

Predicting the risk of osteoporosis in schoolchildren using data mining

Christian Incalla-Nina, Br¹, Renzo Portilla-Arias, Br¹, Doris Ccama-Yana, Br¹, Britsel Calluchi-Arocutipa, Br¹ and Jose Sulla-Torres, Dr¹

¹Universidad Nacional de San Agustín de Arequipa, Perú, christ.incalla@gmail.com, renzoaqp@gmail.com, dccamay@unsa.edu.pe, bcalluchi@unsa.edu.pe, jsulla@unsa.edu.pe

Abstract -- Low bone mineral density and loss of bone tissue can result in weak and fragile bones that are characteristic of osteoporosis disease. This common public health problem has no symptoms. Osteoporosis is a disease considered as the global epidemic of the 21st century. This disease is usually pronounced in children and adolescents as osteopenia. The following article aims to classify and detect bone mineral density in children and adolescents from a range of 6 to 11 years of age by pre-processing data with the KDD process and using association rules as a classification technique. Subsequently, the results are compared with the database of a real densitometer. The results show the statistics of children who have osteoporosis and osteopenia.

Keywords – Prediction, Osteoporosis, Data Mining, bone mineral density.

Digital Object Identifier (DOI):
<http://dx.doi.org/10.18687/LACCEI2019.1.1.408>
ISBN: 978-0-9993443-6-1 ISSN: 2414-6390

Predicción de riesgo de osteoporosis en escolares utilizando minería de datos

Christian Incalla-Nina, Br¹, Renzo Portilla-Arias, Br¹, Doris Ccama-Yana, Br¹, Britsel Calluchi-Arocutipa, Br¹ and Jose Sulla-Torres, Dr¹

¹Universidad Nacional de San Agustín de Arequipa, Perú, christ.incalla@gmail.com, renzoaqp@gmail.com, dccamay@unsa.edu.pe, bcalluchi@unsa.edu.pe, jsulla@unsa.edu.pe

Resumen— La baja densidad mineral ósea y la pérdida de tejido óseo pueden dar lugar a huesos débiles y frágiles. Estos patrones son características típicas de la osteoporosis. Este problema de salud pública común no tiene síntomas. La osteoporosis es una enfermedad considerada como la epidemia mundial del siglo 21. El objetivo del estudio fue evaluar y detectar la densidad mineral ósea en niños y adolescente de 6 a 11 años de edad. Se efectuó un pre-procesamiento de datos con la técnica KDD, utilizando reglas de asociación como técnica de clasificación. Posteriormente se realiza la comparación de resultados con la base de datos de un densitómetro real. Los resultados evidenciaron que niños y niñas poseen osteoporosis y osteopenia.

Palabras Clave— Predicción, Osteoporosis, Minería de Datos, Densidad mineral óseo.

Abstract— Low bone mineral density and loss of bone tissue can result in weak and fragile bones that are characteristic of osteoporosis disease. This common public health problem has no symptoms. Osteoporosis is a disease considered as the global epidemic of the 21st century. This disease is usually pronounced in children and adolescents as osteopenia. The following article aims to classify and detect bone mineral density in children and adolescents from a range of 6 to 11 years of age by pre-processing data with the KDD process and using association rules as a classification technique. Subsequently, the results are compared with the database of a real densitometer. The results show the statistics of children who have osteoporosis and osteopenia.

Keywords— Prediction, Osteoporosis, Data Mining, bone mineral density.

I. INTRODUCCIÓN

A través del tiempo se han desarrollado una gran cantidad de métodos para el análisis de datos, principalmente están basados en técnicas de estadística tradicional. Sin embargo, a medida que la información almacenada crece en grandes proporciones, los métodos estadísticos tradicionales han empezado a enfrentar problemas de eficiencia y escalabilidad cuando se trabajan con grandes bases de datos.

La mayor parte de la información es histórica y procede de fuentes diversas, por lo que es necesario contar con métodos alternativos para el análisis de datos a gran escala.

Con el desarrollo de la Inteligencia Artificial (IA) y las técnicas de Minería de Datos (MD) se pueden procesar

grandes volúmenes de información, cuyo objetivo es extraer patrones que residan en los datos almacenados. La minería de datos es una tecnología novedosa que integra diferentes técnicas de análisis de datos y extracción de modelos.

La posibilidad de extraer patrones, así como describir tendencias y regularidades, y predecir comportamientos y en general, aprovechar la utilidad de la información almacenada, independientemente de la homogeneidad, heterogeneidad y la cantidad de individuos es necesario modelar de manera más eficiente y precisa un conjunto de datos, para luego tomar decisiones al respecto.

El objetivo del estudio fue evaluar y comparar resultados entre un densitómetro y los resultados obtenidos por medio de técnicas no invasivas (variables antropométricas) para clasificar la densidad mineral ósea en niños y adolescente.

II. TRABAJOS RELACIONADOS

En el estudio efectuado por Tejaswini, Vaishnavi, y Sunitha, [1] trata de buscar una solución para que las personas de bajos recursos puedan prevenir la osteoporosis o hacerse un diagnóstico sin pagar costos elevados. Asimismo, utilizó un método de detección y predicción haciendo uso de Redes Neuronales Artificiales.

Otro estudio efectuado por Sung Kean Kim, Tae Keun Yoo, Ein Oh, y Deok Won Kim [2], en el que utilizaron el aprendizaje máquina para el desarrollo y la validación de modelos predictivos en mujeres con post-menopausia, también utilizaron la técnica de SVM para identificar el riesgo de osteoporosis con una precisión de 76.7%.

Por otro lado, con el objetivo de explorar la viabilidad de extraer factores de riesgo críticos para la osteoporosis, Li, H., Li, X., Jia, X., Ramanathan, M., & Zhang, A. [3], hacen uso de los registros electrónicos de Salud (EHRs por sus siglas en inglés), cuyo modelo desarrollado S-NBN permitió mejorar enormemente el rendimiento predictivo de la osteoporosis y las fracturas óseas.

En un estudio efectuado por Li et al [4] identificaron las relaciones entre una enfermedad ósea y sus posibles factores de riesgo, mediante el aprendizaje de un modelo gráfico profundo. Este estudio tuvo como objetivo predecir la osteoporosis y la pérdida de la masa ósea. Así mismo primero se investigó un enfoque para mostrar la importancia de las

Digital Object Identifier (DOI):

<http://dx.doi.org/10.18687/LACCEI2019.1.1.408>

ISBN: 978-0-9993443-6-1 ISSN: 2414-6390

17th LACCEI International Multi-Conference for Engineering, Education, and Technology: “Industry, Innovation, And Infrastructure for Sustainable Cities and Communities”, 24-26 July 2019, Jamaica.

características. Como resultado se obtuvo el éxito de la predicción de osteoporosis para esta población estudiada.

Otros estudios recientemente han estudiado la predicción y el riesgo de padecer osteoporosis [5], [6] en diversas poblaciones, con lo que queda en evidencia que el interés por estudiar la salud ósea en niños y adolescentes es esencial, sobre todo si se trata de buscar nuevas técnicas de predicción e identificar métodos no-invasivos e inclusive para verificar técnicas que permitan un rápido análisis e interpretación de los datos.

III. MATERIALES Y MÉTODOS

Para el desarrollo del artículo es necesario tener en claro algunas definiciones como: Densidad Mineral Ósea, osteopenia y osteoporosis, las cuales nos permitirá obtener un mayor conocimiento al momento de la experimentación y obtención de mejores resultados.

La Densidad Mineral Ósea (DMO), es la medida de la cantidad de minerales (por lo general, calcio y fósforo) que contiene cierto volumen de hueso. Las mediciones de la densidad mineral ósea se usan para diagnosticar la osteopenia y osteoporosis, determinar si los tratamientos contra la osteoporosis son eficaces y calcular la probabilidad de que los huesos se rompan. La DMO baja se puede presentar en pacientes tratados por cáncer. También se llama densidad ósea, DMO, y masa ósea.

Tanto la osteopenia como la osteoporosis son enfermedades asociadas a la debilidad ósea de una persona a continuación definiremos claramente el concepto de cada termino.

Osteopenia es una disminución en la densidad mineral ósea, que puede ser una condición precursora de osteoporosis. Sin embargo, no todas las personas diagnosticadas de osteopenia desarrollarán osteoporosis. Más específicamente, la osteopenia se ha definido por la Organización Mundial de la Salud (OMS) como una T score menor a -1,0 y mayor a -2,5, determinada mediante la prueba de densitometría ósea. La escala T hace referencia a la media de densidad ósea de la población sana del mismo sexo y 20 años de edad.

Osteoporosis se define como reducción de la resistencia ósea que incrementa el riesgo de fracturas. La pérdida de tejido óseo se relaciona con deterioro de la microarquitectura esquelética. La Organización Mundial de la Salud (OMS) define operacionalmente a la osteoporosis como una densidad ósea que cae 2.5 desviaciones estándar (SD, standard deviations) por debajo del promedio de los adultos jóvenes sanos del mismo género, también conocida como una calificación T de -2.5. Las mujeres posmenopáusicas que inciden en el extremo inferior del espectro joven normal (calificación T <-1.0) son aquellas que tienen una densidad ósea reducida y mayor riesgo de padecer osteoporosis. Este

grupo con densidad ósea reducida padece más de 50% de las fracturas en las mujeres posmenopáusicas, incluidas las fracturas de cadera.

Cualquier persona puede desarrollar osteoporosis, pero es más común en mujeres adultas mayores. Los factores de riesgo generalmente aluden al envejecimiento, ser una persona pequeña y/o delgada, o tener antecedentes en familiares.

A. Base de datos

Para esta investigación se cuenta con una base de datos de estudiantes peruanos a los cuales se les registro algunos datos fisiológicos importantes para el desarrollo de la investigación, a continuación, se muestran dichos datos en la Tabla 1.

La muestra estuvo conformada por 368 escolares (172 varones y 196 mujeres). La selección de la muestra fue de tipo probabilístico (aleatorio). Esto corresponde al 12% del Universo total (IC: 95%). El rango de edad es de 6 a 11 años. Todos los escolares estudiados pertenecen a colegios del estado (condición socioeconómica media).

TABLA I
DATOS DE ESCOLARES PARA ENCONTRAR LA DMO

Abrev.	Nombre	Descripción	U. de Medida
FN	Fecha de Nacimiento.	Fecha de nacimiento del encuestado.	Formato: dd/mm/aaaa
Peso	Peso.	Peso del encuestado.	Kg.
Estatura	Estatura.	Estatura del encuestado cuando se encuentra de pie.	m.
ES	Estatura Sentado.	Estatura del encuestado cuando se encuentra sentado.	cm.
CA	Circunferencia Abdominal.	Medida de la circunferencia abdominal del encuestado.	cm.
DC	Diámetro de Codo.	Medida del diámetro del codo del encuestado.	cm.
DM	Diámetro de la Muñeca.	Medida del diámetro de la muñeca del encuestado.	cm.
DR	Diámetro de la Rodilla.	Medida del diámetro de la rodilla del encuestado.	cm.
DT	Diámetro del Tobillo	Medida del diámetro del codo del encuestado.	cm.
LA	Longitud del Antebrazo.	Medida de la longitud del antebrazo del encuestado.	cm.
LP	Longitud de la Pierna.	Medida de la longitud de la pierna del encuestado.	cm.
SO	Saturación de O ₂ .	Medida del nivel de saturación de oxígeno en la sangre del encuestado.	Nivel en Porcentaje (%)
FC	Frecuencia Cardíaca.	Medida del nivel de frecuencia cardíaca del encuestado.	
FE	Flujo Espiratorio.	Medida del nivel de flujo espiratorio del encuestado.	

Además, que se realizó una encuesta que consta de las tres preguntas que se muestran a continuación:

- ¿Haces Deporte? (si/no)
- ¿Fumas con frecuencia? (si/no)
- ¿Desayunas con normalidad? (si/no)

Para la carga, extracción y transformación (ETL en adelante) se utilizó la herramienta *Kettle Data Integration* que es una herramienta potente en lo que se refiere a herramientas ETL, para trabajar con la data, una vez procesada, se utilizó la herramienta WEKA una herramienta que nos permite trabajar con técnicas de aprendizaje supervisado y no supervisado.

El uso de métodos y herramientas para el análisis de diagnósticos médicos son los siguientes:

B. Minería de datos

La Minería de Datos (MD) es el proceso de extraer conocimiento útil y comprensible, previamente desconocido, desde grandes cantidades de datos almacenados en distintos formatos [8]. Las herramientas de Minería de Datos predicen futuras tendencias y comportamientos, permitiendo en los negocios la toma de decisiones.

De acuerdo con esto, el proceso de minería de datos consiste únicamente en la aplicación de un algoritmo para extraer patrones de datos y se llamará KDD al proceso completo que incluye pre-procesamiento, minería y post-procesamiento de los datos [9].



Fig. 1. Proceso de KDD

Las metas del KDD son:

- Procesar automáticamente grandes cantidades de datos sin filtrar.
- Identificar los patrones más significativos y relevantes.
- Presentarlos como conocimiento apropiado para satisfacer las metas del usuario

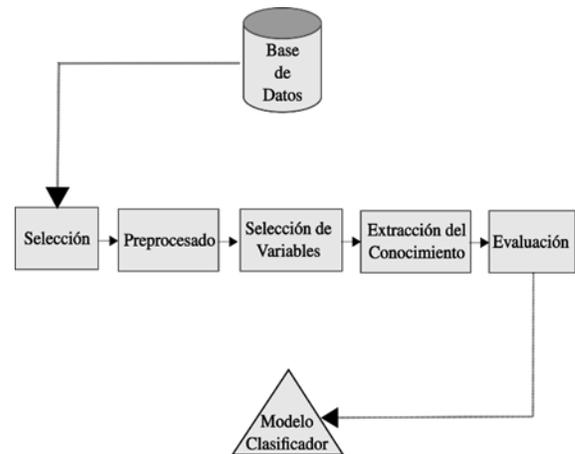


Fig. 2. Fases de un proceso de MD [10].

C. Clasificación

La clasificación tiene como particularidad la selección del atributo que mejor revela la clase de salida. Las características propias de este método de clasificación son su rapidez y buenos resultados, en contraste con otros algoritmos más complejo.

D. Asociación

Es una técnica importante en la Minería de Datos y consiste en encontrar las asociaciones interesantes en forma de relaciones de implicación entre los valores de los atributos de los objetos de un conjunto de datos.

Pasos principales en minería de reglas de asociación.

- Generación de *itemsets* frecuentes. Encontrar *itemsets* que tienen un soporte S mayor o igual que un punto de corte preestablecido.
- Derivación de reglas de asociación. Usando los *itemsets* frecuentes obtenidos anteriormente se generan las reglas de asociación que tienen una confianza C mayor o igual que un punto de corte preestablecido.

El rendimiento global de hacer minería para hallar reglas de asociación se determina en el primer paso.

E. Algoritmo Apriori

El algoritmo Apriori es un algoritmo básico de reglas de asociación, se puede usar para minar relaciones potenciales entre elementos de datos en varios campos. Permite encontrar de forma eficiente "conjuntos de ítems frecuentes", los cuales sirven de base para generar reglas de asociación [11].

El algoritmo se puede observar en la figura 3.

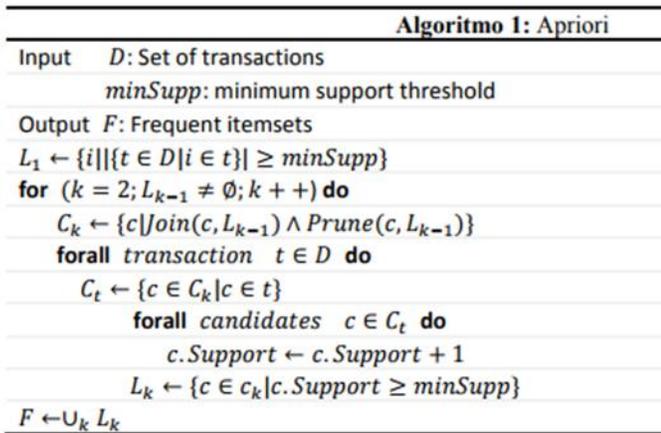


Fig. 3. Algoritmo apriori

F. Lógica Difusa

La lógica difusa se basa en lo relativo de lo observado como posición diferencial. Este tipo de lógica toma dos valores aleatorios, pero contextualizados y referidos entre sí. Así, por ejemplo, una persona que mida dos metros es claramente una persona alta, si previamente se ha tomado el valor de persona baja y se ha establecido en un metro. Ambos valores están contextualizados a personas y referidos a una medida métrica lineal.

G. Pre-procesamiento y Limpieza de Datos

Para tener una data bien estructurada y con la que se pueda trabajar de forma correcta es necesario verificar que todos los datos estén completos, en caso de no estarlo se debe tomar decisiones que regulen este problema.

En algunas aplicaciones es común llenar los datos faltantes utilizando un criterio matemático, en esta investigación se optó por eliminar aquellos registros donde algunos datos de interés (como las medidas de longitud de pierna, antebrazo, etc.) se encuentran ausentes, debido a que calcular estos valores empleando criterios matemáticos no sería correcto ya que estamos hablando de cuestiones de salud donde las aproximaciones podrían afectar los resultados, también, para poder trabajar con otras herramientas se optó por reemplazar los datos de tipo "NO", "SI" por valores numéricos como 0 y 1 respectivamente, todo esto a través de *Kettle*, herramienta previamente mencionada.

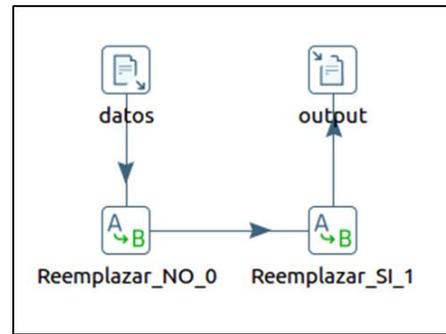


Fig. 4. Pre-procesamiento de Datos con Kettle.

IV. RESULTADOS

A. Clasificación de los datos utilizando el Densitómetro

Al momento de trabajar con un densitómetro este devuelve algunos valores que pueden ser de utilidad para quienes analizan los datos, entre esos valores existen dos parámetros de sumo interés T-score y Z-score, ambos son medidas que determinan cuan propensa esta una persona de desarrollar osteopenia u osteoporosis, ambos parámetros se regulan con referencia a una desviación estándar preestablecida. Los valores para determinar si una persona desarrollo osteopenia u osteoporosis se muestra a continuación:

TABLA II
NIVELES EN PERCENTILES DE DMO EN VARONES DE 11 A 18 AÑOS DE EDAD

Estado de una Persona	Score
Persona Normal	score ≥ -1.0
Persona con Osteopenia	$2.5 < \text{score} < -1.0$
Persona con Osteoporosis	score ≤ 2.5

Tanto T-score y Z-score son valores numéricos, ambos sirven para determinar el estado de desarrollo de osteoporosis en una persona, sin embargo, T-score es un valor con referencia a una persona adulta de 30 años y un sexo determinado (Femenino o Masculino), mientras que Z-score es un valor con referencia a personas de la misma edad y sexo.

Si se estableciera un criterio de clasificación del desarrollo de la osteoporosis en niños utilizando el T-score seguramente obtendríamos datos erróneos, es por tal motivo que para este trabajo se utilizará Z-score.

Para clasificar los datos una vez conociendo las clases, se utilizó la herramienta Weka, los resultados en sujetos de sexo masculino y femenino se muestran a continuación

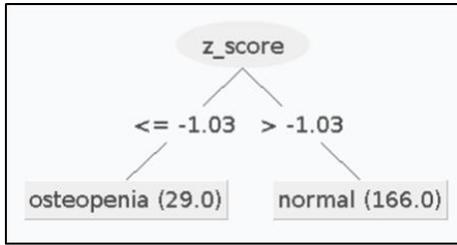


Fig. 5. Clasificación mediante árbol J48 en datos de personas de sexo femenino.

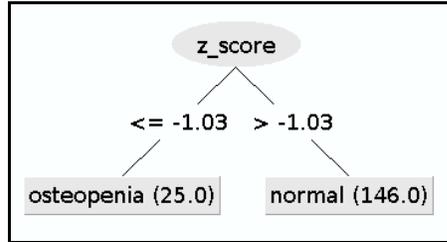


Fig. 6. Clasificación mediante árbol J48 en datos de personas de sexo masculino.

Como se puede observar en las figuras 5. y 6. el clasificador detecto automáticamente el valor -1.03 como un punto de quiebre entre las dos clases que son persona con osteopenia y persona normal. Se conoce con claridad cuantas personas se consideran normales y cuantas, con osteopenia, todo esto entre hombres y mujeres

B. Niveles Estándares de DMO

Esta investigación cuenta con un recurso clave y fundamental para determinar si existe o no el riesgo de desarrollar osteoporosis u osteopenia, se pudo obtener los niveles normales y de riesgo en cuanto a DMO.

TABLA III
NIVELES EN PERCENTILES DE DMO EN VARONES DE 4 A 11 AÑOS DE EDAD

Edad	P3	P5	P15	P25	P50	P75	P85	P95	P97
4	0.74	0.75	0.78	0.80	0.83	0.87	0.89	0.92	0.94
5	0.79	0.80	0.83	0.85	0.89	0.93	0.95	0.98	1.00
6	0.84	0.86	0.89	0.91	0.95	0.98	1.00	1.04	1.05
7	0.90	0.91	0.94	0.96	1.00	1.04	1.06	1.09	1.11
8	0.95	0.96	1.00	1.02	1.05	1.09	1.11	1.14	1.15
9	1.00	1.01	1.04	1.06	1.10	1.13	1.15	1.18	1.19
10	1.04	1.05	1.08	1.10	1.13	1.17	1.18	1.21	1.23
11	1.08	1.09	1.12	1.13	1.17	1.20	1.21	1.24	1.25

TABLA IV
NIVELES EN PERCENTILES DE DMO EN DAMAS DE 4 A 11 AÑOS DE EDAD.

Edad	P3	P5	P15	P25	P50	P75	P85	P95	P97
4	0.73	0.74	0.76	0.77	0.80	0.82	0.83	0.85	0.86
5	0.76	0.77	0.80	0.81	0.84	0.86	0.87	0.90	0.91
6	0.80	0.81	0.83	0.84	0.87	0.90	0.91	0.93	0.94
7	0.83	0.84	0.86	0.87	0.90	0.93	0.94	0.97	0.98
8	0.85	0.86	0.89	0.90	0.93	0.96	0.97	0.99	1.00
9	0.88	0.89	0.91	0.92	0.95	0.98	1.00	1.02	1.03

10	0.90	0.91	0.93	0.95	0.97	1.00	1.02	1.05	1.06
11	0.92	0.93	0.95	0.97	1.00	1.02	1.04	1.07	1.08

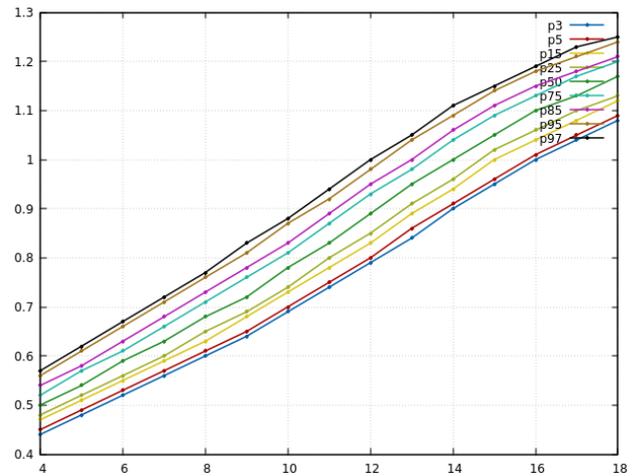


Fig. 7. Gráfica que muestra los percentiles pertenecientes a los niveles en varones (X: Edades vs. Y: Niveles de DMO).

C. Cálculo de DMO utilizando medidas antropométricas

En base a las ecuaciones para el cálculo de niveles de DMO en el que se encuentra una persona.

$$DMO = 0.605 + 0.056 * APHV + 0.008 * MA + 0.022 * MDF \quad (1)$$

$$DMO = 0.469 + 0.027 * APHV + 0.007 * MA + 0.019 * MDF \quad (2)$$

Las ecuaciones (1) y (2) muestran los cálculos para obtener los niveles de DMO en varones y damas respectivamente, donde:

- DMO: Densidad Mineral Ósea
- APHV: Edad del crecimiento acelerado
- MA: Medida de la longitud del antebrazo
- MDF: Medida del diámetro del fémur

Clasificación de Resultados obtenidos al aplicar la formula basadas en medidas antropométricas

Luego de obtener los resultados de DMO de los estudiantes de educación primaria y según los percentiles mostrados en las Tablas 1 y 2 para varones y mujeres respectivamente, los diagnósticos muestran que todos los estudiantes poseen un nivel de densidad mineral ósea normal, a excepción de un estudiante que fue clasificado como persona con osteoporosis.

Comparando ambos métodos (diagnostico basado en un densitómetro y diagnostico basado en características antropométricas) se observa una gran diferencia entre los resultados, mientras que los diagnósticos del densitómetro muestran un conjunto considerable de estudiantes con

osteopenia y osteoporosis, en método de cálculo mediante medidas antropomórficas muestra casi en su totalidad estudiantes con densidad mineral ósea normal.

D. Descubriendo Reglas de Asociación

Para encontrar un patrón entre los datos de los estudiantes se utilizó el algoritmo apriori el cual revela los siguientes resultados.

best rules found:

1. practica_deporte=1 242 ==> desayuna=1 240 <conf:(0.99)> lift:(1.01)
2. practica_deporte=1 fuma=0 238 ==> desayuna=1 236 <conf:(0.99)> lift:
3. desayuna=1 289 ==> fuma=0 285 <conf:(0.99)> lift:(1) lev:(-0) [0] cc
4. practica_deporte=1 242 ==> fuma=0 238 <conf:(0.98)> lift:(1) lev:(-0)
5. practica_deporte=1 desayuna=1 240 ==> fuma=0 236 <conf:(0.98)> lift:
6. fuma=0 291 ==> desayuna=1 285 <conf:(0.98)> lift:(1) lev:(-0) [0] cc
7. practica_deporte=1 242 ==> fuma=0 desayuna=1 236 <conf:(0.98)> lift:
8. desayuna=1 289 ==> practica_deporte=1 240 <conf:(0.83)> lift:(1.01)
9. fuma=0 desayuna=1 285 ==> practica_deporte=1 236 <conf:(0.83)> lift:
0. fuma=0 291 ==> practica_deporte=1 238 <conf:(0.82)> lift:(1) lev:(-0)

Fig 8. Identificación de Reglas de Asociación con todas las Variables.

1. rodilla_cm=8 67 ==> codo_cm=5 32 <conf:(0.48)> lift:(1.68) lev:(
2. antebrazo_der_cm=22 53 ==> codo_cm=5 23 <conf:(0.43)> lift:(1.52)
3. codo_cm=5 84 ==> rodilla_cm=8 32 <conf:(0.38)> lift:(1.68) lev:(
4. antebrazo_der_cm=23 47 ==> codo_cm=5 17 <conf:(0.36)> lift:(1.27)
5. pierna_cm=48 46 ==> antebrazo_der_cm=24 15 <conf:(0.33)> lift:(1
6. antebrazo_der_cm=22 53 ==> rodilla_cm=8 17 <conf:(0.32)> lift:(1
7. antebrazo_der_cm=23 47 ==> rodilla_cm=8 15 <conf:(0.32)> lift:(1
8. codo_cm=5 84 ==> antebrazo_der_cm=22 23 <conf:(0.27)> lift:(1.52)
9. antebrazo_der_cm=24 55 ==> rodilla_cm=8 15 <conf:(0.27)> lift:(1
0. antebrazo_der_cm=24 55 ==> pierna_cm=48 15 <conf:(0.27)> lift:(1

Fig 9. Identificación Reglas de Asociación omitiendo variables binarias

De los resultados Mostrados se puede destacar:

Estudiantes que practican deporte desayunan

Estudiantes de desayunan no fuman

Estudiantes con diámetros de rodilla de 8 cm. tienen un diámetro de codo de 5 cm.

Los estudiantes que tienen una longitud de antebrazo de 24 cm. Tienen una longitud de pierna de 48 cm.

E. Construcción de un Controlador Difuso

En esta parte gracias a los datos obtenidos es posible elaborar un controlador difuso en función a los percentiles antes mostrados. Donde los niveles por debajo del P3 significan una alta probabilidad de padecer osteoporosis, los niveles entre P3 y P15 indican una alta probabilidad de padecer de osteopenia y los niveles por encima de P15 indican que la persona posee una DMO y CMO normales.

Entonces es posible establecer la variable de salida, con una función afiliada que posee 3 valores difusos, como se muestra a continuación.

TABLA V
VALORES DIFUSOS DE SALIDA QUE SE ESPERA OBTENER EN UN CONTROLADOR DIFUSO

Valores Difusos	
Persona Sana	DMO > P15
Persona con Osteopenia	P15 > DMO > P3
Persona con Osteoporosis	P3 > DMO

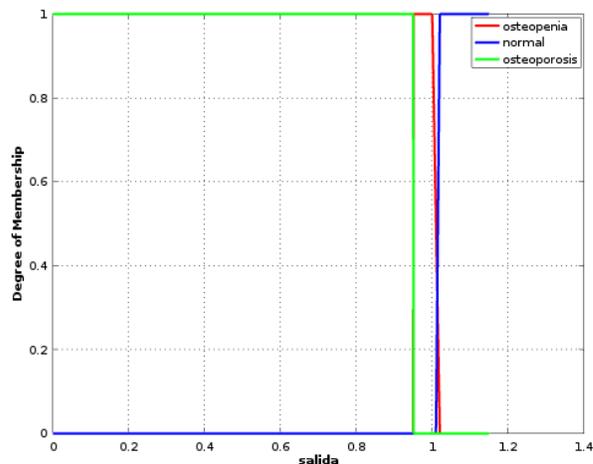


Fig. 10. Valores difusos propuestos en la Tabla 3.

V. CONCLUSIONES

El objetivo de esta investigación fue aplicar técnicas de minería de datos para determinar la densidad mineral ósea de un escolar y luego compararlo con los resultados de un equipo densitómetro.

Los resultados que se encontraron en función de la comparación de ambos métodos son contraproducentes y ello se puede deber a varios factores, esto se puede dar ya que los datos obtenidos de los escolares no fueron tomados con la precisión necesaria para el cálculo.

Los percentiles de diferentes estados/regiones, no se aplican a todas las realidades, en ese caso se debe obtener percentiles aplicables a la realidad local.

Para construir un controlador difuso es necesario determinar que el cálculo obtenido por medidas antropométricas sea correcto, una vez determinada, se podrá obtener qué medidas antropomórficas influyen en el desarrollo de osteopenia u osteoporosis en una persona. Los resultados alcanzados sugieren que se puede utilizar en la implementación de un software para determinar la predicción de osteoporosis.

AGRADECIMIENTOS

A la Universidad Nacional de San Agustín de Arequipa, que ha financiado el proyecto con número de contrato 42-2017-UNSA otorgado para la realización del artículo.

REFERENCIAS

- [1] Tejaswini, E., Vaishnavi, P., & Sunitha, R. (2016). "Detection and prediction of osteoporosis using impulse response technique and artificial neural network." 2016 International Conference on Advances in Computing, Communications and Informatics (ICACCI).
- [2] Sung Kean Kim, Tae Keun Yoo, Ein Oh, & Deok Won Kim. (2013). "Osteoporosis risk prediction using machine learning and conventional methods". 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC).
- [3] Li, H., Li, X., Jia, X., Ramanathan, M., & Zhang, A. (2015). "Bone disease prediction and phenotype discovery using feature representation over electronic health records". Proceedings of the 6th ACM Conference on Bioinformatics, Computational Biology and Health Informatics - BCB '15.
- [4] Li, H., Li, X., Ramanathan, M., & Zhang, A. (2007). "A Semi-Supervised Learning Approach to Integrated Salient Risk Features for Bone Diseases". Proceedings of the International Conference on Bioinformatics, Computational Biology and Biomedical Informatics - BCB '13.
- [5] Li, H., Li, X., Ramanathan, M., & Zhang, A. (2015). "Prediction and Informative Risk Factor Selection of Bone Diseases". IEEE/ACM Transactions on Computational Biology and Bioinformatics, 12(1), 79–91.
- [6] Kim, T., Ramanathan, M., Bone, L., & Zhang, A. (2011). "Mathematical network model for bone mineral density (BMD) and bone quality assessment". Proceedings of the 2nd ACM Conference on Bioinformatics, Computational Biology and Biomedicine - BCB '11.
- [7] Cossio-Bolaños, M., Lee-Andruske, C., de Arruda, M., Duarte-Rocha, C., Almonacid-Fierro, A., & Gómez-Campos, R. (2018). "Hand grip strength and maximum peak expiratory flow: determinants of bone mineral density of adolescent students". BMC Pediatrics, 18(1).
- [8] Gómez-Campos, R., Andruske, C. L., Arruda, M. de, Urra Alborno, C., & Cossio-Bolaños, M. (2017). "Proposed equations and reference values for calculating bone health in children and adolescent based on age and sex". PLOS ONE, 12(7).
- [9] Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). The KDD process for extracting useful knowledge from volumes of data. *Communications of the ACM*, 39(11), 27-35.
- [10] Saldaña, R., Fernando, J., & García Flores, R. (2005). El proceso de descubrimiento de conocimiento en bases de datos. *Ingenierías*, 8(26), 37-47.
- [11] You, X., Xu, Y., Huang, J., Zhi, Y., Wu, F., Ding, F., & Zhang, J. (2019). A Data Mining-Based Analysis of Medication Rules in Treating Bone Marrow Suppression by Kidney-Tonifying Method. *Evidence-Based Complementary and Alternative Medicine*, 2019.