for three-dimensional virtual reconstruction of a fragmented cranium: the case of Angelo Poliziano. *Int J Legal Med* [Internet]. 2009 Jul; 123(4):[333-44 pp.]. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/19294402>.

54. O'Higgins P, Bastir M, Kupczik K. Shaping the human face. *Int Congr* [Internet]. 2006; 1296:[55-73 pp.]. Available from: <http://www.sciencedirect.com/science/article/pii/S0531513106003268>.

55. Bapi RS, McCabe SL. Artificial intelligence and neural networks: Steps toward principled integration: Edited by Vasant Honavar and Leonard Uhr, Academic Press, Boston, MA: 1994. (Book Review). *Neural Network* [Internet]. 1996; 9(3):[545-8 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T08-49HG0X5-5/2/2a258efe73a5b0c89935c733e456105f>.

56. Honavar V. Artificial Intelligence: An Overview. *Com S 572* [Internet]. 2006. Available from: <http://www.cs.iastate.edu/~cs572/handout1.pdf>.

57. Hamamoto I, Okada S, Hashimoto T, Wakabayashi H, Maeba T, Maeta H. Prediction of the early prognosis of the hepatectomized patient with hepatocellular carcinoma with a neural network. *Comput Biol Med* [Internet]. 1995; 25(1):[49-59 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T5N-3YF49D0-1N/2/e29a2ccffa6d7e58c01a6fa9e70ecc56>.

58. Wei JT, Zhang Z, Barnhill SD, Madyastha KR, Zhang H, Oesterling JE. Understanding artificial neural networks and exploring their potential applications for the practicing urologist. *Urology* [Internet]. 1998; 52(2):[161-72 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6VJW-3W847WP-1/2/a4326bb4e72d645c80f1d6b6961f0411>.

59. Lin C-C, Ou Y-K, Chen S-H, Liu Y-C, Lin J. Comparison of artificial neural network and logistic regression models for predicting mortality in elderly patients with hip fracture. *Injury* [Internet]. 2010; 41(8):[869-73 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T78-504C9HV-2/2/ea1eb4982713e553e94e1dbd861d9d03>.

60. Nilsson J, Ohlsson M, Thulin L, Höglund P, Nashef SAM, Brandt J. Risk factor identification and mortality prediction in cardiac surgery using artificial neural networks. *J Thorac Cardiovasc Surg* [Internet]. 2006; 132(1):[12- pp.]. Available from:

<http://www.sciencedirect.com/science/article/B6WMF-4K7T5SW-G/2/29e5d4604d9851d9bb1a0f54b1f14ec9>.

61. Baxt WG. Application of artificial neural networks to clinical medicine. *Lancet* [Internet]. 1995; 346(8983):[1135-8 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T1B-49N8438-18K/2/29ff487b384e99c95e3171c3b10caad2>.

62. Lisboa PJ, Taktak AFG. The use of artificial neural networks in decision support in cancer: A systematic review. *Neural Network* [Internet]. 2006; 19(4):[408-15 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T08-4J8D90J-1/2/d93007fb1a9a79c14c7c1c7476b62b05>.

63. Ikeda M, Ito S, Ishigaki T, Yamauchi K. Evaluation of a neural network classifier for pancreatic masses based on CT findings. *Comput Med Imag Graph* [Internet]. 1997/6//; 21(3):[175-83 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T5K-3RH6VBG-4/2/6cd03e0ff70fcd9dcc1c44c2ea625ee7>.

64. Lisboa PJG, Wong H, Harris P, Swindell R. A Bayesian neural network approach for modelling censored data with an application to prognosis after surgery for breast cancer. *Artif Intell Med* [Internet]. 2003; 28(1):[1-25 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T4K-48JK409-1/2/34e4c3e95fef444a2988afc5197e1f98>.

65. Ennett CM, Frize M, Charette E. Improvement and automation of artificial neural networks to estimate medical outcomes. *Med Eng Phys* [Internet]. 2004; 26(4):[321-8 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T9K-4BJWYNH-1/2/fcf8367b012c2f8f128a61c2624120a1>.

66. Egmont-Petersen M, de Ridder D, Handels H. Image processing with neural networks--a review. *Pattern Recogn* [Internet]. 2002; 35(10):[2279-301 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V14-463FTWW-7/2/409c589fa2ab672c7067f526784ef0a8>.

67. Gooroochurn M, Kerr D, Bouazza-Marouf K, Vloeberghs M. Extraction of Craniofacial Landmarks for Preoperative to Intraoperative Registration. *WASET* [Internet]. 2009; 57. Available from: <http://www.waset.org/journals/waset/v57/v57-1.pdf>.

68. Resino S, Seoane JA, Bellon JM, Dorado J, Martin-Sanchez F, Emilio A, et al. An artificial neural network improves the non-invasive diagnosis of significant fibrosis in HIV/HCV coinfecting patients. *J Infect* [Internet]. 2010. Available from: [http://www.bases.unal.edu.co:2053/science?\\_ob=MIimg&\\_imagekey=B6WJT-51F7PJR-2-F&\\_cdi=6887&\\_user=1998314&\\_pii=S0163445310003282&\\_origin=search&\\_coverDate=11/10/2010&\\_sk=999999999&\\_view=c&\\_wchp=dGLzVlz-zSkzk&\\_md5=da2ad09ebb2b2ae5bfb53dc7e4606da6&\\_ie=/sdarticle.pdf](http://www.bases.unal.edu.co:2053/science?_ob=MIimg&_imagekey=B6WJT-51F7PJR-2-F&_cdi=6887&_user=1998314&_pii=S0163445310003282&_origin=search&_coverDate=11/10/2010&_sk=999999999&_view=c&_wchp=dGLzVlz-zSkzk&_md5=da2ad09ebb2b2ae5bfb53dc7e4606da6&_ie=/sdarticle.pdf).

69. Claes P, Vandermeulen D, De Greef S, Willems G, Clement JG, Suetens P. Bayesian estimation of optimal craniofacial reconstructions. *Forensic Sci Int* [Internet]. 2010; 201(1-3):[146-52 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T6W-4YRGJC4-3/2/e5f1aca5dcf093fd83bf2bf3c59e23e0>.

70. Ferreyra Ramirez A. Redes Neuronales Difusas para modelado vía agrupamiento en línea: Aplicación a un condensador de aspiración. México D.F: Instituto Politécnico Nacional; 2005.

71. Jiang J, Trundle P, Ren J. Medical image analysis with artificial neural networks. *Comput Med Imag Graph* [Internet]. 2010; 34(8):[617-31 pp.]. Available from:

<http://www.sciencedirect.com/science/article/B6T5K-50SJMFG-1/2/34ecd287d5051478173b50d5bd38bcdd>.

72. Prescher A, Meyers A, Keyserlingk DGv. Neural net applied to anthropological material: A methodical study on the human nasal skeleton. *Ann Anat* [Internet]. 2005; 187(3):[261-9 pp.]. Available from: <http://www.sciencedirect.com/science/article/B7GWX-4FWSDKD-1/2/bf9ef79d4dcf00a1a46920cef52d9461>.

73. Wen U-P, Lan K-M, Shih H-S. A review of Hopfield neural networks for solving mathematical programming problems. *Eur J Oper Res* [Internet]. 2009; 198(3):[675-87 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6VCT-4TX33M3-1/2/d72424cb5d61bfab7f275593ec2a86ea>.

74. Fontenla-Romero O, Guijarro-Berdiñas B, Pérez-Sánchez B, Alonso-Betanzos A. A new convex objective function for the supervised learning of single-layer neural networks. *Pattern Recogn* [Internet]. 2010; 43(5):[1984-92 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V14-4XVK3TN-2/2/1d099bd6aabc4e923d982affec91e750>.

75. García P. Las Redes Neuronales Supervisadas. Unpublished document [Internet]. 2005. Available from: <http://www.telefonica.net/web2/pgestevez/RN%20Supervisadas%20Estevez.pdf>.

76. Giraldo MD, Hoyos JG. Control Por Redes Neuronales De Base Radial Y Planos Deslizantes. *Scientia et Technica* [Internet]. 2004; 10(26):[4 p.]. Available from: <http://www.utp.edu.co/php/revistas/ScientiaEtTechnica/docsFTP/10444943-46.pdf>.

77. Acherjee B, Mondal S, Tudu B, Misra D. Application of artificial neural network for predicting weld quality in laser transmission welding of thermoplastics. *Appl Soft Comput* [Internet]. In Press, Corrected Proof. Available from: <http://www.sciencedirect.com/science/article/B6W86-51BYS5V-3/2/36122a7ba7e5314785e533331867cd7f>.

78. Javad G, Narges T. Application of artificial neural networks to the prediction of tunnel boring machine penetration rate. *Min Sci Tech* [Internet]. 2010; 20(5):[727-33 pp.]. Available from: <http://www.sciencedirect.com/science/article/B9861-513KXPX-F/2/2234709a8936370d021c0a2dd359d452>.

79. Deh Kiani MK, Ghobadian B, Tavakoli T, Nikbakht AM, Najafi G. Application of artificial neural networks for the prediction of performance and exhaust emissions in SI engine using ethanol- gasoline blends. *Energy*. 2010;35(1):65-9.

80. Hammond P, Hutton TJ, Nelson-Moon ZL, Hunt NP, Madgwick AJ. Classifying Vertical Facial Deformity Using Supervised And Unsupervised Learning. *Methods Inf Med* [Internet]. 2001; 40(5):[365-72 pp.]. Available from: <http://discovery.ucl.ac.uk/9982/1/9982.pdf>.

81. Vakil-Baghmisheh M-T, Pavesic N. Premature clustering phenomenon and new training algorithms for LVQ. *Pattern Recogn* [Internet]. 2003; 36(8):[1901-12 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V14-47XWGYR-2/2/64ad9242be227dbace17eeb7e23b0e03>.

82. Bashar MK, Ohnishi N, Matsumoto T, Takeuchi Y, Kudo H, Agusa K. Image retrieval by pattern categorization using wavelet domain perceptual features with LVQ neural network. *Pattern Recogn Lett* [Internet]. 2005; 26(15):[2315-35 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V15-4GFV5BT-3/2/4771ace4ca3470c817444ed1b0393a58>.

83. Ren M, Wang B, Liang Q, Fu G. Classified real-time flood forecasting by coupling fuzzy clustering and neural network. *Int J sediment res* [Internet]. 2010; 25(2):[134-48

- pp.]. Available from: <http://www.sciencedirect.com/science/article/B8JJR-50GFW3R-4/2/08514e1d4d413be41d27393ba2faf2ec>.
84. Xue F, Ke K-l. Five-Category Evaluation of Commercial Bank's Loan by the Integration of Rough Sets and Neural Network. *Simulat Pract Theor* [Internet]. 2008; 28(1):[40-5 pp.]. Available from: <http://www.sciencedirect.com/science/article/B8JJ0-4VNGRVX-3/2/9fc14ae272f74ea1f78040e94b7e882e>.
85. Carcano EC, Bartolini P, Muselli M, Piroddi L. Jordan recurrent neural network versus IHACRES in modelling daily streamflows. *J Hydrol* [Internet]. 2008; 362(3-4):[291-307 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V6C-4TFW9H2-1/2/635ab09e647d2abf45f38437a084cfc9>.
86. Fourati F, Chtourou M. A greenhouse control with feed-forward and recurrent neural networks. *Simulat Pract Theor* [Internet]. 2007; 15(8):[1016-28 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6X3C-4NYJ0W2-1/2/6e8cf6adfacd75a8cd8fbde530761f12>.
87. Valous NA, Mendoza F, Sun D-W, Allen P. Supervised neural network classification of pre-sliced cooked pork ham images using quaternionic singular values. *Meat Sci* [Internet]. 2010; 84(3):[422-30 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T9G-4X97D3F-2/2/77cb34d6049062f68b14a9ccdd990961>.
88. Hayati M, Rezaei A, Seifi M. CNT-MOSFET modeling based on artificial neural network: Application to simulation of nanoscale circuits. *Solid State Electron* [Internet]. 2010; 54(1):[52-7 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6TY5-4XF7XWR-1/2/8bf3b9f7749c0e99b88c737912425240>.
89. Jafar R, Shahrour I, Juran I. Application of Artificial Neural Networks (ANN) to model the failure of urban water mains. *Math Comput Model* [Internet]. 2010; 51(9-10):[1170-80 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V0V-4Y3TX7N-2/2/3997f5f3eed0ead8410ae0caaf3882c4>.
90. Fadare DA. The application of artificial neural networks to mapping of wind speed profile for energy application in Nigeria. *Appl Energ* [Internet]. 2010; 87(3):[934-42 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V1T-4XBWWBG-2/2/10e32fcc2090edde619b84e2a91e7ad5>.
91. Gago J, Landín M, Gallego PP. Artificial neural networks modeling the in vitro rhizogenesis and acclimatization of *Vitis vinifera* L. *J Plant Physio* [Internet]. 2010; 167(15):[1226-31 pp.]. Available from: <http://www.sciencedirect.com/science/article/B7GJ7-5091Y5H-1/2/44d8ebb315e9af940deb7ab1c340ca80>.
92. Ramaiah GB, Chennaiah RY, Satyanarayanarao GK. Investigation and modeling on protective textiles using artificial neural networks for defense applications. *Mater Sci Eng B* [Internet]. 2010; 168(1-3):[100-5 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6TXF-4Y062H5-F/2/8f13cb56d3ba9bca771d94f9b3aa8ff1>.
93. Daqi G, Yan J. Classification methodologies of multilayer perceptrons with sigmoid activation functions. *Pattern Recogn* [Internet]. 2005; 38(10):[1469-82 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V14-4GFCSVG-1/2/9a110e1afb5722deefa8517ec3e86608>.
94. Sabourin C, Bruneau O. Robustness of the dynamic walk of a biped robot subjected to disturbing external forces by using CMAC neural networks. *Robot Autonom*

- Syst [Internet]. 2005; 51(2-3):[81-99 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V16-4FTS30W-1/2/6b97bb009f69e6884df1c429e20a0f60>.
95. Abdelhameed MM, Pinspon U, Cetinkunt S. Adaptive learning algorithm for Cerebellar model articulation controller. *Mechatronics* [Internet]. 2002; 12(6):[859-73 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V43-45VD556-5/2/c9c7f6090eef2400ebbaeedc12f1cccd>.
96. Hernández JA, Bassam A, Siqueiros J, Juárez-Romero D. Optimum operating conditions for a water purification process integrated to a heat transformer with energy recycling using neural network inverse. *Renew Energ* [Internet]. 2009; 34(4):[1084-91 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V4S-4TC8J1K-1/2/33a23971e07b24f63b1ac43b824b2819>.
97. Villasana M. Introducción a Las redes Neuronales (Neurales) Online document [Internet]. Available from: <http://prof.usb.ve/mvillasa/redes/Introduccion-vl.pdf>.
98. Ruilin Z, Lowndes IS. The application of a coupled artificial neural network and fault tree analysis model to predict coal and gas outbursts. *Int J Coal Geol* [Internet]. 2010; 84(2):[141-52 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V8C-5120JYB-2/2/2c6c7e17e1878689625602c70a9eb871>.
99. Dybowski R. Classification of incomplete feature vectors by radial basis function networks. *Pattern Recogn Lett* [Internet]. 1998; 19(14):[1257-64 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V15-3WPXRYT-1/2/b64be79c7d31313caab8937215838b16>.
100. Kagoda PA, Ndiritu J, Ntuli C, Mwaka B. Application of radial basis function neural networks to short-term streamflow forecasting. *Physics and Chemistry of the Earth, Parts A/B/C* [Internet]. 2010; 35(13-14):[571-81 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6X1W-50M1RWH-8/2/9509e9f298a6262f66c287fe62051ae8>.
101. Alba JL, Docío L, Docampo D, Márquez OW. Growing Gaussian mixtures network for classification applications. *Signal Process* [Internet]. 1999; 76(1):[43-60 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V18-3X28VD0-4/2/44dcc58fe9b89fd0edbbefe8d9685ac8>.
102. Misra J, Saha I. Artificial neural networks in hardware: A survey of two decades of progress. *Neurocomputing* [Internet]. 2010; 74(1-3):[239-55 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V10-50106SV-2/2/aa25f526b2b0afd79d9baaf5856ce9b8>.
103. Ghosh AK, Sinha P. An economised craniofacial identification system. *Forensic Sci Int* [Internet]. 2001; 117(1-2):[109-19 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T6W-42DX1RC-F/2/0e63b41fb33ac1f113ad892be615dc5c>.
104. Lucht R, Delorme S, Brix G. Neural network-based segmentation of dynamic MR mammographic images. *Magn Reson Imag* [Internet]. 2002; 20(2):[147-54 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T9D-45WG17Y-2/2/1914263bc6aeb649f42a379e5214a9a7>.
105. Mario MC, Abe JM, Ortega NR, Del Santo M, Jr. Paraconsistent artificial neural network as auxiliary in cephalometric diagnosis. *Artif Organs* [Internet]. 2010; 34(7):[E215-21 pp.]. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/20528855>.
106. Bartolini CM, Caresana F, Comodi G, Pelagalli L, Renzi M, Vagni S. Application of artificial neural networks to micro gas turbines. *Energ Convers Manag* [Internet]. 2011;

52(1):[781-8 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V2P-50X30S5-1/2/fb42976f606ef268bc7c45c4960182e1>.

107. Fast M, Palmé T. Application of artificial neural networks to the condition monitoring and diagnosis of a combined heat and power plant. *Energy* [Internet]. 2010; 35(2):[1114-20 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V2S-4WSG2NT-2/2/9eeb4b7eff7c0d07ba0e931d1d621501>.

108. Panagou EZ, Mohareb FR, Argyri AA, Bessant CM, Nychas G-JE. A comparison of artificial neural networks and partial least squares modelling for the rapid detection of the microbial spoilage of beef fillets based on Fourier transform infrared spectral fingerprints. *Food Microbiol* [Internet]. In Press, Corrected Proof. Available from: <http://www.sciencedirect.com/science/article/B6WFP-508JX45-1/2/73844f65b3f8ca73936ddac339c26593>.

109. Deeb O. Correlation ranking and stepwise regression procedures in principal components artificial neural networks modeling with application to predict toxic activity and human serum albumin binding affinity. *Chemometr Intell Lab Syst* [Internet]. 2010; 104(2):[181-94 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6TFP-50THX40-2/2/c778ee080f2964814b9dddc4d9b37973>.

110. Chartier S, Renaud P, Boukadoum M. A nonlinear dynamic artificial neural network model of memory. *New Ideas Psychol* [Internet]. 2008; 26(2):[252-77 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6VD4-4PK8MJ7-1/2/9c68ac243863610954a6d0e0af16a647>.

111. Naumovic R, Furuncic D, Jovanovic D, Stosovic M, Basta-Jovanovic G, Lezaic V. Application of artificial neural networks in estimating predictive factors and therapeutic efficacy in idiopathic membranous nephropathy. *Biomed Pharmacother* [Internet]. 2010; 64(9):[633-8 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6VKN-50K4PNN-1/2/992d8c7f810c9a62047e740b0eb3d7c1>.

112. Jolivot R, Vabres P, Marzani F. Reconstruction of hyperspectral cutaneous data from an artificial neural network-based multispectral imaging system. *Comput Med Imag Graph* [Internet]. 2010; In Press, Corrected Proof. Available from: <http://www.sciencedirect.com/science/article/B6T5K-50RFMSW-1/2/e81712cbc80a9b2935909c5c2e34a19b>.

113. Hsu J-H, Tseng C-S. Application of three-dimensional orthogonal neural network to craniomaxillary reconstruction. *Comput Med Imag Graph* [Internet]. 2001 2001/12//; 25(6):[477-82 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T5K-45NYNB4-4/2/7f110b7efb43b9ce1af2667dfcccea9c>.

114. Mountrakis G, Im J, Ogole C. Support vector machines in remote sensing: A review. *ISPRS J Photogramm* [Internet]. 2011; 66(3):[247-59 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6VF4-51M4Y40-2/2/edff3f13c6da724dc7706e19cff73bd8>.

115. Joachims T. Text categorization with support vector machines: learning with many relevant features. *Mach Learn ECML98* [Internet]. 1998; 1398(23):[137-42 pp.]. Available from: <http://www.springerlink.com/index/drhq581108850171.pdf>.

116. Chandaka S, Chatterjee A, Munshi S. Cross-correlation aided support vector machine classifier for classification of EEG signals. *Expert Syst Appl* [Internet]. 2009; 36(2, Part 1):[1329-36 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V03-4R8NB86-7/2/a3c3393a7673a85f683a13ef2f6ec0a6>.



117. Morik K, Brockhausen P, Joachims T. Combining statistical learning with a knowledge-based approach - a case study in intensive care monitoring. Proceedings of the 16th ICML [Internet]. 1999; 10:[268-77 pp.]. Available from: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.1.1.5781&rep=rep1&type=pdf>.
118. Boyacioglu MA, Kara Y, Baykan ÖK. Predicting bank financial failures using neural networks, support vector machines and multivariate statistical methods: A comparative analysis in the sample of savings deposit insurance fund (SDIF) transferred banks in Turkey. Expert Syst Appl [Internet]. 2009; 36(2, Part 2):[3355-66 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V03-4RSRDDN-6/2/d41fba710bb3c02410a671f6df8187cd>.
119. Kara Y, Acar Boyacioglu M, Baykan ÖK. Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. Expert Syst Appl [Internet]. 2011; 38(5):[5311-9 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V03-51C4RRS-3/2/919c552fc859a4fbd54eb3b33643b534>.
120. Majid A, Khan A, Javed G, Mirza AM. Lattice constant prediction of cubic and monoclinic perovskites using neural networks and support vector regression. Comput Mater Sci [Internet]. 2010; 50(2):[363-72 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6TWM-513XWWG-1/2/a2910309ccc69843974af18c0c7b2213>.
121. Yang C-C, Shieh M-D. A support vector regression based prediction model of affective responses for product form design. Comput Ind Eng [Internet]. 2010; 59(4):[682-9 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V27-50M6XFD-1/2/4f68e31f9c1a1be862603dac7913b672>.
122. Chen Z, Li J, Wei L. A multiple kernel support vector machine scheme for feature selection and rule extraction from gene expression data of cancer tissue. Artif Intell Med [Internet]. 2007; 41(2):[161-75 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T4K-4PMT5J9-2/2/513852786ba36216b7fa0d3dd70c1df1>.
123. Westreich D, Lessler J, Funk MJ. Propensity score estimation: neural networks, support vector machines, decision trees (CART), and meta-classifiers as alternatives to logistic regression. J Clin Epidemiol [Internet]. 2010; 63(8):[826-33 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T84-50BJCG7-6/2/9a306a97764096a17d353130f193d358>.
124. Boardman M, Trappenberg T, editors. A Heuristic for Free Parameter Optimization with Support Vector Machines. Neural Networks, 2006 IJCNN '06 International Joint Conference on; 2006 0-0 0.
125. Gómez A, Hernández G. Utilización de las máquinas con vectores de soporte para regresión: m<sup>2</sup> de construcción en Bogotá. Av Sist Inf [Internet]. 2009; 6(2):[21-8 pp.]. Available from: <http://redalyc.uaemex.mx/redalyc/pdf/1331/133113598004.pdf>.
126. Ikeda K, Aoishi T. An asymptotic statistical analysis of support vector machines with soft margins. Neural Networks [Internet]. 2005; 18(3):[251-9 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T08-4G1GF9G-1/2/79a43a33c5bcdb334dabf56e17a3489a>.
127. Restrepo D, Niño L, Patarroyo M. Método Computacional Para La Identificación de Proteínas Secretadas por vía No Clásica. Bogotá, Colombia.: Universidad Nacional De Colombia; 2010.
128. Weisstein EW. Convex Hull. . Available from: <http://mathworld.wolfram.com/ConvexHull.html>.

129. Ikeda K, Aoishi T. An asymptotic statistical analysis of support vector machines with soft margins. *Neural Network* [Internet]. 2005; 18(3):[251-9 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6T08-4G1GF9G-1/2/79a43a33c5bcd334dabf56e17a3489a>.
130. Lee K, Cho S, Asfour S. Web-based algorithm for cylindricity evaluation using support vector machine learning. *Comput Ind Eng* [Internet]. 2011; 60(2):[228-35 pp.]. Available from: <http://www.sciencedirect.com/science/article/B6V27-51GHWRX-2/2/957ffb13d811ca14210fdbe9a51ea3ec>.
131. Jaramillo J. Metodología de optimización de los parámetros de control de un algoritmo genético Manizales: Universidad Nacional de Colombia; 2007.
132. Banumathi A, Raju S, Abhaikumar V. Diagnosis of dental deformities in cephalometry images using support vector machine. *J Med Syst*. 2011 Feb;35(1):113-9. PubMed PMID: 20703579. Epub 2010/08/13. eng.
133. Kim BM, Kang BY, Kim HG, Baek SH. Prognosis prediction for Class III malocclusion treatment by feature wrapping method. *Angle Orthod* [Internet]. 2009; 79(4):[683-91 pp.]. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/19537866>.
134. Grummons DC, Kappeyne van de Coppello MA. A frontal asymmetry analysis. *J Clin Orthod*. 1987 Jul;21(7):448-65. PubMed PMID: 3476493. Epub 1987/07/01. eng.
135. Rubio G, Zapata A. Fundamentos de la odontología. Ortodoncia. Bogotá.: Pontificia Universidad Javeriana.; 2002.
136. Abdullah RT, Kuijpers MA, Berge SJ, Katsaros C. Steiner cephalometric analysis: predicted and actual treatment outcome compared. *Orthod Craniofac Res* [Internet]. 2006; 9(2):[77-83 pp.]. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/16764682>.
137. Barahona J, Benavides J. Principales Análisis Cefalométricos Utilizados Para el Diagnóstico Ortodóntico. 2006. Available from: <http://colegiodentistas.org/revista/index.php/revistaodontologica/article/download/24/50>.
138. Infante C. Fundamentos para la Evaluación del Crecimiento, Desarrollo y Función Craneofacial. Colombia: Cámara colombiana del Libro; 2008.
139. Steiner C. The use of cephalometrics as an aid to planning and assessing orthodontic treatment. *Am J Orthod Dentofacial Orthoped*. 1960;46:721 - 35.
140. Castro N, Infante C, Muñoz J. Modelo de identificación de patrones del tercio medio facial en Clase I, II y III esquelética: un análisis morfogeométrico: Universidad Nacional de Colombia; 2012.
141. Byers S. Introduction to Forensic Anthropology: A Textbook: Allyn Bacon; 2001.
142. Enlow D, Hans M. Crecimiento Facial. México, D.F: McGraw-Hill Interamericana Editores, S.A.; 1998.
143. Savage AW, Showfety KJ, Yancey J. Repeated measures analysis of geometrically constructed and directly determined cephalometric points. *Am J Orthod Dentofacial Orthop*. 1987;91(4):295-9. PubMed PMID: 3471071. eng.
144. Swennen G, Schutyser F, Hausamen J. Three-dimensional Cephalometry: A Color Atlas and Manual. Germany: Springer-Verlag Berlin Heidelberg; 2006.
145. Ubelaker D. Human Skeletal Remains: Excavation, Analysis, Interpretation. Third edition ed. Washington, D.C: Taraxacum; 1999.
146. Cakirer B, Dean D, Palomo JM, MG H. Orthognathic surgery outcome analysis: 3-dimensional landmark geometric morphometric. *Int J Adult Orthodon Orthognath Surg* [Internet]. 2002; 17((2)): [116-32 pp.].
147. Moorrees C, Lebet L. The Mesh Diagram And Cephalometrics. *Angle Orthod*. 1962;32(4):214-31.

148. Carrillo N, Infante C. Capacidad predictora del método de petrovic en pacientes con maloclusión clase III evaluado por métodos multivarados: Universidad Nacional de Colombia; 2006.
149. Suzuki A, Takahama Y. Parental data used to predict growth of craniofacial form. *American Journal of Orthodontics and Dentofacial Orthopedics*. 1991;99(2):107-21.
150. Thames TL, Sinclair PM, Alexander RG. The accuracy of computerized growth prediction in Class II high-angle cases. *American Journal of Orthodontics*. 1985;87(5):398-405.
151. Cangialosi TJ, Chung JM, Elliott DF, Meistrell ME. Reliability of computer-generated prediction tracing. *The Angle Orthodontist*. 1995 2012/10/17;65(4):277-84.
152. Ferrario VF, Sforza C, Dalloca LL, DeFranco DJ. Assessment of facial form modifications in orthodontics: Proposal of a modified computerized mesh diagram analysis. *American Journal of Orthodontics and Dentofacial Orthopedics*. 1996;109(3):263-70.
153. Kocadereli I, Telli AE. Evaluation of Ricketts' long-range growth prediction in Turkish children. *Am J Orthod Dentofacial Orthop*. 1999;115(5):515-20. PubMed PMID: 10229883. eng.
154. Turchetta BJ, Fishman LS, Subtelny JD. Facial growth prediction: A comparison of methodologies. *American Journal of Orthodontics and Dentofacial Orthopedics*. 2007;132(4):439-49.
155. Hixon EH. Cephalometrics: A Perspective. *Angle Orthod*. 1972 2012/09/21;42(3):200-11.
156. Pileski RCA, Woodside DG, James GA. Relationship of the Ulnar Sesamoid Bone and Maximum Mandibular Growth Velocity. *The Angle Orthodontist*. 1973 2012/10/17;43(2):162-70.
157. Harris JE, Kowalski CJ, Walker GF. Discrimination Between Normal and Class II Individuals Using Steiner's Analysis. *Angle Orthod*. 1972 2012/09/21;42(3):212-20.
158. Kowalski CJ, Nasjleti CE, Walker GF. Differential Diagnosis of Adult Male Black and White Populations. *Angle Orthod*. 1974 2012/09/21;44(4):346-50.
159. Harris JE, Kowalski CJ, Walker SJ. Dentofacial Differences between "Normal" Sibs of Class II and Class III Patients. *Angle Orthod*. 1975 2012/09/21;45(2):103-7.
160. Oktay H. A comparison of ANB, WITS, AF-BF, and APDI measurements. *American Journal of Orthodontics and Dentofacial Orthopedics*. 1991;99(2):122-8.
161. Fine MB, Lavelle CLB. Diagnosis of skeletal form on the lateral cephalogram with a finite element-based expert system. *American Journal of Orthodontics and Dentofacial Orthopedics*. 1992;101(4):318-29.
162. Inada E, Saitoh I, Hayasaki H, Iwase Y, Kubota N, Tokemoto Y, et al. Relationship of nasal and skeletal landmarks in lateral cephalograms of preschool children. *Forensic Sci Int*. 2009;191(1-3):111.e1-e4.
163. Adams GL, Gansky SA, Miller AJ, Harrell Jr WE, Hatcher DC. Comparison between traditional 2-dimensional cephalometry and a 3-dimensional approach on human dry skulls. *Am J Orthod Dentofacial Orthoped*. 2004;126(4):397-409.
164. Chen YT, Cheng KS, Liu JK. Improving cephalogram analysis through feature subimage extraction. *IEEE Eng Med Biol Mag [Internet]*. 1999 Jan-Feb; 18(1):[25-31 pp.]. Available from: [http://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=740961&tag=1](http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=740961&tag=1).
165. Innes A, Ciesielski V, Mamutil J, John S. Landmark Detection for Cephalometric Radiology Images using Pulse Coupled Neural Networks 2002; 2:[511-7 pp.]. Available from: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.92.8079&rep=rep1&type=pdf>.

166. Innes A, Ciesielski V, Mamutil J, John S. Finding Templates for Cephalometric Landmarks Using Pulse Coupled Neural Networks and Genetic Programming. CISST [Internet]. 2003:[456-62 pp.]. Available from: <http://goanna.cs.rmit.edu.au/~vc/papers/cisst03.pdf>.
167. El-Feghi I, Sid-Ahmed MA, Ahmadi M. Automatic localization of craniofacial landmarks for assisted cephalometry. Pattern Recogn [Internet]. 2004; 37(3):[609-21 pp.]. Available from: <http://www.sciencedirect.com/science/article/pii/S0031320303003200>.
168. El-Feghi I, Sid-Ahmed MA, Ahmadi M. Automatic localization of craniofacial landmarks using multi-layer perceptron as a function approximator. Pattern Recogn Lett [Internet]. 2006; 27(6):[544-50 pp.]. Available from: <http://www.sciencedirect.com/science/article/pii/S0167865505002722>.
169. Kafieh R, Mehri A, Sadri S. Automatic landmark detection in cephalometry using a modified Active Shape Model with sub image matching. Machine Vision ICMV 2007 [Internet]. 2007:[73-8 pp.]. Available from: [http://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=4469276](http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4469276).
170. Leonardi R, Giordano D, Maiorana F. An Evaluation of Cellular Neural Networks for the Automatic Identification of Cephalometric Landmarks on Digital Images. J Biomed Biotechnol [Internet]. 2009; 2009. Available from: <http://dx.doi.org/10.1155/2009/717102>.
171. Sato K, Mito T, Mitani H. An accurate method of predicting mandibular growth potential based on bone maturity. American Journal of Orthodontics and Dentofacial Orthopedics. 2001;120(3):286-93.