

Identificación de somatotipos con inteligencia artificial: medidas antropométricas vs bioimpedancia

Identification of somatypes with artificial intelligence: anthropometric measurements vs bioimpedance

María Fernanda Urdañez Carbajal, José Sergio Ruiz Castilla, Farid García Lamont
Universidad Autónoma del Estado de México. Texcoco, Estado de México, México.
fer.marcarbajal@gmail.com, jsruizc@uaemex.mx, fgarcial@uaemex.mx.

Abstract

The shape of a person's body depends on their race due to genetic inheritance. The shape of a person's body is classified into somatotypes. The somatotypes are: endomorph, mesomorph and ectomorph. To determine the somatotype, the Heath and Carter method can be applied by measuring height, weight, arm and ankle diameters, as well as skin folds. The shape of the body is relevant in athletes. Therefore, in this work we try to predict the somatotype of a person. The prediction would be achieved without doing a calculation. A Dataset was obtained with values obtained from a bioimpedance device and anthropometric measurements. Algorithms were trained with both types of data using neural networks, SVM, and linear regression. Results were obtained and each scenario is compared. The best results were those generated with anthropometric measurements, reaching 96.8% accuracy.

Resumen

La forma del cuerpo humano es influenciada por varias características, desde su genética, alimentación y entrenamiento siendo modificables los últimos dos. Todos estos tienen afectación directa sobre tres componentes principales que son grasa, músculo y linealidad, conocido como somatotipo. Para poder obtener la cantidad que posee cada persona de estos componentes se utiliza la técnica de Heath y Carter, ya que permite tener la descripción cuantitativa del cuerpo, así como la composición corporal a través de medidas como son pliegues subcutáneos, peso, altura, circunferencias de extremidades y torso, entre otros, lo que se conoce como antropometría. Las aplicaciones y ventajas del cálculo del somatotipo son por mucho mejores que solo la obtención del IMC ya que este último no nos sirve para distinguir entre la distribución de los tres componentes del cuerpo mencionados anteriormente y solo nos da una estimación de parámetros excedidos por una persona. Aun así, el proceso de obtención de medidas puede ser un poco engorroso para el paciente y aunque los resultados son óptimos y permiten conocer la distribución corporal, se busca un medio alternativo, como la predicción para que podamos mejorar el proceso de obtención del somatotipo sin

tener que realizar ningún cálculo. Se obtuvo un dataset con valores arrojados por medio de una báscula de bioimpedancia y así también las medidas antropométricas. Se entrenaron algoritmos con ambos tipos de datos mediante redes neuronales, SVM y regresión lineal. Los resultados obtenidos fueron comparados en los dos escenarios. El mejor resultado fue obtenido con las medidas antropométricas, alcanzando un 96.8% de precisión.

Keywords and phrases: Somatotypes, Classification, Bioimpedance, Anthropometric Measurements.

2020 Mathematics Subject Classification: 68N01

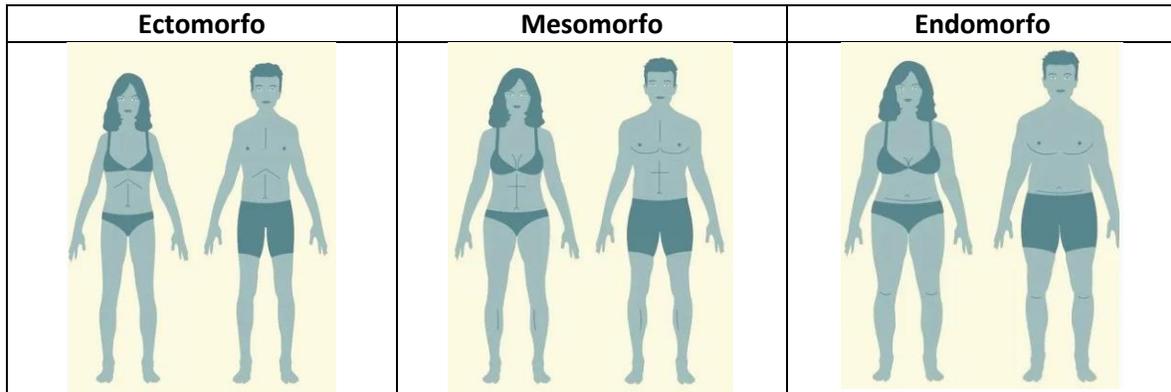
1 Introducción

El cuerpo de una persona es diferente de acuerdo con el género, edad y raza, que son parámetros no modificables. Existen otros parámetros que ayudan a cambiar la forma del cuerpo como son los hábitos alimenticios y ejercicio. Lo anterior, ayuda a que una persona tenga cierta tendencia a desarrollar diferentes grupos musculares. Para el deporte, es de gran ayuda esta identificación de características ya que la morfología del cuerpo ayuda a mejorar el desempeño en el deporte como es la biomecánica del movimiento y el rendimiento. A esta definición cuantitativa con la que se describe al cuerpo se le llama somatotipo. El somatotipo es la distribución física de los elementos corporales dentro de las tres categorías del somatotipo. El endomorfo corresponde al tejido adiposo subcutáneo, el mesomorfo es la masa musculoesquelética y el ectomorfo a la delgadez. En todos los casos, las personas pertenecen a más de una categoría, pero siempre una es más predominante. Hay que recordar que, el principio del somatotipo es identificar la grasa, músculo y linealidad lo cual puede ser identificado con mayor precisión a partir de una báscula de bioimpedancia eléctrica, la cual puede diferenciar entre el músculo y la grasa, densidad ósea, proporción del peso, cantidad de: grasa, masa muscular, agua, entre otros. Los anteriores son datos que pueden ser usados para clasificar los somatotipos de una persona sin necesidad de cálculos.

2 Somatotipos

El somatotipo representa la forma del cuerpo de una persona que tiene cierta tendencia a una categoría. De acuerdo con las medidas de cada persona se obtiene una clasificación y esta puede ayudar en diferentes aspectos como es proporcionar un plan alimenticio, reforzar la actividad física o decidir el deporte óptimo en el cual puede desenvolverse mejor. En la Tabla 1 [1] se muestran los somatotipos con las características físicas de cada uno.

Tabla 1. Somatotipos definidos para mujeres y hombres [1].



2.1 Método de medidas antropométricas

El método para obtener el somatotipo corresponde al propuesto por Heath y Carter que consiste en realizar las siguientes medidas: Pliegue del *triceps*, Pliegue *subescapular*, Pliegue *suprailíaco*, medidos en milímetros (mm). Diámetro *biepicondileo* de húmero y *bicondileo* del fémur, medido en centímetros (cm). Perímetro corregido del brazo en centímetros corregido por el pliegue *triceps*. Perímetro corregido por el pliegue de la pierna. También se determinó la estatura, medida en centímetros y el peso corporal medido en kilogramos (Kg.) [2].

2.2 Cálculo del Somatotipo

Las fórmulas que componen el método de Heath-Carter son las ecuaciones 1, 2 y 3: Se detalla cada una para cada caso

$$\text{Endomorfía} = -0,7182 + 0,1451X - 0,00068X^2 + 0,0000014X^3 \quad (1)$$

X= (Pliegue tricripital + Pliegue subescapular + Pliegue supra espinal en mm) * (170,18/Estatura en cm)

$$\text{Mesomorfía} = 0,858U + 0,601F + 0,188B + 0,161P - 0,131H + 4,5 \quad (2)$$

U= Diámetro *biepicondilar* del húmero en cm.

F= Diámetro *bicondilar* del *fémur* en cm.

B= Perímetro corregido del brazo en cm = Perímetro del brazo contraído – Pliegue *tricipital* en cm.

P= Perímetro corregido de la pierna en cm = Perímetro de la pierna (pantorrilla) – Pliegue de la pierna en cm.

H= Altura en cm.

$$\text{Ectomorfía} = \text{Índice ponderal (IP)} = \text{Estatura (cm)} \text{ Peso} * (1/3) \text{ en kg} \quad (3)$$

1. Si IP es mayor o igual a $40,75 - (IP * 0,732) - 28,58$
2. Si IP se encuentra entre $38,25$ y $40,75 - (IP * 0,463) - 17,63$
3. Si IP es menor o igual a $38,25 - 0,1$

Una vez aplicadas las ecuaciones se obtienen tres valores, una para cada somatotipo. Uno de los tres índices puede sobresalir. El valor máximo puede ser el somatotipo buscado [1].

2.3 Básculas de bioimpedancia eléctrica

Las básculas habituales nos ayudan a conocer el peso de una persona, sin poder diferenciar entre cada componente. Sin embargo, las básculas de bioimpedancia son todo lo contrario, permiten conocer la cantidad de músculo, grasa y agua de cualquier persona, se envía una pequeña cantidad de electricidad compuesta por *Resistencia R* y *Reactancia K*. entre las plantas de los pies y las palmas de las manos, de esta forma el cuerpo genera cierta resistencia de acuerdo con los componentes que posea su cuerpo y poder realizar la medición [3].

2.4 Aprendizaje automático

El Aprendizaje automático (AA – ML por sus siglas en inglés, *Machine learning*) es el término más usado en la literatura. El AA consiste en algoritmos capaces de aprender después de un entrenamiento. Con el entrenamiento se obtiene un modelo. El modelo es capaz de hacer predicciones o clasificaciones. Es posible hacer entrenamientos con datos diferentes como son textos, imágenes, audios o videos [4].

2.5 Aprendizaje supervisado, no supervisado y reforzado

El AA puede ser Supervisado, No supervisado o Reforzado. El AA Supervisado implica tener una etiqueta para cada elemento para ayudar al algoritmo a identificar a cada categoría. En el AA No supervisado los registros carecen de etiqueta. Por lo tanto, el algoritmo debe encontrar patrones y clasificar de acuerdo con dichos patrones. Generalmente se usa para hacer clústeres. Finalmente el AA Reforzado permite interactuar durante el entrenamiento para mejorar el modelo [4].

2.6 Algoritmos de clasificación

Los algoritmos de clasificación permiten generar clústeres que nos ayudan a identificar elementos de alguna categoría, los cuales son usados más frecuentemente en la actualidad. Permite identificar o diferenciar datos entre sí, ya sean imágenes o textos. Se ha usado desde el ámbito médico hasta en autos autónomos. Los más comunes son: el vecino más cercano (KNN), Máquinas de soporte vectorial (SVM), Redes bayesianas, entre otros [4].

2.7 Trabajos relacionados

En [5] se propone aplicar una red neuronal artificial para determinar la endomorfia, ectomorfia y mesomorfia utilizando datos sobre la altura, peso y datos brutos sobre análisis de impedancia bioeléctrica en mujeres jóvenes con ayuda del método Heath-Carter, en el que se propuso un perceptrón multicapa, se utilizó 173 casos y se dividieron 70% para entrenamiento, 15% para validación y 15% para prueba de los cuales se obtuvieron una precisión aproximada de entre 0.83 y 0.87.

En [6] se tiene como objetivo analizar las aplicaciones del aprendizaje automático en las ciencias del deporte relacionadas con la cineantropometría, utilizando la plataforma *Microsoft Azure Machine Learning* y comparar los algoritmos clasificadores. Se utilizó un tamaño de muestra de 1000 datos, el conjunto de datos se dividió en el 75% entrenamiento y el 25% prueba, para los algoritmos utilizados se tuvo las siguientes precisiones respectivamente: red neuronal multiclase el .8483, árboles de decisión .7448, regresión logística 0.2009 y decisión multiclase .7658

Para [7] se tiene como finalidad predecir los tipos de cuerpo de las mujeres al comparar la tasa de precisión predictiva entre un análisis discriminante estadístico y una Red neuronal artificial (ANN por sus siglas en inglés). Se observó que la ANN generó una precisión del 94.7% para predecir los tipos de cuerpo con mayor precisión que el discriminante análisis 83.5%.

Para la investigación [8] se utilizaron imágenes tomadas de internet para la predicción de atributos físicos de imágenes de rostros usando redes neuronales convolucionales, donde se usaron alrededor de 61,000 imágenes de la web y luego se usó detección de rostros para recortar las caras de estas imágenes. Se usó una ResNet-50 como arquitectura, en las que se obtuvo las siguientes precisiones para tipo de cuerpo 84.58%, etnia 87.34%, para altura 70.51%, peso 63.99%.

En [9] se realiza un trabajo que utiliza Redes neuronales de Regresión generalizada capaces de predecir con precisión 76 medidas corporales detalladas a partir de las siguientes características corporales fáciles de medir como son: la edad, sexo, y perímetro de busto, cintura y cadera de la cual se tiene una precisión del .90 al .92.

En el trabajo [10] se realizó la clasificación de la forma del cuerpo de los estudiantes basada en la red neuronal profunda. Para ello, basado en los datos del cuerpo humano en 3D, de 62 estudiantes. Para los cuales, se obtuvieron las coordenadas en *Matlab* para identificar los cuatro ángulos del cuerpo, al comparar los resultados de clasificación se encontró que los mejores resultados se obtuvieron cuando las muestras se dividieron en cuatro categorías y la probabilidad fue inferior a 0.05. No se buscó el somatotipo sino otras categorías. Todos los estudiantes fueron clasificados en alguna categoría.

En [11] se tiene como objetivo obtener el somatotipo utilizando sus imágenes corporales en diferentes posiciones basándose en técnicas de procesamiento de imágenes, se obtuvo un Dataset de 46 personas. Los resultados obtenidos muestran que el tipo de somatotipo de los fisiculturistas se puede estimar solo con base a las imágenes, obteniendo la mejor tasa de clasificación del 92%.

3 Método propuesto

3.1 Obtención del dataset

Una Báscula de Bioimpedancia Eléctrica (BBE) proporciona datos relacionados con el peso, cantidad de grasa, masa muscular y agua entre otros indicadores. La BBE es utilizada por los entrenadores físicos profesionales y los nutriólogos. Cada BBE proporciona diferentes indicadores. Sin embargo, la información es considerada privada, por lo que es complicado que dicha información sea compartida.

Para este trabajo se usó un Dataset disponible por *Krzykala*. El Dataset cuenta con datos de una BBE y con datos de Medidas Antropométricas (MA) [12] . Ver Tabla 2. El Dataset se dividió por columnas para trabajar con datos de la BBE y MA por separado. Al final se hacen pruebas con los datos juntos.

Tabla 2. Datos desde un dispositivo de bioimpedancia eléctrica [12].

S E X O	Edad en decimal	Altura [cm]	Peso [kg]	TBWP [%]	FATP [%]	FATM [kg]	PMM [%]	PMM [kg]	FFM [kg]	RLFAT P [%]	RLFAT M [kg]	RLPM M [%]	TRFFM [kg]
F	19.25	163.5	44.2	60.2	11.6	5.2	37.4	16.5	39.3	22.0	1.9	6.3	... 22.5
F	18.92	174.8	60.9	57.3	21.1	12.7	45.3	27.6	47.7	24.6	2.7	7.8	... 26.9
F	18.92	165.8	51.0	61.0	16.3	8.4	41.0	20.9	43.2	23.4	2.3	6.9	... 24.8
F	19.67	163.2	44.0	60.1	25.0	14.1	40.0	17.6	42.1	32.6	3.4	6.6	... 24.2
F	19.83	184.4	67.0	60.9	13.2	9.3	58.4	39.1	61.2	10.1	1.2	10.3	... 32.9
F	19.25	171.7	55.4	57.9	24.0	13.8	41.7	23.1	43.9	27.0	2.8	7.2	... 24.6
F	19.58	174.0	55.7	58.9	19.6	10.9	42.4	23.6	44.8	24.5	2.5	7.2	... 25.5
F	19.75	166.8	53.7	58.7	20.0	10.7	41.0	22.0	43.0	25.7	2.6	7.0	... 24.5
F	19.50	165.8	50.4	60.3	8.1	4.1	43.3	21.8	46.3	20.7	2.0	7.1	... 26.4
F	19.58	177.9	70.6	56.4	23.1	16.3	51.6	36.4	54.3	28.2	3.6	8.5	... 31.0
F	18.92	174.5	59.8	56.5	22.7	13.6	43.9	26.3	46.2	26.1	2.8	7.6	... 26.0
F	18.83	171.0	55.1	57.0	30.5	18.8	40.7	22.4	42.9	32.4	3.6	7.1	... 24.1
F	20.67	176.8	61.6	56.7	24.7	15.6	45.3	27.9	47.7	27.2	3.1	7.8	... 26.7
F	20.17	173.0	62.9	57.6	21.7	13.7	46.9	29.5	49.4	28.4	3.2	7.7	... 28.4
F	19.08	163.9	50.4	60.7	16.7	8.6	41.0	20.7	43.2	25.1	2.4	6.9	... 24.8
F	21.17	167.2	51.5	59.2	17.5	8.9	39.6	20.4	41.7	25.6	2.4	6.6	... 24.0
F	18.92	161.8	43.4	50.9	30.4	13.2	28.7	12.5	30.2	41.2	3.8	5.1	... 17.1
F	18.67	172.2	56.1	55.4	24.3	13.7	40.3	22.6	42.5	26.4	2.7	7.1	... 23.6
F	19.42	168.2	54.1	55.8	23.9	13.0	39.0	21.1	41.2	28.0	2.8	6.8	... 23.2
F	19.50	172.0	57.0	52.8	27.8	15.9	39.2	22.3	41.1	32.3	3.3	6.6	... 23.5

El Dataset tiene 35 columnas incluyendo: Género, Edad, Estatura y Peso. No se muestran todas las columnas en la Tabla 2, por falta de espacio.

Por otro lado, se tienen datos de medidas antropométricas. Para este caso se conservó: Género, Edad, Estatura y Peso. Ver la Tabla 3.

En la Tabla de MA se tienen medidas en centímetros y milímetros. Se cuenta con 13 datos o columnas.

Tabla 3. Datos desde medidas antropométricas [12].

Sex	Decimal age	Height [cm]	Weight [kg]	TBWP [%]	Elbow width [cm]	Knee width [cm]	Subscapular skinfold [mm]	Triceps skinfold [mm]	Suprailiac skinfold [mm]	Calf skinfold [mm]	Arm circumference [cm]	Calf circumference [cm]
F	19.25	163.5	44.2	60.2	5.7	8.3	9.0	11.2	7.4	9.8	21.5	30.0
F	18.92	174.8	60.9	57.3	6.0	9.0	8.2	15.6	11.6	14.2	23.0	35.0
F	18.92	165.8	51.0	61.0	5.8	8.3	8.4	9.6	9.0	10.0	23.5	32.5
F	19.67	163.2	44.0	60.1	5.6	8.4	15.0	13.6	21.6	14.4	24.0	32.0
F	19.83	184.4	67.0	60.9	7.0	9.4	10.0	8.2	11.2	11.6	26.0	33.5
F	19.25	171.7	55.4	57.9	5.9	8.7	7.0	10.2	15.0	8.0	23.0	34.0
F	19.58	174.0	55.7	58.9	6.1	9.1	9.4	11.0	12.0	9.8	23.5	33.5
F	19.75	166.8	53.7	58.7	6.1	9.2	8.2	14.2	10.2	12.8	23.0	34.5
F	19.50	165.8	50.4	60.3	6.1	8.4	7.2	8.2	8.0	5.2	21.5	32.0
F	19.58	177.9	70.6	56.4	6.9	9.5	10.0	9.6	10.2	10.4	27.0	37.0
F	18.92	174.5	59.8	56.5	5.9	8.5	9.0	12.0	14.0	12.0	24.5	36.0
F	18.83	171.0	55.1	57.0	6.6	8.8	10.8	13.8	15.4	10.8	24.0	33.0
F	20.67	176.8	61.6	56.7	5.9	8.7	9.2	15.8	15.8	12.4	24.0	34.0
F	20.17	173.0	62.9	57.6	6.0	8.5	8.4	12.0	12.0	14.0	26.0	34.5
F	19.08	163.9	50.4	60.7	5.7	8.3	10.4	9.6	12.0	9.0	22.5	34.0
F	21.17	167.2	51.5	59.2	6.0	8.1	11.2	11.0	18.0	9.0	24.0	32.5
F	18.92	161.8	43.4	50.9	5.6	8.3	8.0	14.0	9.2	17.4	22.0	31.5
F	18.67	172.2	56.1	55.4	6.1	9.1	7.8	16.4	10.8	12.6	23.1	35.6
F	19.42	168.2	54.1	55.8	6.0	8.5	13.4	12.6	11.2	12.0	23.8	32.3

Se creó un Dataset con ambos datos para el entrenamiento. Lo anterior para hacer tres entrenamientos y comparar los datos.

3.2 Método aplicado

Con el Dataset de *Krzykala* se trataron los datos por separado. Por un lado, los datos de la BBE y por el otro lado los datos de las MA. Luego se llevó a cabo el entrenamiento con los algoritmos de Redes neuronales artificiales (RNA) y Regresión logística (RL). Para el Entrenamiento se utilizó la aplicación de *Orange*. Se obtuvieron datos de cada conjunto de datos. Finalmente, se obtuvieron datos de los datos juntos BBE y Las MA. Ver la Figura 1.

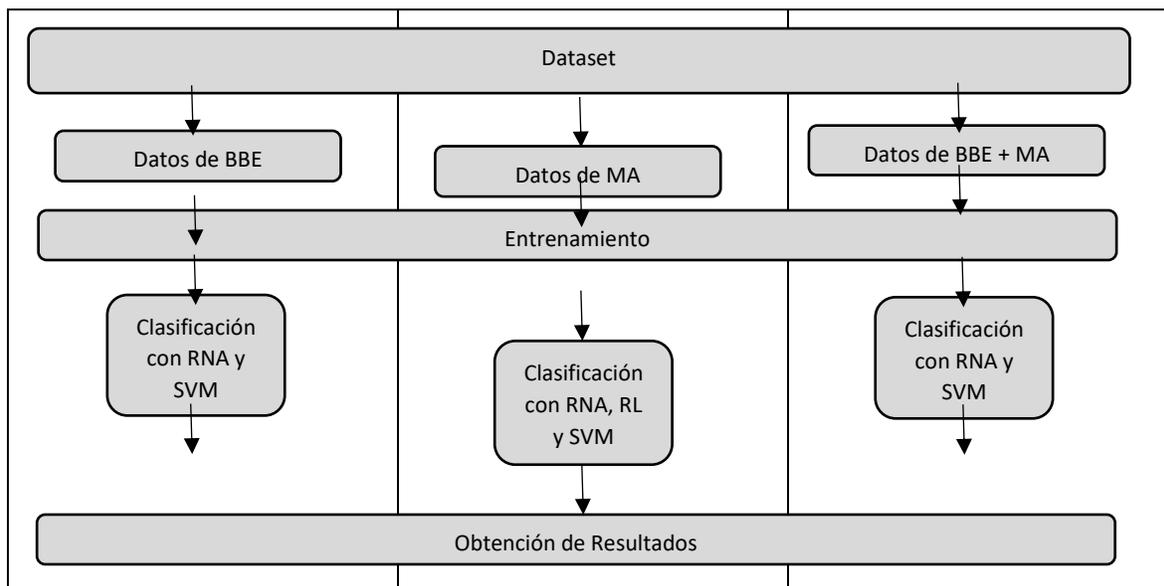


Figura 1. Diagrama de las tres dataset para el entrenamiento.

4 Resultados

Para la clasificación de somatotipos usando solo datos de la BBE. Se presentan los resultados de cada categoría. Ver la Tabla 4 y 5.

Tabla 4. Resultados del dataset de datos del dispositivo de bioimpedancia eléctrica.

Modelo	Ectomorfo						Endomorfo						Mesoformo					
	AUC	CA	F1	Prec	Recall	MCC	AUC	CA	F1	Prec	Recall	MCC	AUC	CA	F1	Prec	Recall	MCC
RNA	0.921	0.903	0.581	0.607	0.557	0.527	0.964	0.911	0.941	0.933	0.948	0.765	0.955	0.923	0.717	0.722	0.712	0.672
RL	0.923	0.915	0.627	0.664	0.593	0.580	0.964	0.914	0.943	0.927	0.959	0.769	0.948	0.925	0.713	0.750	0.679	0.671
SVM	0.901	0.908	0.524	0.706	0.417	0.498	0.953	0.887	0.928	0.887	0.972	0.692	0.946	0.919	0.677	0.741	0.624	0.634

Tabla 5. Matrices de confusión del dataset de datos del dispositivo de bioimpedancia eléctrica.

RNA	Ectomorfo			Endomorfo			Mesomorfo			RL	Ectomorfo			Endomorfo			Mesomorfo			SVM	Ectomorfo			Endomorfo			Mesomorfo		
	Ectomorfo	Endomorfo	Mesomorfo	Ectomorfo	Endomorfo	Mesomorfo	Ectomorfo	Endomorfo	Mesomorfo		Ectomorfo	Endomorfo	Mesomorfo	Ectomorfo	Endomorfo	Mesomorfo	Ectomorfo	Endomorfo	Mesomorfo		Ectomorfo	Endomorfo	Mesomorfo	Ectomorfo	Endomorfo	Mesomorfo			
Ectomorfo	167	79	54	Ectomorfo	178	72	50	Ectomorfo	125	114	61	Ectomorfo	125	114	61	Ectomorfo	125	114	61	Ectomorfo	125	114	61	Ectomorfo	125	114	61		
Endomorfo	56	1745	39	Endomorfo	48	1765	27	Endomorfo	38	1789	13	Endomorfo	38	1789	13	Endomorfo	38	1789	13	Endomorfo	38	1789	13	Endomorfo	38	1789	13		
Mesomorfo	52	46	242	Mesomorfo	42	67	231	Mesomorfo	14	114	212	Mesomorfo	14	114	212	Mesomorfo	14	114	212	Mesomorfo	14	114	212	Mesomorfo	14	114	212		

Como se puede observar se logró el 93.3% de predicción al clasificar la categoría de Endomorfo con la RNA, donde solo se clasificaron 75 de 1840. Mientras que la precisión más baja se presentó en la Categoría de Ectomorfo con la RNA con el 60.7%.

Por otro lado, la Categoría de Medidas antropométricas presentó mejores resultados. Ver la Tabla 6 y 7.

Tabla 6. Resultados del dataset con datos de medidas antropométricas.

Modelo	Ectomorfo						Endomorfo						Mesoformo					
	AUC	CA	F1	Prec	Recall	MCC	AUC	CA	F1	Prec	Recall	MCC	AUC	CA	F1	Prec	Recall	MCC
RNA	0.984	0.962	0.847	0.844	0.851	0.826	0.987	0.953	0.968	0.968	0.968	0.877	0.987	0.959	0.848	0.851	0.845	0.825
SVM	0.975	0.954	0.824	0.792	0.859	0.799	0.986	0.949	0.965	0.961	0.969	0.865	0.985	0.960	0.845	0.904	0.793	0.824

Tabla 7. Matrices de confusión del dataset con datos de medidas antropométricas.

RNA					SVM				
	Ectomorfo	Endomorfo	Mesomorfo	Σ		Ectomorfo	Endomorfo	Mesomorfo	Σ
Ectomorfo	1313	137	93	1543	Ectomorfo	1325	152	66	1543
Endomorfo	139	8884	155	9178	Endomorfo	205	8897	76	9178
Mesomorfo	104	156	1419	1679	Mesomorfo	143	205	1331	1679
Σ	1556	9177	1667	12400	Σ	1673	9254	1473	12400

Con el Dataset conformado con las Medidas antropométricas se logró el mejor resultado. El mejor resultado fue del 96.8% con la Categoría de Endomorfo con la RNA. Mientras que el resultado más bajo fue del 79.2% para el Ectomorfo con la SVM.

Finalmente, con el Dataset combinado los resultados fueron mejores que el Dataset-BBE, pero menor que el Dataset-MA. Ver la Tabla 8 y 9.

Tabla 8. Resultados del dataset con datos del dispositivo de bioimpedancia y medidas antropométricas.

Modelo	Ectomorfo						Endomorfo						Mesoformo					
	AUC	CA	F1	Prec	Recall	MCC	AUC	CA	F1	Prec	Recall	MCC	AUC	CA	F1	Prec	Recall	MCC
RNA	0.967	0.942	0.746	0.803	0.697	0.716	0.982	0.943	0.962	0.955	0.969	0.852	0.968	0.937	0.777	0.764	0.791	0.741
SVM	0.947	0.935	0.710	0.790	0.645	0.679	0.980	0.910	0.941	0.910	0.974	0.758	0.949	0.932	0.727	0.824	0.651	0.695

Tabla 9. Matrices de confusión del dataset de datos del dispositivo de bioimpedancia y medidas antropométricas.

RNA					SVM				
	Ectomorfo	Endomorfo	Mesomorfo	Σ		Ectomorfo	Endomorfo	Mesomorfo	Σ
Ectomorfo	53	10	13	76	Ectomorfo	49	22	5	76
Endomorfo	6	443	8	457	Endomorfo	5	445	7	457
Mesomorfo	7	11	68	86	Mesomorfo	8	22	56	86
Σ	66	464	89	619	Σ	62	489	68	619

Los resultados muestran que la mejor precisión ha sido para la categoría de Endomorfo con la RNA con el 95.5%. Mientras que la precisión más baja fue para la categoría de Mesomorfo con la RNA con el 75.4%.

Se presenta una comparación de resultados de las tres estrategias de este trabajo. Por otro lado, se presentan los resultados del estado del arte encontrado. Ver la Tabla 10.

Tabla 10. Comparación de resultados propios y del estado del arte.

Resumen de resultados de los escenarios		Resultados de trabajos del estado del arte	
	Máxima	Técnica	Precisión
Dataset con bioimpedancia	93.3%	[1] Perceptrón múltiple	87%
Dataset con medidas antropométricas	96.8%	[2] Red neuronal	84.8%
Dataset combinado	95.5%	[3] Red neuronal	94.7%
		[4] Red neuronal convolucional	87.3

5 Conclusiones y trabajo a futuro

Después de aplicar entrenamiento a los diferentes Dataset se concluye que es posible predecir el somatotipo. Si usamos los datos de impedancia la predicción puede ser hasta del 93.3% en la categoría de mesomorfo. Mientras, que con el Dataset de medidas antropométricas es posible predecir el somatotipo hasta el 96.7%. Por lo tanto, es posible hacer predicción con datos antropométricos sin necesidad de hacer los cálculos apoyados en los algoritmos de clasificación. Además, resulta un método más práctico y barato debido a que el equipo es más básico.

Se trabajó la clasificación con imágenes. Sin embargo, los resultados no fueron favorables. Se sigue trabajando con las imágenes, pero se segmentarán. Con este pre procesamiento se pretende utilizar la aplicación Orange y algoritmos de Aprendizaje profundo.

Agradecimientos

Se agradece al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo brindado.

Referencias

- [1] A. V. Sport, «Somatotipo y su clasificación. ¿Cómo se calcula?,» [En línea]. Available: <https://aptavs.com/articulos/conoces-tu-somatotipo>. [Último acceso: 22 06 2023].
- [2] V. Carrasco Alarcón, C. Martínez Salazar, E. Díaz Bustos, H. Silva Mella y O. Jirón Amaro, «Caracterización del somatotipo de estudiantes universitarios,» *Revista Ciencias de la Actividad Física*, num 13, pp. 45-50, 2012.
- [3] J. R. Iván, Valoración de la composición corporal por antropometría y bioimpedancia eléctrica, Tesis de Licenciatura de la Universidad Francisco de Vitoria, 2016.
- [4] M. & K. J. A. Kubat, «An introduction to machine learning,» Switzerland: Springer International Publishing., vol. 2, pp. 321-329, 2017.
- [5] M. G. K. & G. M. Drywień, «Application of artificial neural network to somatotype determination,» *Applied Sciences*, vol. 11, num 4, p. 1365, 2021.
- [6] D. & C. M. Katović, Comparison of Machine Learning Algorithms for Somatotype Classification, In *Proceedings of the 7th International Conference on Sport Sciences Research and Technology Support (icSPORTS 2019)*, p.p. 217-223, 2019. DOI: 10.5220/0008368002170223
- [7] N. S. H. K. K. S. & D. W. Kim, «An Effective Research Method to Predict Human Body Type Using an Artificial Neural Network and a Discriminant Analysis.,» *Fibers and Polymers*, vol. 19, pp. 1781-1789., 2018.
- [8] R. T. A. T. & T. M. Jahandideh, Physical attribute prediction using deep residual neural networks, *arXiv preprint arXiv:1812.07857*, 2018.
- [9] L. L. T. J. B. J. & E. L. Wang, «A data-driven approach towards the full anthropometric measurements prediction via Generalized Regression Neural Networks.,» *Applied Soft Computing*, vol. 109, p. 107551, 2021.
- [10] F. Li, «Classification of Students' Body Shape Based on Deep Neural Network,» In *Innovative Computing*, vol. 675, pp. 549-557, 2020.
- [11] A. R. A. d. O. G. T. C. J. W. B. G. E. C. C. K. F. & C. P. M. Brasil, «Automatic Identification of Somatotype by Digital Images,» In *Simpósio Brasileiro de Automação Inteligente-SBAI*, vol. 1, nº 1, 2021.
- [12] M. K. M. S. R. P. B. P. K. & K. K. Krzykała, « Morphological asymmetry, sex and dominant somatotype among Polish youth,» *Plos on*, vol. 15, num 9, 2020.