



UNIVERSIDAD  
DE PIURA

FACULTAD DE INGENIERÍA

**Estudio para estimar el contenido de humedad en  
agregados de concreto utilizando redes neuronales y  
algoritmos genéticos mediante imágenes hiperespectrales**

Trabajo de Investigación para optar el Grado de  
Bachiller en Ingeniería Mecánico - Eléctrica

**Miguel Angel Delgado Saavedra  
Edson Ayrton Effio Velasco  
Ney Margarita Farfán Marchán**

Asesor:  
Dr. Ing. William Ipanaqué Alama

Piura, abril de 2021



## **Agradecimientos**

En primer lugar, deseamos expresar nuestro agradecimiento al laboratorio de Sistemas Automáticos de Control y al laboratorio de Mecánica de Suelos por facilitarnos los componentes necesarios para realizar el trabajo de investigación, a las personas que laboran dentro de este que nos orientaron y nos dieron su tiempo para instruirnos en diferentes temas.

Al Dr. William Ipanaqué por la dedicación y apoyo que ha brindado a este trabajo, además, de sus invaluable conocimientos y sugerencias que nos permitieron sacar adelante este proyecto. Pero sobre todo por la confianza brindada, la cual nos sirvió para presentar esta investigación la misma que ha sido indexada en SCOPUS, por la IEEE.

No obstante, un trabajo de investigación es además resultado del apoyo y reconocimiento que nos brindan las personas más cercanas a nosotros y que nos aprecian mucho, sin las cuales no tendríamos la energía y fuerza que nos incita a crecer como personas y profesionales. Finalmente, gracias a nuestras familias pues siempre nos han prestado apoyo moral, emocional y humano, necesarios en los momentos difíciles de este trabajo y profesión.



## Resumen Analítico-Informativo

**Estudio para estimar el contenido de humedad en agregados de concreto utilizando redes neuronales y algoritmos genéticos mediante imágenes hiperespectrales**

**Delgado Saavedra, Miguel Angel; Effio Velasco, Edson Ayrton; Farfán Marchán, Ney Margarita.**

Asesor(es): **Ing. William Ipanaqué Alama**

Trabajo de investigación.

**Bachiller en Ingeniería Mecánico-Eléctrica**

**Universidad de Piura.** Facultad de Ingeniería.

**Piura,** Abril de 2021

**Palabras claves:** humedad, imagen hiperespectral, agregado de concreto, arena, inteligencia artificial, wavelet.

**Introducción:** A nivel mundial, uno de los sectores con mayor crecimiento es el de la construcción; tanto de edificios, casas, etc. Para su realización, el concreto es un elemento indispensable, debido a su duración, alta resistencia, impermeabilidad y facilidad de producción. En el Perú la elaboración de este se da de manera empírica, por lo que se debe de optimizar este proceso con valores precisos.

**Metodología:** Se utilizaron 3 canteras de arena, las cuales son: Moyobamba, Cerro Mocho y Sechura, a estas se le realizaron mediciones estándares para que así todas estén parametrizadas. Las muestras fueron almacenadas en un horno por 1 día a una temperatura de  $110 \pm 5^\circ\text{C}$  para que así la humedad se elimine completamente. Para la preparación de las muestras, de cada cantera se decidieron sacar 65 con el objetivo de administrarles diferente contenido de humedad. Se varió el porcentaje de humedad desde 0% y se aumentó cada 0.2%, llegando a 12% en la última muestra. Una vez realizado esto se prosigue al estudio a partir de imágenes hiperespectrales, mediante una cámara hiperespectral. Esta cámara hace uso del software SpectrononPro en donde se importa el espectro y proyecta la firma espectral, la cual es una gráfica de reflectancia vs longitud de onda. Posterior a esto se introducen los datos obtenidos a las redes neuronales y algoritmos genéticos para entrenar y validar el modelo.

**Resultados: Con redes neuronales:** El sistema redujo el número de bandas a 60 y se obtuvo una correlación de 0.87, el cual es un resultado muy aceptable. **Con sistema experto:** Al aplicar este algoritmo el número de bandas se redujo a 27 que son las que contienen la mayor cantidad de información, obteniéndose una correlación de 0.93.

**Conclusiones:** El sistema experto optimiza el anterior método descartando aquellas bandas que aportan menos información, permaneciendo así las que son relevantes y describen completamente el sistema, reduciéndose a 27 bandas de las 60 seleccionadas anteriormente y obteniendo como resultado una correlación de 0.93, relativamente ideal, demostrando que el sistema funciona.

**Fecha de elaboración del resumen:** Abril de 2021

## Analytical-Informative Summary

Estudio para estimar el contenido de humedad en agregados de concreto utilizando redes neuronales y algoritmos genéticos mediante imágenes hiperespectrales

Delgado Saavedra, Miguel Angel; Effio Velasco, Edson Ayrton; Farfán Marchán, Ney Margarita.

Asesor(es): Ing. William Ipanaqué Alama

Trabajo de investigación.

Bachiller en Ingeniería Mecánico-Eléctrica

Universidad de Piura. Facultad de Ingeniería.

Piura, Abril de 2021

**Keywords:** moisture, hyperspectral image, concrete aggregate, sand, artificial intelligence, wavelet.

**Introduction:** Worldwide, one of the sectors with the greatest growth is the construction sector; both buildings and houses, etc. For its realization, concrete is an indispensable element, due to its duration, high resistance, impermeability, and ease of production. In Peru, the elaboration of this is given in an empirical way, so this process must be optimized with precise values.

**Methodology:** Three sand quarries were used, which are Moyobamba, Cerro Mocho and Sechura. Standard measurements were taken for all of them to be parameterized. The samples were stored in an oven for 1 day at a temperature of  $110 \pm 5^\circ\text{C}$  so that the humidity is completely eliminated. For the preparation of the samples, it was decided to take 65 from each quarry in order to administer different moisture contents. The percentage of humidity was varied from 0% and increased every 0.2%, reaching 12% in the last sample. Once this had been done, the study was continued using hyperspectral images, by means of a hyperspectral camera. This camera makes use of the SpectrononPro software where the spectrum is imported and projects the spectral signature, which is a reflectance vs wavelength graph. After this, the data obtained is introduced to the neural networks and genetic algorithms to train and validate the model.

**Results:** With neural networks: The system reduced the number of bands to 60 and a correlation of 0.87 was obtained, which is a very acceptable result. With expert system: By applying this algorithm the number of bands was reduced to 27 which are those that contain the most information, obtaining a correlation of 0.93.

**Conclusions:** The expert system optimizes the previous method by discarding those bands that provide less information, thus remaining those that are relevant and completely describe the system, reducing it to 27 bands of the 60 previously selected and obtaining as a result a correlation of 0.93, relatively ideal, demonstrating that the system works.

**Summary date:** April of 2020

## Tabla de contenido

Introducción .....	1
Capítulo 1.....	3
Generalidades.....	3
1.1. Antecedentes .....	3
1.2. Planteamiento del problema.....	3
1.3. Objetivos .....	3
1.3.1. Objetivos Generales .....	3
1.3.2. Objetivos específicos.....	3
1.4. Elección de las muestras de trabajo .....	4
1.5. Justificación del estudio .....	4
Capítulo 2.....	5
Marco teórico.....	5
2.1 Métodos de medición del porcentaje de humedad.....	5
2.1.1. Sensores de humedad.....	5
2.1.2. Sensores mecánicos (por deformaciones):.....	5
2.1.3. Bulbos húmedo y seco .....	6
2.1.4. Sensores por condensación .....	7
2.1.5. Sensores infrarrojos .....	8
2.2 Cámara hiperespectral.....	9
2.2.1. Sistemas hiperespectrales .....	9
2.2.2. Procesamiento de imágenes hiperespectrales .....	9
2.3 Metodologías de predicción.....	11
2.3.1 Rectas de regresión .....	12
2.3.2 Phytton .....	14
2.3.3. Redes Neuronales .....	17
2.4 Algoritmos genéticos .....	25
2.4.1 Esquema básico.....	25

2.4.2. Parámetros de los algoritmos genéticos.....	25
2.4.3 Operadores Genéticos.....	27
2.4.4. Algoritmos de reemplazo.....	30
2.4.5. Evaluación.....	31
Capítulo 3.....	33
Metodología.....	33
3.1 Muestras estandarizadas.....	33
3.2 Preparación de las muestras.....	35
3.3 Toma de imágenes en la Cámara Hiperespectral.....	37
3.3.1 Procedimiento en la cámara hiperespectral.....	37
Capítulo 4.....	41
Resultados.....	41
4.1. Análisis por recta de regresión en Excel.....	42
4.1.1. Cerro Mocho.....	42
4.1.2. Moyobamba.....	46
4.1.3. Sechura.....	49
4.2. Análisis por Redes neuronales.....	53
4.3. Análisis con algoritmos genéticos.....	56
Conclusiones.....	63
Recomendaciones.....	65
Referencias bibliográficas.....	67
Anexos.....	69
Anexo A. Artículo presentado en el 2019 CHILEAN Conference on Electrical, Electronics, Engineering, Information and Communication Technologies, 2019, Chile. .....	71

### Lista de tablas

<b>Tabla 1.</b> Resultados al aplicar redes neuronales.....	54
<b>Tabla 2.</b> Resultados aplicando algoritmos genéticos.....	57



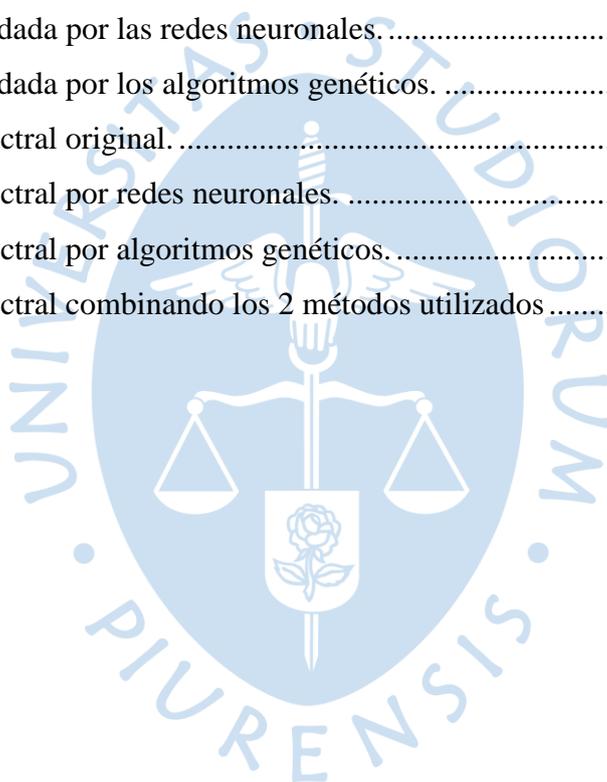


## Lista de figuras

<b>Figura 1.</b> Amplificación de deformación. ....	6
<b>Figura 2.</b> Partes de sensor de bulbo húmedo y seco.....	7
<b>Figura 3.</b> Dispositivo para medir la variable.....	7
<b>Figura 4.</b> Procedimiento.....	8
<b>Figura 5.</b> Esquema de tratamiento de una imagen hiperespectral antes de su evaluación. ....	10
<b>Figura 6.</b> Esquema del sistema de visión artificial.....	11
<b>Figura 7.</b> Recta de regresión.....	12
<b>Figura 8.</b> Ejemplos de rectas de regresión.....	14
<b>Figura 9.</b> Representación gráfica de la descomposición de la señal original.....	17
<b>Figura 10.</b> La neurona.....	17
<b>Figura 11.</b> Comparación entre una neurona biológica (izquierda) y una artificial (derecha). ..	19
<b>Figura 12.</b> Redes feedforward.....	21
<b>Figura 13.</b> Redes recurrentes.....	21
<b>Figura 14.</b> Red neuronal.....	22
<b>Figura 15.</b> Ejemplo de neurona con 2 entradas y 1 salida.....	22
<b>Figura 16.</b> Función de activación lineal.....	23
<b>Figura 17.</b> Función de activación sigmoidea.....	24
<b>Figura 18.</b> Función de activación tangente hiperbólica.....	24
<b>Figura 19.</b> Cruce de un punto.....	28
<b>Figura 20.</b> Cruce de dos puntos.....	29
<b>Figura 21.</b> Cruce uniforme.....	29
<b>Figura 22.</b> Introducción de la arena en el horno.....	33
<b>Figura 23.</b> Arena de las diferentes canteras sacadas del horno.....	34
<b>Figura 24.</b> 65 muestras de la Cantera de Moyobamba.....	34
<b>Figura 25.</b> 65 muestras de la Cantera de Sechura.....	34
<b>Figura 26:</b> 65 muestras de la Cantera de Cerro Mocho.....	35
<b>Figura 27.</b> Muestras de la Cantera de Moyobamba con cierto contenido de humedad.....	36

<b>Figure 28.</b> Muestras de la Cantera de Sechura con porcentaje de humedad. ....	36
<b>Figura 29.</b> Muestras de la Cantera Cerro Mocho con porcentaje de humedad. ....	36
<b>Figura 30.</b> Muestra de Arena de la Cantera de Sechura.....	37
<b>Figura 31.</b> Faja transportadora de la Cámara Hiperespectral.....	38
<b>Figura 32.</b> Conexión entre computadora y cámara Hiperespectral. ....	38
<b>Figura 33.</b> Programa SpectronPro.....	39
<b>Figura 34.</b> Firma Espectral.....	39
<b>Figura 35.</b> Firmas Espectrales de Cerro Mocho.....	41
<b>Figura 36.</b> Firmas Espectrales de Moyobamba.....	41
<b>Figura 37.</b> Firmas Espectrales de Sechura.....	42
<b>Figura 38.</b> Firmas Espectrales de Cerro Mocho.....	43
<b>Figura 39.</b> Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 393.35 de la Cantera de Cerro Mocho.....	43
<b>Figura 40.</b> Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 558.255 de la Cantera de Cerro Mocho.....	44
<b>Figura 41.</b> Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 725.247 de la Cantera de Cerro Mocho.....	44
<b>Figura 42.</b> Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 892.239 de la Cantera de Cerro Mocho.....	45
<b>Figura 43.</b> Recta de regresión para la longitud de onda de 558.255 de la cantera de Cerro Mocho.....	45
<b>Figura 44.</b> Firmas Espectrales de Moyobamba.....	46
<b>Figura 45.</b> Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 393.35 de la Cantera de Moyobamba.....	47
<b>Figura 46.</b> Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 558.255 de la Cantera de Moyobamba.....	47
<b>Figura 47.</b> Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 725.247 de la Cantera de Moyobamba.....	48
<b>Figura 48.</b> Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 892.239 de la Cantera de Moyobamba.....	48
<b>Figura 49.</b> Recta de regresión para la longitud de onda de 558.255 de la cantera de Moyobamba.....	49
<b>Figura 50.</b> Firmas Espectrales de Sechura.....	50

<b>Figura 51.</b> Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 393.35 de la Cantera de Sechura .....	50
<b>Figura 52.</b> Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 558.255 de la Cantera de Sechura .....	51
<b>Figura 53.</b> Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 725.247 de la Cantera de Sechura. ....	51
<b>Figura 54.</b> Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 892.239 de la Cantera de Sechura. ....	52
<b>Figura 55.</b> Recta de regresión para la longitud de onda de 558.255 de la cantera de Sechura. ....	52
<b>Figura 56.</b> Regresión dada por las redes neuronales. ....	54
<b>Figura 57.</b> Regresión dada por los algoritmos genéticos. ....	57
<b>Figura 58.</b> Firma espectral original. ....	60
<b>Figura 59.</b> Firma espectral por redes neuronales. ....	60
<b>Figura 60.</b> Firma espectral por algoritmos genéticos. ....	61
<b>Figura 61.</b> Firma espectral combinando los 2 métodos utilizados .....	61





## **Introducción**

El Perú se encuentra en una etapa de industrialización, una de las zonas en desarrollo es el de la construcción; como la de edificios, centros comerciales, viviendas, etc. Para su realización, el concreto es un elemento fundamental, debido a su permanencia, alta resistencia, impermeabilidad, facilidad de producción y economía.

El concreto se fabrica mezclando homogéneamente: cemento, agua, arena, grava y para casos especiales se adhieren aditivos. Dependiendo de la función que cumplirá el concreto, cada elemento tiene una medida que al fusionarse se obtendrán los requerimientos para cada caso.

Pero en el Perú, estas medidas se realizan de forma empírica lo que de una u otra forma afecta a las propiedades mecánicas del material. Por ello hemos decidido realizar un estudio para medir el porcentaje de humedad de los agregados del concreto, ya que influyen en las propiedades finales y dar una posible solución con el objetivo de acabar o finiquitar con ciertos problemas que a la larga traen muchas consecuencias económicas para diferentes empresas.

Para realizar el estudio nos hemos centrado en la arena, debido a sus características tales como la granulometría, módulo de finura, forma y textura de las partículas, así como el contenido de materia orgánica, el cual dichos factores juegan un papel decisivo en la calidad.



# Capítulo 1

## Generalidades

### 1.1. Antecedentes

El control de humedad en los agregados de concreto es un tema que hasta la actualidad no ha sido evaluado mediante las redes neuronales y algoritmos genéticos, estos sistemas de predicción se basan en datos reales para entrenarse, pudiendo así predecir de manera óptima el contenido de humedad.

Estos sistemas son compatibles con diferentes tipos de datos, en este caso se utilizarán imágenes hiperespectrales las cuales tienen la característica de obtener un alto número de imágenes monocromáticas de la misma escena en distintas longitudes de onda, las cuales proporcionan información espacial y espectral de la escena.

### 1.2. Planteamiento del problema

Actualmente, la producción del concreto no posee instrumentos para la medición en tiempo real de la humedad, sino se obtiene a través de métodos realizados en el laboratorio y esto ocasiona ciertas variaciones porcentaje en el contenido de humedad del concreto afectando a las propiedades del producto final.

### 1.3. Objetivos

#### 1.3.1. Objetivos Generales

- Aplicar redes neuronales y algoritmos genéticos para la predicción del porcentaje de humedad en agregados de concreto mediante el uso de imágenes hiperespectrales.

#### 1.3.2. Objetivos específicos

- Diseñar un sistema de redes neuronales que puedan predecir la humedad mediante el uso de imágenes hiperespectrales.

- Diseñar un sistema de algoritmos genéticos que potencien el sistema de redes neuronales, obteniendo así mejores resultados.
- Definir una metodología general para poder procesar y tomar los datos que serán utilizados para entrenamiento y validación del sistema.

#### **1.4. Elección de las muestras de trabajo**

El laboratorio de sistemas automáticos de control en colaboración con el laboratorio de suelos nos brindó el apoyo en la obtención de las muestras de arena de 3 ciudades del Perú: Moyobamba, Sechura y Cerro Mocho.

#### **1.5. Justificación del estudio**

El impacto social es que, si se logra proporcionar al concreto la cantidad exacta de humedad, las propiedades serán las requeridas, sin embargo, hoy en día, todo esto se hace de manera empírica, lo que ocasiona una alteración en las propiedades físicas del material haciendo que el tiempo de duración del elemento sea mínimo, es decir, de mala calidad. Además de no tenerse en cuenta, al momento de la dosificación de materiales, el agua prevista en el diseño podría resultar demasiada en la mezcla y aumentar la relación agua/cemento, aumentando la trabajabilidad, pero disminuyendo así la resistencia del concreto.

Y esto trae consecuencias económicas debido al gasto que se hará por los daños que sufrirá este material ya que, al no tener el valor de referencia, lo que se hace es ir desechando grandes cantidades de concreto. Por lo que es muy importante conocer la cantidad de porcentaje de humedad en el determinado momento en que se mezclará para formar el concreto, porque como se sabe, la humedad va variando conforme pase el tiempo debido a los efectos del drenaje y sería un gran paso conocer al instante para que así no exista equivocaciones sobre las propiedades físicas pensadas desde un inicio (valor de referencia).

Todo lo dicho anteriormente se resume en que, al saber los niveles de humedad de las materias primas, el fabricante no solo podrá conocer con exactitud el importe de agua que debe añadir a la mezcla, sino también la cantidad adecuada de cemento y áridos. Y esto es una gran ventaja ya que se va a poder ahorrar mucho dinero debido a que se reducirá los costes y los volúmenes de lotes rechazados.

## **Capítulo 2**

### **Marco teórico**

#### **2.1 Métodos de medición del porcentaje de humedad**

##### **2.1.1. Sensores de humedad**

Los procesos industriales se han ido modernizando a través del tiempo, ya que la calidad y cantidad de tecnología ha ido en aumento, por ello se logran tener cada vez sistemas óptimos y rentables. Es aquí donde aparece un área significativa llamada automatización, la cual abarca un rol muy importante debido a que está llegando a comprender más áreas de la ingeniería como es el caso de nuestro proyecto, medición de la humedad.

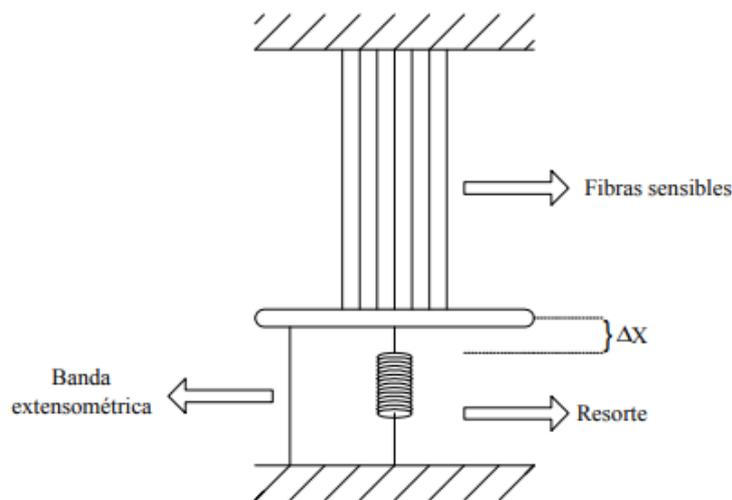
A continuación, presentaremos los sensores de humedad, en donde se explicará sus conceptos y variables relativas a ella. Con algunos de los que se mencionarán, nos hemos guiado para la realización de nuestro trabajo.

##### **2.1.2. Sensores mecánicos (por deformaciones):**

Esta herramienta permite beneficiarnos debido a las permutaciones en las dimensiones que resisten algunos tipos de materiales ante la presencia de humedad. Los materiales en los que estos cambios son más significativos son, por ejemplo: algunas fibras orgánicas y sintéticas (como el cabello humano).

Este se basa en que, al momento en el que se va incrementando la humedad relativa, las fibras aumentarán de tamaño, es decir, se alargarán.

Inmediatamente esta deformación debe ser amplificada (por palancas mecánicas, o circuitos electrónicos), y ajustada en función a la proporcionalidad y a la humedad relativa.



**Figura 1.** Amplificación de deformación.

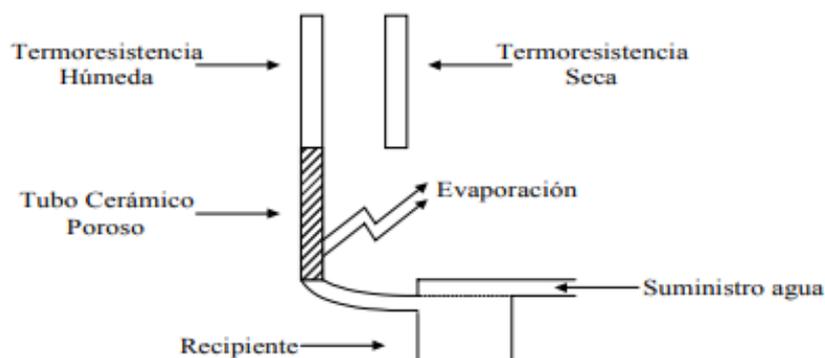
**Fuente:** Asociados, M. & M. (2008). Sensores de humedad, tipos y aplicaciones. 12.

### 2.1.3. Bulbos húmedo y seco

Este psicrómetro tiene como punto específico la medición de temperatura, debido a que será nuestro parámetro para inferir la cantidad de agua evaporada que se encuentra en una mezcla gaseosa.

La idea es colocar 2 termómetros, lo más parecido posible, con uno se debe calcular la temperatura de la mezcla (temperatura de bulbo seco), y con el otro, la temperatura en la superficie de una película de agua que se vaporiza de forma adiabática (temperatura de bulbo húmedo). Lo que hace el sensor es envolver el bulbo de uno de los termómetros con un algodón humedecido con agua. Las moléculas de agua que se encuentran en el algodón absorberán toda la energía necesaria para poder evaporarse del bulbo del termómetro, descendiendo así la temperatura a algunos grados comparado con la temperatura del termómetro seco. Lo que se obtenga de ambas variables nos va a permitir determinar la humedad relativa, ya que solo basta acudir a las ecuaciones, tablas o gráficos psicrométricos.

Actualmente esto se ha ido modernizando, ya que hoy en día no se utilizan algodones ni termómetros comunes, sino mechas que ciñen termo-resistencias (de platino) unidas con cualquier depósito de agua ya que gracias a la capilaridad siguen permaneciendo húmedas. Ahora se acude a utilizar instrumentos cerámicos porosos que rodean el bulbo y están en contacto con el agua.

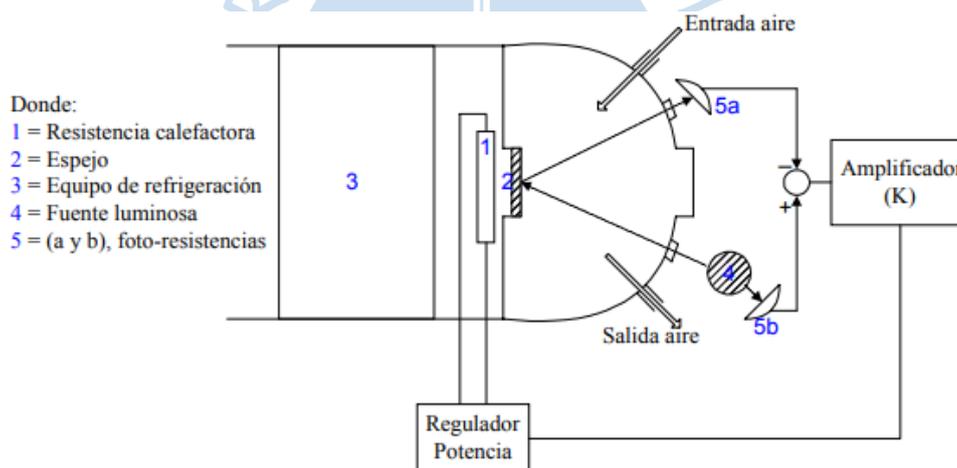


**Figura 2.** Partes de sensor de bulbo húmedo y seco.

**Fuente:** Kouro, S. (2001). Sensores De Humedad. Departamento de Electrónica, 25.

#### 2.1.4. Sensores por condensación

Otra variable que nos posibilita hallar la humedad relativa es la temperatura de punto de rocío. Para determinar esta variable se utiliza lo siguiente:



**Figura 3.** Dispositivo para medir la variable.

**Fuente:** Kouro, S. (2001). Sensores De Humedad. Departamento de Electrónica, 25.

Consiste en hacer transitar la mezcla gaseosa por una cámara que tiene en su interior un espejo. Esta mezcla puede ser enfriada o calentada por un equipo de refrigeración o calefactor correspondientemente, con la finalidad de conseguir que el vapor se condense en el espejo o, sino que el agua se evapore.

Este sistema es un control a lazo cerrado, el cual nos va a permitir tomar la temperatura en la superficie del espejo hasta llegar al punto de rocío, solo con la medida de este valor y con la ayuda de las ecuaciones, tablas o gráficos psicrométricos podemos llegar a obtener la humedad relativa.

### 2.1.5. Sensores infrarrojos

Las moléculas tienen movimientos rotatorios con respecto a su centro de masa, es decir no son estructuras rígidas e inmóviles. Asimismo, cuentan con movimientos vibratorios similares a un movimiento armónico simple. Ambas energías se encuentran cuantizadas, la rotatoria y la de vibración. Entonces para que la molécula se transporte de un determinado nivel energético a otro, va a requerir de un importe de energía específica, que es totalmente dependiente de la clase de molécula que se está mostrando. Y esto es lo que desarrolla la llamada “teoría de espectros moleculares”.

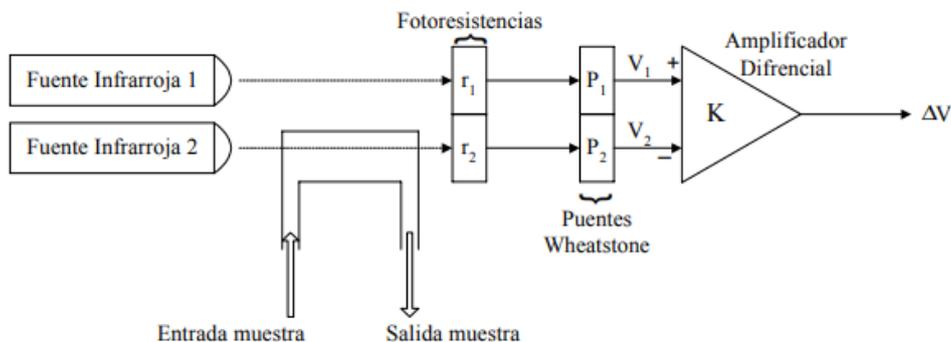
Dado que las ondas electromagnéticas tienen cantidades de energía dependiendo de la longitud de onda de estas, las moléculas absorberán o radiarán ondas de frecuencias, el cual su energía será semejante a las transformaciones energéticas que se den en la molécula. La ecuación matemática que nos ayuda a calcular la energía que posee una onda es la siguiente:

$$E = h\nu = \frac{hc}{\lambda}$$

Donde:

- E, energía.
- $\nu$ , frecuencia.
- $\lambda$ , longitud de onda.
- h, constante de Planck =  $6.63 \times 10^{-34} [\text{J} \cdot \text{s}]$ .

Si se analiza el caso del agua, una de las radiaciones que absorbe, está ubicado en la porción infrarroja del espectro, de manera más específica en el rango de  $\lambda = 1400 [\eta\text{m}]$  y  $\lambda = 1930 [\eta\text{m}]$ . La idea es disparar una fuente de rayos infrarrojos a la muestra a medir, y reunir en el otro extremo la radiación resultante, utilizando un receptor apropiado para tal intención.



**Figura 4.** Procedimiento.

**Fuente:** Kouro, S. (2001). Sensores De Humedad. Departamento de Electrónica, 25.

Se dispone de 2 fuentes infrarrojas similares (1 y 2), la primera se toma como referencia y se logra medir con una foto-resistencia ( $r_1$ ), la segunda cruza la muestra con vapor de agua, el cual absorbe cierta parte de la radiación e incide en el otro detector ( $r_2$ ), estos valores resistivos son transformados a voltaje gracias a los puentes de Wheatstone, para de esta manera ser comparados con un amplificador diferencial. La diferencia entre ellos va a ser proporcional a la cantidad de humedad existente en la muestra, consiguiendo así una medida de la variable deseada.

## **2.2 Cámara hiperespectral**

### **2.2.1. Sistemas hiperespectrales**

Es una herramienta que tiene como finalidad convertir la energía reflejada de un medio. Este sistema cuenta con un determinado proceso en el que desarrolla una serie de etapas analógicas y digitales de filtrado, cabe recalcar que también realiza un acondicionamiento de señales. Los datos se procesan con el objetivo de conseguir características y modelos, para de esta manera poder predecir muchas capas de información.

Los sistemas hiperespectrales surgen en el campo de la investigación del censo remoto para la observación de la tierra a través de sensores hiperespectrales, años después se expandió rápidamente a la tecnología alimentaria, desarrollándose en las últimas décadas en la detección de daños en la fruta.

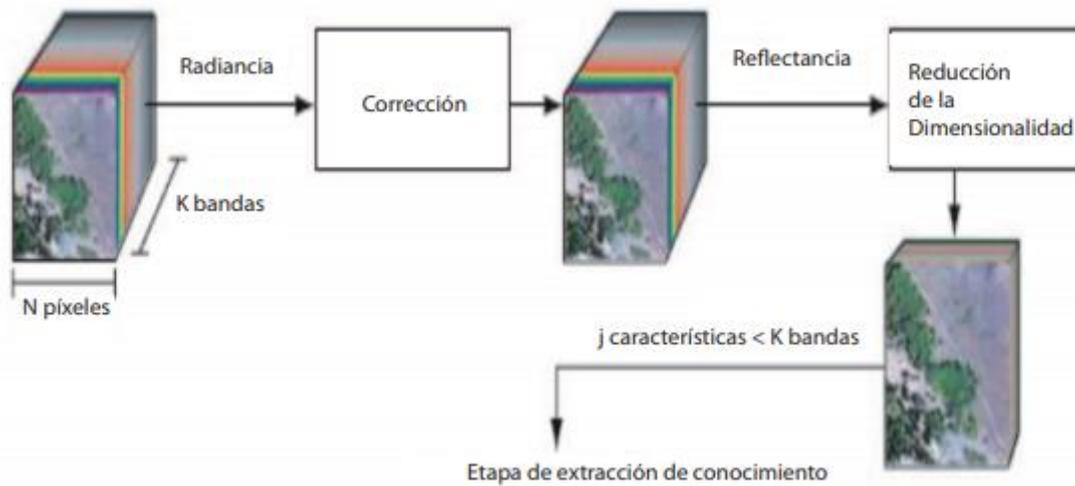
Estos se caracterizan por dar como resultado un alto número de imágenes monocromáticas de la misma escena en diferentes longitudes de onda, estas imágenes suministran información espacial y espectral de la escena.

Tienen dos partes diferenciadas las cuales son: el sistema de adquisición de imagen y un sistema que escoge la longitud de onda que incide en el CCD. Los filtros pueden regular la frecuencia de radiación que emiten.

### **2.2.2. Procesamiento de imágenes hiperespectrales**

La información que se obtiene mediante las imágenes hiperespectrales es mucho mayor a la que se obtiene con una imagen convencional. Está formada por un grupo de imágenes monocromáticas las cuales se unen formando un hipercubo, en donde dos dimensiones son las dimensiones espaciales y la tercera en la espectral. Pero este exceso de información puede ser un problema pues se podría obtener información redundante o que no es necesaria para la clasificación requerida.

Al analizar imágenes hiperespectrales sin una previa reducción de información, se analiza la radiancia de la escena, cuando mayormente, lo que se desea es la reflectancia, es por esto que primero se deben realizar, en la medida de lo posible, compensaciones.



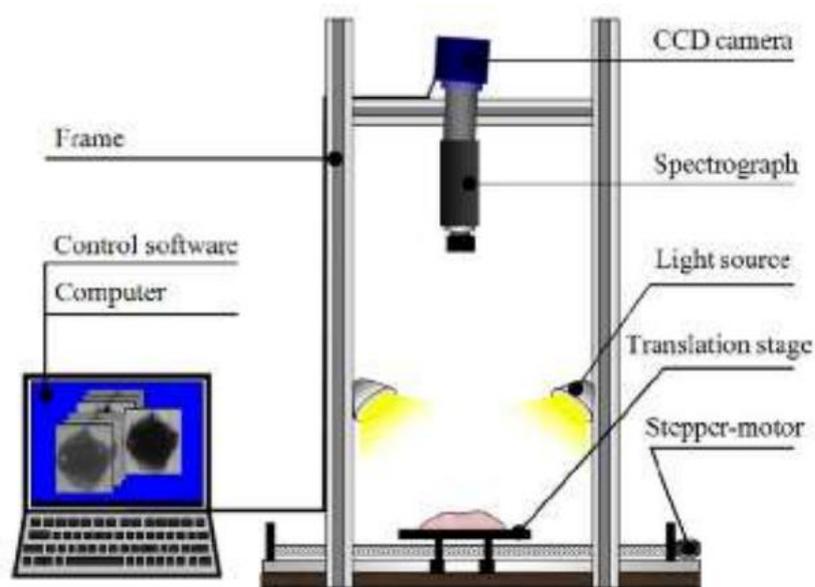
**Figura 5.** Esquema de tratamiento de una imagen hiperespectral antes de su evaluación.

**Fuente:** Shaw and Bruke, 2003.

La compensación varía dependiendo del modo en que se adquiere las imágenes hiperespectrales, si se obtiene desde un satélite se debe tener en cuenta los efectos dispersivos de la atmósfera, pero si los parámetros de iluminación son controlados y se conoce la forma del objeto, la compensación se da mediante un blanco de referencia y el modelo de elevación digital respecto a la forma del objeto.

La selección de características se basa en obtener un reducido número de características en el espacio vectorial que tenga la mayor información del problema estudiado. La construcción de clasificadores y el entrenamiento conforman un problema abierto para la selección de información. Antes de construir un clasificador se deben encontrar las características más significativas, si no es así pueden introducir ruido generando resultados erróneos.

Una imagen hiperespectral, en términos computacionales, se puede definir como un arreglo de 3 dimensiones, un cubo de información ( $N \times M \times P$ ).  $N$  y  $M$  describe la resolución espacial y el tamaño de la imagen, el  $P$  la resolución espectral (número de bandas).



**Figura 6.** Esquema del sistema de visión artificial.

**Fuente:** Yao-Ze Feng, et al., (2013).

Está compuesto por:

- Cámara CCD.
- Espectrógrafo.
- Fuente de luz.
- Un sistema de traslación accionado por un motor paso a paso.
- Estructura de soporte.
- Computadora con software de control para la adquisición de las imágenes.

### 2.3 Metodologías de predicción

La automatización de los procesos productivos se define como una herramienta primordial que permite un desarrollo dinámico, además facilita la relación entre las diferentes variables. Por lo que fue transcendental encontrar un correcto procedimiento, es decir, adecuado y eficaz, para así lograr el objetivo del proyecto.

Por ello, el análisis se centró en sistemas de aprendizaje automático, es decir, aquellos que utilizan inteligencia artificial, los cuales están compuestos de varios algoritmos con la finalidad de hallar un comportamiento generalizado, fijando patrones en una base de datos, es decir que clasifiquen, predigan e identifiquen modelos, según sea el caso.

Este paso tiene mucha importancia cuando no se tiene un modelo matemático, por lo cual es muy difícil modelarlo.

### 2.3.1 Rectas de regresión

Son aquellas rectas que se ajustan a la nube de puntos (o también llamado diagrama de dispersión) generada por una distribución binomial. Matemáticamente, son posibles dos rectas de máximo ajuste:

La recta de regresión de Y sobre X:

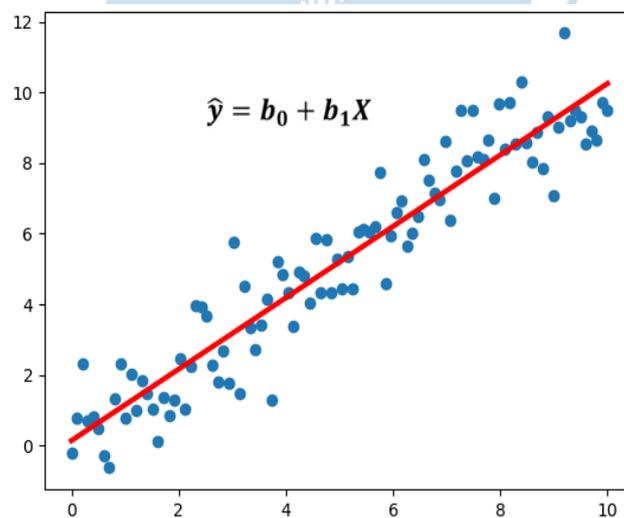
$$Y = \bar{Y} + \frac{\sigma_{XY}}{\sigma_X^2}(X - \bar{X})$$

La recta de regresión de X sobre Y:

$$x = \bar{X} + \frac{\sigma_{XY}}{\sigma_Y^2}(Y - \bar{Y})$$

Para poder estimar el valor de tiene una variable a partir de otra independiente dados unos datos previos, se utiliza la recta de regresión, siempre y cuando las estas estén relacionadas de forma dependiente.

Los valores de las variables se pueden representar a través de una nube de puntos, por tanto, la recta de regresión es el modelo lineal que se acerca más a la relación entre las variables.



**Figura 7.** Recta de regresión.

**Fuente:** Laguna, C. (2014). Correlación y regresión lineal. Instituto Aragonés de Ciencias de la Salud, 1-18.

La recta de regresión tiene carácter de línea media, en otros términos, sintetiza la información proveída por las cifras. Si tiene carácter de línea media (de promedio), deberá ir de la mano de una medida que nos proporcione su representatividad ya que el haber obtenido la mejor de todas no da garantías de que sea la idónea. Es por ello por lo que se necesita una

medida de dispersión, que considere la dispersión de cada observación con respecto a la recta, es decir, lo separado que se encuentra cada punto de la recta. En sí, se tiene que evaluar los errores.

Concluimos que, si las dispersiones son mínimas, la recta será una gran representante de la nube de puntos, es decir, la bondad de ajuste del modelo será alta. Si la dispersión es considerable, la bondad de ajuste será baja. Una manera de calcular lo mencionado antes es evaluando la suma de los cuadrados de los errores. Y esto se llama Varianza residual y se representa de la siguiente manera:

$$S_e^2 = \frac{\sum_{i=1}^n (Y_i - Y_i^*)^2}{n}$$

Si esta es grande, se puede decir que el modelo no es el adecuado, es decir, la recta no manifestará el comportamiento general de la nube. La fórmula práctica para calcular la varianza residual, si es que el método es el de los mínimos cuadrados, es el siguiente:

$$S_e^2 = \frac{\sum_{i=1}^n Y_i^2 - a \sum_{i=1}^n Y_i - b \sum_{i=1}^n X_i Y_i}{n}$$

La cota máxima de la varianza residual es la varianza que tratamos de explicar mediante el modelo de regresión. Por tanto, sin más que hacer relativa la varianza residual respecto de su máximo valor, y 365 multiplicando por 100, obtendremos el porcentaje de variaciones no explicado por el modelo:

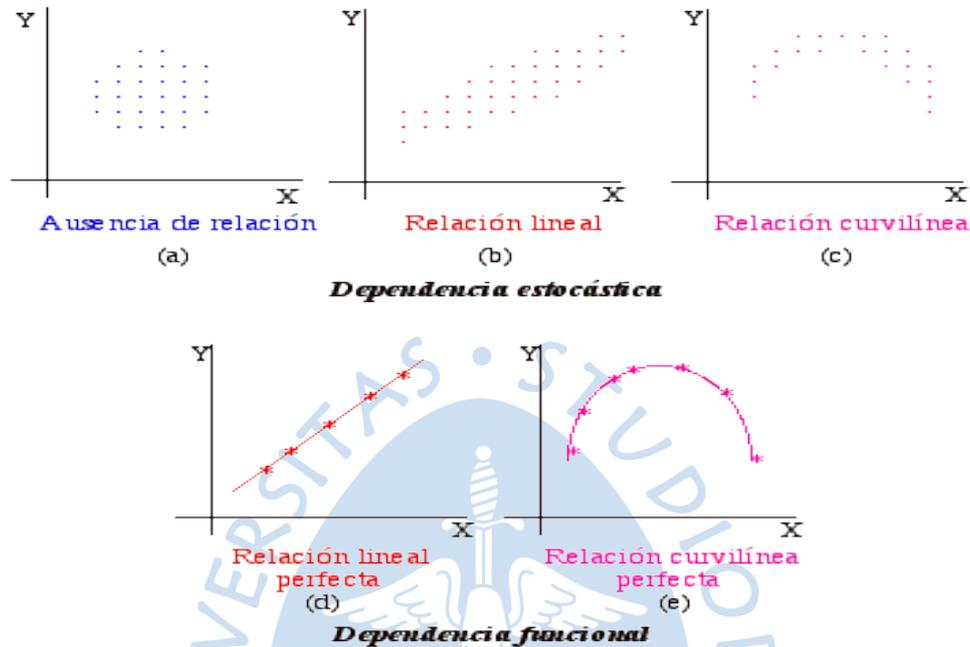
$$\% \text{ de variaciones sin explicar} = \frac{S_e^2}{S_Y^2} 100$$

Ahora, ya se puede obtener una media que nos proporcione el porcentaje de variaciones controladas mediante el modelo, que se conoce como Coeficiente de Determinación:

$$R^2 = 1 - \frac{S_e^2}{S_Y^2}$$

Por lo tanto: Si  $0 < R^2 < 1$ . Por tanto, si  $R^2 = 1$  significa que no habrá residuos. Mientras más se acerque dicho valor a la unidad, mejor será el modelo de regresión.

Si  $R^2 = 0$ , X no explica en absoluto ninguna de las variaciones de la variable Y, de modo que o bien el modelo es inadecuado, o bien las variables son independientes. Cuanto más cercano a 0 esté dicho valor, el modelo no será eficiente.



**Figura 8.** Ejemplos de rectas de regresión.

**Fuente:** Laguna, C. (2014). Correlación y regresión lineal. Instituto Aragonés de Ciencias de la Salud, 1-18.

## 2.3.2 Phyton

Es un lenguaje de programación que se basa en una sintaxis que beneficie un código legible. Está basado en una programación orientada a objetos, imperativa y funcional. También, es catalogado como un lenguaje de un nivel muy alto debido a que comprende algunas estructuras implícitas de datos como listas, diccionarios, conjuntos y tuplas, lo cual nos ayuda a ejecutar algunas tareas difíciles en pocas líneas de código.

### 2.3.2.1. Métodos realizados con Phyton

#### Reducción de dimensionalidad y transformada Wavelet

Es de vital importancia tener en cuenta los tiempos de cálculo, lo cual permite buscar posibles soluciones y estrategias que nos ayuden a reducir la gran dimensionalidad implícita en una imagen hiperespectral. Hay muchas variaciones no deseadas que resultan de la física, interacciones ambientales o errores en los instrumentos durante la toma de datos, en algunos casos puede aminorar la robustez y precisión de la predicción del modelo.

Cuando los modelos cuentan con un gran número de características, la precisión y eficacia de los algoritmos tiende a disminuir. Esto se da generalmente cuando dichas características no brindan información relevante al sistema.

Algunas posibles causas se dan debido a la degradación de los datos causado por ruidos, disturbios, inadecuada calibración y excesiva dimensionalidad. Pero, si los datos que se obtienen son de ambientes controlados sumándole una adecuada calibración, se pueden conseguir datos de calidad; sin embargo, los problemas de alta dimensionalidad pueden seguir presente, generando un sub-entrenamiento o sobre entrenamiento.

### **Transformada Wavelet (TW)**

Es una evolución de la transformada Fourier, es decir es una extensión de ella. La TW surge para mejorar las debilidades de la Transformada de Fourier que tiene en el dominio del tiempo. Debido a que la Transformada de Fourier (TF) fue pensada para señales permanentes, periódicas e infinitas. En el campo de la frecuencia no existe información del tiempo; por ello es utópico determinar en qué periodo de tiempo tiene lugar un suceso particular a una frecuencia determinada.

El análisis *Wavelet* es un procedimiento que nos da la facultad de poder representar, descomponer y reconstruir una señal, donde se puede presentar cambios muy significativos en sus componentes de tiempo y frecuencia en forma repentina; pero gracias al análisis multiresolución con ventanas de longitud variable, estas logran adaptarse al cambio de frecuencia.

En cambio, la TF representan las funciones en base de senos y cosenos de permanencia infinita, mientras que la TW representa en base a funciones localizadas en frecuencia (dilatación) y en el tiempo (traslación).

### **Wavelet discreta**

Actualmente la adquisición de señales y datos son de tipo digitales, es decir se dispone de una data que es digital y esta es proveniente de sistemas de instrumentación, por ello es de suma importancia contar con una herramienta matemática que pueda trabajar con señales digitales, es decir analizarlas. Por ello surge la necesidad de aprovechar la Transformada *Wavelet* Discreta (DWT). La DWT es una formulación matemática que transforma un arreglo de datos de dimensión en otro vector de coeficientes.

La transformada *wavelet* continua, muestra 2 tipos de coeficientes (u, s), entonces es necesario llevar estos dos coeficientes a un plano discreto.

$$s = a^i$$

$$u = kna^i$$

El término  $a^i$  menciona a un paso de dilatación fijo,  $i$  y  $k$  son enteros. Entonces esto se reemplaza en la ecuación de la WM:

$$\psi_{i,k}(t) = a^{-i/2} \psi(a^{-i}(t - kna^i))$$

$$\psi_{i,k}(t) = a^{-i/2} \psi(a^{-i}t - kn)$$

El factor de escala  $s$  puede ser empleado para identificar singularidades de las señales, es decir, puede expandir o contraer el ancho de la ventana de análisis. El valor de  $u$  representa en que parte de la señal se está analizando.

La DWT se expresa como:

$$DW_f = \int_{-\infty}^{\infty} f(t) \psi_{i,k}(t) dt$$

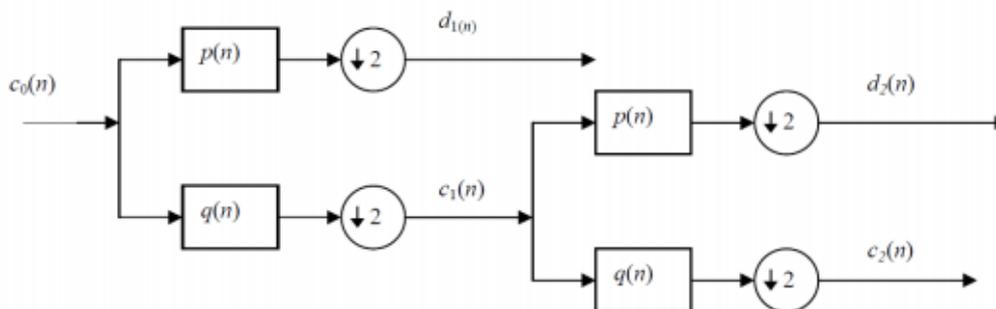
Se puede constituir la función  $(t)$  en función de la sumatoria de los coeficientes wavelet discretos multiplicados por las funciones base.

$$f(t) = \sum \sum Wf(s, u) s u \psi_{u,s}(t)$$

Basado en la Transformada *Wavelet*, la reconstrucción de la señal no contiene información redundante; por lo tanto, al utilizar estos planteamientos, el problema de sobre dimensionalidad queda resuelto.

### Reconstrucción de señal

La Transformada *Wavelet* se desarrolla como una serie de filtros agrupados por etapas, denominado “Niveles de descomposición”. Cabe resaltar que en cada etapa se encuentran dos procesos: filtrado para alta frecuencia y para baja frecuencia. Cada proceso de filtrado adquiere coeficientes de detalle y aproximación.



**Figura 9.** Representación gráfica de la descomposición de la señal original.

**Fuente:** Cherre Pupuche, C. V. (2019). Medición de parámetros de calidad de harina de pescado usando imágenes hiperespectrales e inteligencia artificial.

El proceso denominado como  $p$  en donde se cita a un filtro de alta frecuencia y el proceso  $q$  a un filtro de baja frecuencia. Se debe tener en cuenta el orden de coeficientes,  $c_0$  es la señal original,  $c_i$  se refiere a los coeficientes de aproximación y  $d_i$  a los coeficientes de detalle. Se puede reconstruir la señal usando la ecuación discreta de  $c$  se expresa como:

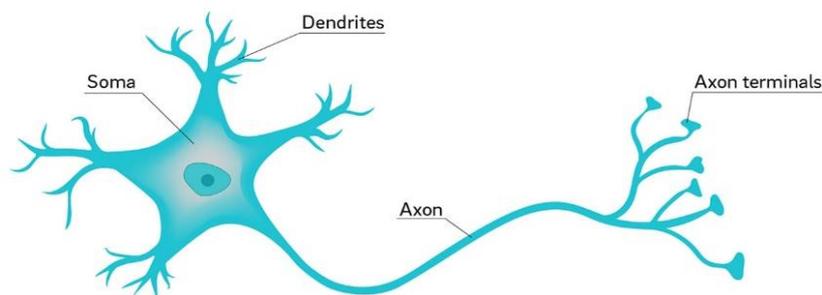
$$c_{i-1}(n) = 2^{\frac{-1}{2}} \sum_k c_i(k) p(n - 2k) + 2^{\frac{-1}{2}} \sum_k d_i(k) q(n - 2k)$$

### 2.3.3. Redes Neuronales

En primer lugar, es de suma importancia recalcar que las neuronas son células muy especializadas y su finalidad es emitir y recibir señales eléctricas en el cuerpo.

Su funcionamiento es el siguiente: Esta es excitada por medio de múltiples entradas (inputs) y cuando consigue un cierto umbral, la neurona se activa de tal manera que envía la señal al axón, encargada de enviar los impulsos nerviosos hacia las otras células.

#### Neuron



**Figura 10.** La neurona.

**Fuente:** Córdoba, F. (2005). Fundamentos biológicos del aprendizaje y la memoria. Universidad de Huelva.

La red neuronal (ANN) trata básicamente en modelar el funcionamiento de estas células, en donde lo que se busca primordialmente es imitar diferentes características innatas de los humanos, como por ejemplo la aptitud de memorizar y en base a esto asociarlo con diferentes hechos diarios.

La característica principal de ANN es la forma en que se retiene la información que se le suministra porque la memoria se encuentra distribuida en todas las conexiones de la red que uno diseña.

Lo que se quiere en un principio es que cuando el diseño que se ha elaborado reciba una entrada parcial, la red elija la entrada semejante que ha guardado en memoria y así esta pueda generar una salida que pertenezca a la señal que se introdujo al principio, pero para que ocurra esto es que, una vez diseñada la red, se tiene que entrenar para que así pueda almacenar en memoria la imagen que se le muestra.

#### **2.3.3.1. Tolerancia a fallas**

Las redes neuronales tienen la facilidad de estudiar patrones con interferencias, ruidos, etc. y así no logra afectar a los datos que en primera instancia se quiere analizar.

Estas tienen la habilidad de realizar la función que crean necesaria a pesar de que se destruya una parte de la red.

La razón primordial por la que las redes neuronales son resistentes a diversas fallas es debido a que poseen su información fraccionada en las conexiones entre neuronas, existiendo cierto grado de reiteración en este tipo de acumulación. La mayoría de las interconexiones entre los nodos de la red tendrán sus valores en función de los estímulos que han ido recibiendo, y se generará un patrón de salida que represente la información que poco a poco se ha almacenado.

#### **2.3.3.2. Elementos que componen una red neuronal**

Las redes neuronales conectadas entre sí poseen múltiples disposiciones, estas disposiciones son de tipo de capa o formaciones de neuronas, estas se ubican entre las entradas y salidas del sistema.

Es importante conocer el número de capas, el número de neuronas por capa; los procesos de selección que influyen directamente en la garantía del sistema con redes neuronales.

Los sistemas multicapa son los más habituales para llevar a cabo sistemas de predicción y se caracterizan por tener un grupo de neuronas agrupadas, para determinar a qué capa pertenece cada grupo de neuronas es necesario observar las entradas y salidas de las neuronas.

Existen grupos que encierran a ciertos tipos de capas y se clasifican en tres: capa de entrada, capas ocultas y capa de salida, la primera es un conjunto de redes neuronales que se encargan de recibir y procesar la información de entrada, esta capa realiza un procedimiento de extracción de características, las capas ocultas son las encargadas de la mayor parte de la generalización del modelo y por último la capa de salida muestra las variables de predicción, para el caso de clasificación se tienen valores binarios o discretos en las salidas y para el caso de regresión se tienen valores numéricos flotantes .



**Figura 11.** Comparación entre una neurona biológica (izquierda) y una artificial (derecha).

**Fuente:** Cachipueno Amagua, L. F. (2016). Estimación de la potencia producida por módulos fotovoltaicos en base a Redes Neuronales Artificiales y comparación con metodologías basadas en Regresiones Múltiples (Bachelor's thesis, Quito, 2016.).

### 2.3.3.3. Clasificación de las redes Neuronales Artificiales

Las redes neuronales pueden clasificarse de distintas maneras, una de ellas es de acuerdo con la función que van a realizar, por ejemplo, agrupación de patrones, la dirección de la información (recurrente y no recurrente). Una gran cantidad de redes y modificaciones, se desarrollan constantemente. Se mencionan una de las redes más utilizadas.

**Redes de Hopfield:** Es una red simétrica de dos capas completamente conectada, que actúa como una memoria asociativa no lineal, que puede resolver eficazmente problemas de optimización. Esta red solo es adecuada para entradas bipolares o binarias, y el aprendizaje se realiza configurando cada peso para conectar dos neuronas al producto de las entradas de estas dos neuronas.

**Redes Backpropagation:** Es una multicapa perceptrón, consta de una capa de ingreso con nodos que representa las variables de entrada al problema, una capa de salida con nodos que simbolizan las variables dependientes y una o más capas ocultas que contienen nodos para ayudar a capturar la no linealidad en los datos. El término retropropagación se refiere a la forma en que se calcula el error, ya que se propaga hacia atrás desde la capa de salida, a la capa oculta, y finalmente a la capa de entrada. En BP-ANN, los datos se envían a la red sin retroalimentación. Estas redes son tan versátiles y se puede utilizar para modelado de datos,

clasificación, previsión, control, compresión de datos e imágenes y patrones reconocimiento (Hassoun 1995).

**Redes de feedforward:** Una Red neuronal *feedforward* se caracteriza por ser un conjunto de neuronas que reciben información multivariable, la procesan y dan una respuesta, la cual así mismo puede ser multivariable. Es de suma importancia mencionar que las redes *feedforward* son las más asequibles en cuanto a implementación y simulación, sin embargo, su trabajo es genial para aplicaciones en que no se quiera que la red detenga información de eventos anteriores como ayuda para evaluar eventos futuros. En la arquitectura *feedforward* la topología del arreglo de neuronas y sus interconexiones hace circular los datos en una sola dirección con el objetivo de que nunca pueda pasar más de una vez a través de una neurona antes de generarse la respuesta de salida.

Se puede decir que el trabajo de la red es ingresar los datos por medio de las neuronas de la capa de entrada, y al momento de transmitir la información a la siguiente capa, llamada oculta, todas las neuronas receptoras van a obtener la suma ponderada de cada una de las entradas conectadas a ella. Puesto que cada conexión entre neuronas representa cualquier peso de conexión.

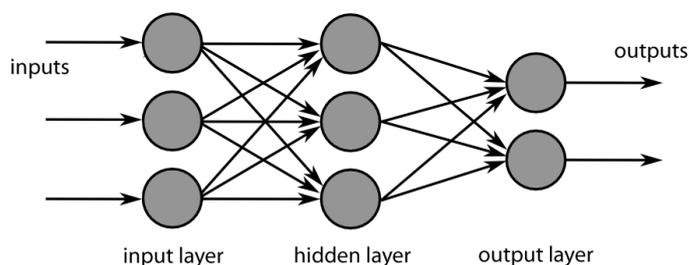
$$\sum_j W_{ij} X_j$$

Donde  $W_{ij}$  son los pesos de cada conexión de las  $X_j$  neuronas a la neurona receptora. Pero, al igual que sucede con las neuronas biológicas reales, a menos que el estímulo tenga cierta magnitud, la información se procesa, de lo contrario se ignora. Por ello, para que esto suceda es necesario un valor umbral  $m_i$  y a menos que la suma ponderada supere un valor dado, se considera la salida efectiva de la información procesada.

$$\sum_j W_{ij} X_j - m_i$$

**Redes recurrentes:** Su complejidad es alta a comparación con una red *feedforward*, ya que en esta última la red únicamente es capacitada para emitir los diferentes datos hacia las siguientes capas, resultando en un efecto de propagación hacia atrás en el tiempo. Las redes neuronales recurrentes, por otro lado, ejecutan el intercambio de información entre neuronas de una forma más compleja y por sus características, dependiendo del tipo de algoritmo de

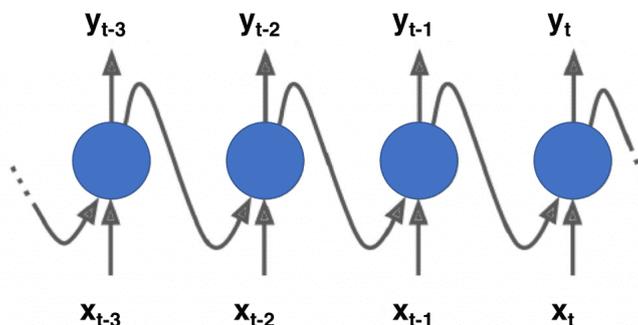
entrenamiento que se elija, pueden expandir la información hacia delante en el tiempo, lo cual iguala a predecir eventos.



**Figura 12.** Redes feedforward

**Fuente:** Llano, L., Hoyos, A., Arias, F., & Velásquez, J. (2007). Comparación del Desempeño de Funciones de Activación en Redes Feedforward para aproximar Funciones de Datos con y sin Ruido. *Avances en Sistemas e Informática*, 4(2).

La red es característica porque la salida de algunas de sus neuronas se retroalimentan a las neuronas a sí mismas las neuronas de la capa anterior. De esta forma, la información se puede transmitir en ambas direcciones. Para proporcionar memoria dinámica para ANN. La red neuronal BP recursiva es una variante simple de la red recurrente en la que se introduce "memoria" Redes neuronales artificiales.



**Figura 13.** Redes recurrentes

**Fuente:** Cruz, Isis Bonet, et al. "Redes neuronales recurrentes para el análisis de secuencias." *Revista Cubana de Ciencias Informáticas* 1.4 (2007): 48-57.

**Redes de counterpropagación:** Estas redes están capacitadas por aprendizaje para crear una tabla de búsqueda organizada para la función de aproximación y clasificación. El aprendizaje se lleva a cabo para crear un mapa *Kohonen* de la entrada datos. Mientras tanto, el aprendizaje supervisado se utiliza para asociar un vector de salida apropiado con cada punto en el mapa. Una vez la red ha sido entrenada, cada característica recién presentada desencadenará una respuesta que es el promedio para aquellos vectores de características más cercanos a este.

### 2.3.3.4. Funciones de las redes neuronales

#### Función de entrada (input function)

Como se sabe, en las neuronas ingresan demasiada información (valores de entrada) como si estas fueran uno solo, a esto se le denomina “entrada global” (gin), el gran problema es cómo se puede combinar las entradas simples que introducimos en la red diseñada con la entrada global, y esto se logra gracias a la función de entrada. En la figura 14 nuestra neurona de interés es la  $y_j$ . Las neuronas  $X_i$  son las que proporcionan señales de entrada,  $W_{ji}$  son los pesos sinápticos. Lo que se hace aquí es multiplicar lo mencionado anteriormente ( $W_{ji}$ ) con su entrada respectiva.

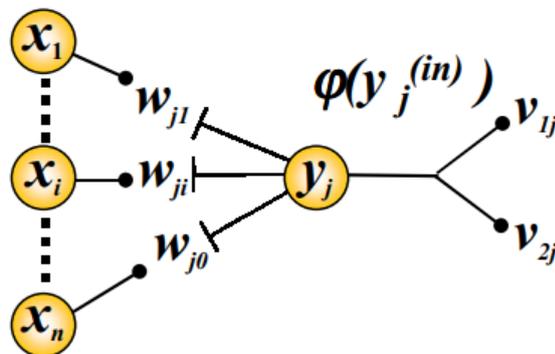


Figura 14. Red neuronal.

Fuente: López, S. T., Cuza, M. L. A., Pérez, P. Y. P., & Diéguez, L. A. P. (2016). Red neuronal multicapa para la evaluación de competencias laborales. Revista Cubana de Ciencias Informáticas, 10, 210-223.

Función de entrada =  $(X_{i1} \times W_{j1}) * (X_{i2} \times W_{j2}) * \dots (X_{in} \times W_{jn})$ , La \* es el operador apropiado, por ejemplo, sumatoria, producto, etc.

$$X_{i1} = I_{n1}$$

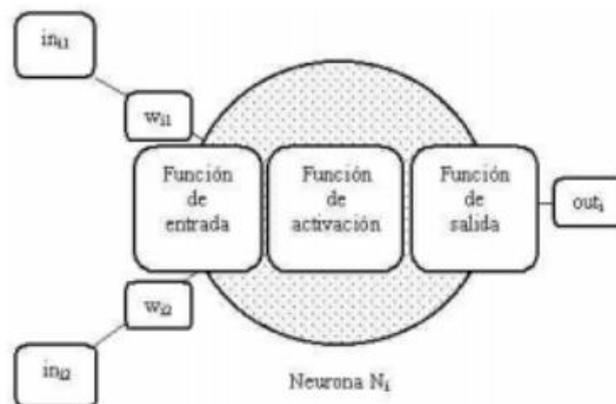


Figura 15. Ejemplo de neurona con 2 entradas y 1 salida.

Fuente: Matich, D. J. (2001). Redes Neuronales: Conceptos básicos y aplicaciones. Universidad Tecnológica Nacional, México.

## Función de activación (activation function)

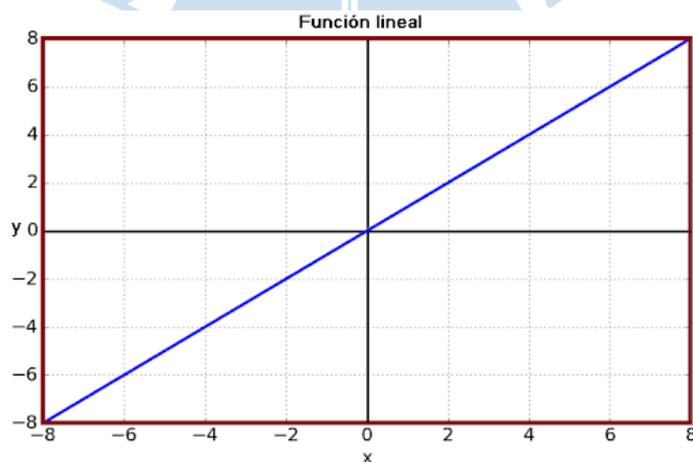
El cerebro biológico aprende mediante la alteración de la intensidad de las conexiones sinápticas mismas. En los algoritmos se emula añadiendo también una función de activación. Esta función se encarga de determinar si la neurona se encuentra activa o inactiva, pero esto lo hace transformando la entrada global en un estado de activación, el cual habitualmente se encuentra en un rango de 0 a 1 o de -1 a 1, y esto es así porque la neurona puede estar de manera inactiva en 0 o -1 o activa 1.

Las funciones más usuales son:

### Función lineal

$$F(x) = \begin{cases} -1, & x \leq -1/a \\ a*x & -1/a < x < 1/a \\ 1 & x \geq 1/a \end{cases}$$

con  $x = g_{ini} - \Theta$



**Figura 16.** Función de activación lineal

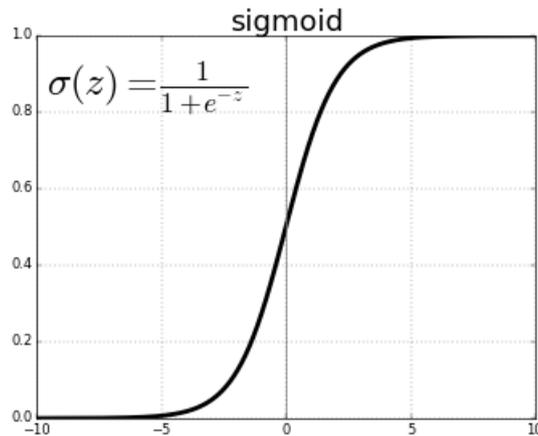
**Fuente:** Matich, D. J. (2001). Redes Neuronales: Conceptos básicos y aplicaciones. Universidad Tecnológica Nacional, México.

La salida que resulta de la función de activación será:  $a*(g_{in} - \Theta_i)$ , cuando el argumento de  $(g_{in} - \Theta_i)$  está en el rango de  $[-1/a, 1/a]$ . Por encima o por debajo de esta zona se fija la salida en 1 o -1, respectivamente. Cuando  $a = 1$ , la salida es igual a la entrada.

### Función sigmoidea

$$F(x) = \frac{1}{1+e^{-gx}}$$

con  $x = g_{ini} - \Theta$



**Figura 17.** Función de activación sigmoidea.

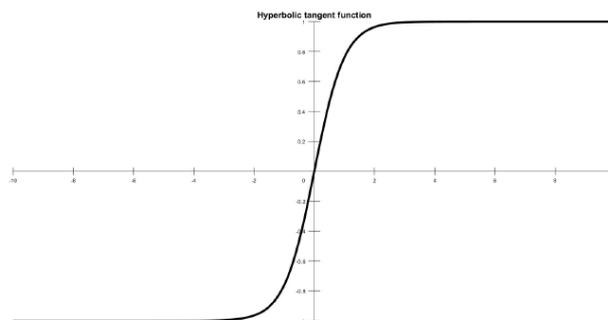
**Fuente:** Matich, D. J. (2001). Redes Neuronales: Conceptos básicos y aplicaciones. Universidad Tecnológica Nacional, México.

Los valores de salida que proporciona esta función están en el rango de 0 a 1. Al alterar el valor de  $g$  se ve afectada la pendiente de la función de activación.

### Función tangente hiperbólica

$$F(x) = \frac{e^{gx} - e^{-gx}}{e^{gx} + e^{-gx}}, \text{ con } x = \text{gini} - \Theta$$

La salida de la función tangente hiperbólica está en el rango de -1 a 1. Al cambiar el valor de  $g$  se ve afectada la pendiente de la función de activación.



**Figura 18.** Función de activación tangente hiperbólica.

**Fuente:** Matich, D. J. (2001). Redes Neuronales: Conceptos básicos y aplicaciones. Universidad Tecnológica Nacional, México.

### Función de salida (output function)

Esta función depende mucho del umbral, debido a que si no llega al valor que se ha impuesto al umbral no habrá salida debido a que la neurona se comportará como inactiva. Los valores de salida están entre  $[0, 1]$  o  $[-1, 1]$ . Se puede dar el caso que sean binarios  $[0, 1]$  o  $[-1, 1]$ .

Existen dos tipos de salidas habituales:

Ninguna: Es cuando el valor de la salida es igual a la de entrada. A esta también se le llama función identidad.

$$\bullet \text{ Binaria: } \begin{cases} 1, & \text{si } act_i \geq \xi_i \\ 0, & \text{de lo contrario} \end{cases} \quad \xi_i \rightarrow \text{Umbral.}$$

## 2.4 Algoritmos genéticos

Si es que se quiere hablar sobre algoritmos genéticos, es muy importante destacar a John Holland, el cual en el año 1962 coloca las bases para sus posteriores investigaciones hasta así llegar a lo que por lo que hoy se conoce como “algoritmos genéticos”.

Los algoritmos genéticos son una serie de métodos adaptativos usados en la búsqueda y optimización de parámetros, que imita la teoría de la evolución biológica de Darwin con la finalidad de resolver los problemas, es decir, se basan en la mecánica de selección y genética natural. Para todo esto, se tiene que partir de una población inicial de la cual se escogen aquellos individuos más capacitados para luego reproducirlos y mutarlos con el objetivo de obtener la siguiente generación de individuos que de una u otra manera estarán más adaptados que la anterior generación.

### 2.4.1 Esquema básico

Para poder aplicar este algoritmo para la resolución de problemas se tiene que hacer una serie de pasos.

En primer lugar, se debe de obtener un gran tamaño de población para así garantizar muchas soluciones. Lo que se sugiere es que dicha población se genere de forma aleatoria ya que si no se hace de esa manera se deberá tener en cuenta una cierta diversidad en la población generada. Los pasos son:

- Estimar la calificación de cada uno de los cromosomas que se han generado.
- Aprobar la reproducción de todos los cromosomas siendo los más idóneos los que tengan más expectativa de reproducirse.
- Con cierta probabilidad de mutación, mutar un gen del nuevo individuo generado.
- Establecer la nueva población.

### 2.4.2. Parámetros de los algoritmos genéticos

#### Tamaño de la Población

Nos da el número de cromosomas que tiene la población. Si es que esto no es suficiente, este algoritmo tendrá posibilidades escasas de hacer reproducciones por lo que se haría una búsqueda de soluciones escasas. Cabe recalcar que existen muchos estudios en donde dicen que hay un límite donde es ineficaz elevar el tamaño de la población ya que no se conseguirá una mejor velocidad al resolver el problema.

### **Probabilidad de cruce**

Indica la repetición con la que se originan cruces entre los cromosomas padre. En caso no exista probabilidad de reproducción, los hijos serán copias exactas de los padres. Si es que la hay, los hijos poseerán partes de los cromosomas de los padres. Si la probabilidad de cruce es del 100% el hijo se crea totalmente por cruce en lugar de parcialmente.

### **Probabilidad de Mutación**

Nos dice con qué frecuencia mutan los genes de los cromosomas. Si no hay mutación, la descendencia será la misma después de la reproducción. Si ocurre una mutación, se modificará parte de los cromosomas de la descendencia y si la probabilidad de mutación es del 100%, se cambiará todo el cromosoma. En este caso, no solo se cambian unos pocos *bits* del cromosoma, sino que se cambian todos los *bits*, lo que significa que hay una inversión en lugar de una mutación en el cromosoma, y la población se degenera rápidamente.

### **Ventajas de los algoritmos genéticos**

- Son intrínsecamente paralelos, es decir, funcionan de forma inmediata con demasiadas soluciones, en vez de trabajar de paso a paso como las técnicas tradicionales.
- Usan operadores probabilísticos, en cambio las otras técnicas utilizan los típicos operadores determinísticos.
- No requieren conocimientos determinados sobre el problema que quieren resolver.
- Resulta de manera sencilla realizarlos en las modernas arquitecturas masivas en paralelo.

### **Desventajas de los algoritmos genéticos**

- Pueden demorar demasiado en converger, o en no converger, esto depende generalmente por las distintas incógnitas que se empleen, como, por ejemplo: tamaño de la población, número de generaciones, etc.
- Pueden converger apresuradamente debido a una serie de problemas. Por ejemplo, si un individuo que es más apto que la mayoría de sus competidores emerge muy pronto en la ejecución, se puede reproducir rápidamente que merme la diversidad de la población demasiado pronto, provocando que el algoritmo se aproxime hacia el óptimo local que

representa ese individuo, en lugar de rastrear el paisaje adaptativo lo bastante a fondo para encontrar el óptimo global.

### 2.4.3 Operadores Genéticos

Para que se dé el paso de una generación a la siguiente se emplean una serie de operadores genéticos.

#### 2.4.3.1 Selección

Este algoritmo es muy importante ya que se encargará de escoger qué individuos van a tener oportunidades de reproducirse y cuáles no. La selección de cada uno de ellos se verá relacionada con su valor de ajuste. Cabe recalcar que no se debe de excluir en su totalidad los menos aptos ya que en pocas generaciones la población se tornaría homogénea.

Una opción bastante común consiste en elegir el primero de los individuos participantes en el cruce mediante algunos de los métodos que se van a mencionar a continuación y el segundo de manera fortuita.

#### 2.4.3.2 Selección por ruleta

Fue propuesto por DeJong y es el método más utilizado desde los orígenes de los Algoritmos Genéticos [Blickle and Thiele, 1995].

Este método consiste en que a cada uno de los individuos se le va a establecer una parte proporcional a su ajuste de una ruleta, de tal manera que la suma de los porcentajes sea la unidad. Los individuos mejores van a recibir una porción de la ruleta mayor que la que han recibido los peores.

Es un método sencillo, sin embargo, ineficaz a medida que aumenta el tamaño de la población. Presenta además el inconveniente de que el peor individuo puede ser seleccionado más de una vez.

#### Selección por torneo

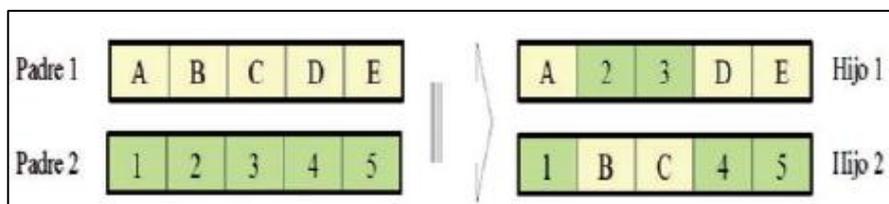
Consiste en realizar la selección en base a comparaciones directas entre individuos. Existen dos versiones de selección:

- Determinística.
- Probabilística.

En la versión determinística se selecciona al azar un número "x" de individuos (mayormente se elige  $p=2$ ). De entre los individuos seleccionados se selecciona el más apto para pasarlo a la siguiente generación.



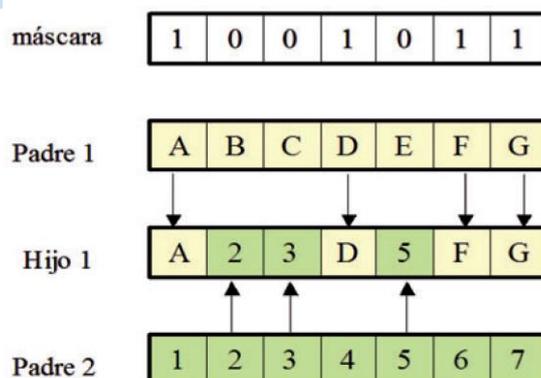
se admite el cruce de 2 puntos pues tiene una mejora con respecto al de un punto, pero generalmente mientras mayor es el número de cortes el rendimiento del algoritmo genético disminuye, esto se debe a que la característica de bondad en conjunto puede ser corrompidas al dividirse.



**Figura 20.** Cruce de dos puntos.

**Fuente:** Gestal, Marcos & Cebrián, Daniel & Rabuñal, Juan & Dorado, Julian & Pazos, Alejandro. (2010). Introducción a los Algoritmos Genéticos y la Programación Genética.

Cruce uniforme: Cada gen de la descendencia tiene las mismas probabilidades de pertenecer a uno u otro padre. Su funcionamiento es básicamente la generación de una máscara de cruce con valores binarios, si hay un gen 1 en la máscara en uno de los descendientes se copia el gen de esa posición del primer padre y si hay un 0 se copia del segundo padre. Para producir otro descendiente se puede variar la posición de los padres o cambian los valores de la máscara.



**Figura 21.** Cruce uniforme.

**Fuente:** Gestal, Marcos & Cebrián, Daniel & Rabuñal, Juan & Dorado, Julian & Pazos, Alejandro. (2010). Introducción a los Algoritmos Genéticos y la Programación Genética.

Cruces específicos de codificaciones no binarias: si se emplean valores enteros o reales pueden definirse otro tipo de operadores de cruce como la media, que toma el valor medio de los genes de los padres, pero solo produce un descendiente del cruce de los padres, también está

la media geométrica en la que cada gen toma la raíz cuadrada del producto de los genes de los padres, se añade como problema de que signo dar al resultado y el operador de extensión que toma la diferencia de los genes en las mismas posiciones de los padres y se suma al valor más alto o se resta al más bajo.

#### **2.4.4. Algoritmos de reemplazo**

Cuando se inserte un nuevo individuo en la población ya debe haber sido eliminado otro de la población. Existen distintos métodos de reemplazo:

- Aleatorio: se inserta un individuo de forma aleatoria en la población.
- Reemplazo de padres: Se libera a los padres y se obtiene espacio para la descendencia.
- Reemplazo de similares: Cuando ya se tiene la descendencia se selecciona un grupo de individuos con ajuste similar y se reemplaza aleatoriamente uno de ellos.
- Reemplazo de los peores: De entre los peores individuos se seleccionan los necesarios para ser reemplazados.

##### **2.4.4.1. Copia**

Se trata de una reproducción asexual, se copia un individuo de la nueva generación, el número de copias debe ser reducido debido a que puede que la población tienda hacia el individuo copiado, se usa cuando no se pueden cruzar dos individuos.

##### **2.4.4.2 Elitismo**

Es un caso particular de copia, pues solo se copia siempre al mejor individuo, es así como siempre se obtendrá una mejora dando buenos resultados y de la mejor calidad, una variación de este proceso es copiar a los mejores individuos a la siguiente generación.

##### **2.4.4.3 Mutación**

Consiste en que generalmente uno de los genes cambie de forma aleatoria, se suele utilizar en conjunto con la operación de cruce, cuando este se produce se hace la mutación con cierta probabilidad, imitándose lo que sucede en la naturaleza.

La probabilidad de mutación es baja, menor a 1%, debido a que los individuos tienen un ajuste menor después de ser mutados, su principal uso es para que ningún punto del espacio de búsqueda tenga probabilidad nula de ser examinado. También se puede realizar la mutación cambiando dos valores del cromosoma.

### 2.4.5. Evaluación

La función de evaluación se encarga de indicar si los individuos de la población representan o no buenas soluciones. Establece una medida numérica de la bondad de la solución, es decir un ajuste.

En los algoritmos genéticos se emplea para controlar la aplicación de los operadores genéticos, es decir, controlará el número de selecciones, cruces, copias y mutaciones. A cada uno de los individuos se le asigna un valor de ajuste escalar. También, puede calcularse el ajuste mediante una manera co-evolutiva. Se pueden diferenciar cuatro tipos de ajuste o *fitness*.

#### 2.4.5.1 Fitness puro: $r(i,t)$

Medida de ajuste establecida en la terminología natural del propio problema, dependiendo de la aplicación es interesante un *fitness* puro elevado o reducido.

$$r(i,t) = \sum_{j=1}^{N_c} |s(i,j) - c(i,j)|$$

$R(i,t)$ : bondad del individuo  $i$  en la generación  $t$

$S(i,j)$ : valor deseado para individuo  $i$  en el caso  $j$

$C(i,j)$ : valor obtenido por el individuo  $i$  en el caso  $j$

$N_c$ : número de casos.

#### 2.4.5.2 Fitness estandarizado: $s(i,t)$

Se utiliza para solucionar la dualidad entre minimización y maximización. La bondad de un individuo será menor cuanto más cercano esté a cero el valor del ajuste, por lo tanto, si se cumple que  $s(i,t) < s(j,t)$  el individuo  $i$  siempre es mejor que  $j$ .

$$s(i,t) = \begin{cases} r(i,t) & \text{minimización} \\ r_{max} - r(i,t) & \text{maximización} \end{cases}$$

### 2.4.5.3 Fitness ajustado: $a(i,t)$

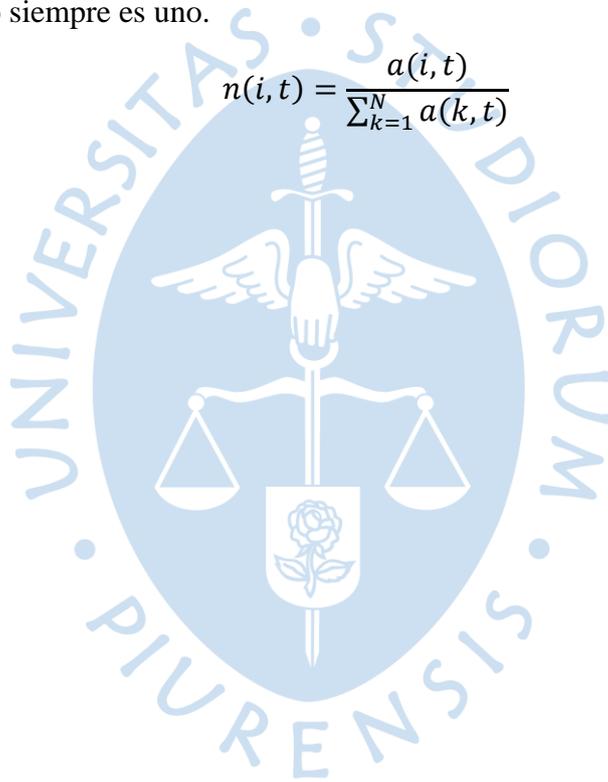
Siempre toma valores del intervalo (0,1], cuando se aproxime a 1 mayor será su bondad.

$$a(i,t) = \frac{1}{1 + s(i,t)}$$

### 2.4.5.4 Fitness normalizado: $n(i,t)$

Indica la bondad de una solución con respecto al resto de las soluciones presentadas en la población. Siempre toma valores entre (0,1] y cuando se aproxime a la unidad tiene más bondad, pero además es una solución destacada con respecto al resto de la población, la suma de valores de fitness normalizado siempre es uno.

$$n(i,t) = \frac{a(i,t)}{\sum_{k=1}^N a(k,t)}$$



## Capítulo 3

### Metodología

#### 3.1 Muestras estandarizadas

Para este proyecto se utilizaron 3 canteras de arena, las cuales son: Moyobamba, Cerro Mocho y Sechura. Al momento de obtener las muestras nos encontramos con algunas humedecidas, entonces procedimos a almacenarlas en un horno por 1 día a una temperatura de  $110 \pm 5^{\circ}\text{C}$  para que así la humedad sea contrarrestada en su totalidad.



**Figura 22.** Introducción de la arena en el horno.

**Fuente:** Elaboración propia.

Después de sacar las muestras del horno, teniendo en cuenta los kg de arena con la que se contaba, procedimos a dividir las en pequeñas muestras de 200 g. Con lo cual, logramos obtener un total de 65 muestras por cada cantera, en general 195 muestras de 200g.



**Figura 23.** Arena de las diferentes canteras sacadas del horno

**Fuente:** Elaboración propia.



**Figura 24.** 65 muestras de la Cantera de Moyobamba.

**Fuente:** Elaboración propia.



**Figura 25.** 65 muestras de la Cantera de Sechura.

**Fuente:** Elaboración propia.



**Figura 26:** 65 muestras de la Cantera de Cerro Mocho.

**Fuente:** Elaboración propia.

### 3.2 Preparación de las muestras

Se resolvió tener 65 muestras de cada cantera con el objetivo de administrarle diferentes porcentajes de humedad.

La humedad que se le agregó a la arena fue por decisión grupal, se comenzó desde 0% y se aumentó cada 0.2%, llegando a un 12% en la última muestra. Los gramos de agua que se añadieron a las 195 muestras se calcularon de la siguiente manera:

$$\text{gramos de cada muestras} * \% \text{ de humedad} = \text{gramos de agua}$$

Como ya es conocido el dato de los gramos en cada muestra (200gramos) y el porcentaje de humedad, fácilmente se logra calcular cuánto gramos de agua hay que añadirle a cada una de ellas.



**Figura 27.** Muestras de la Cantera de Moyobamba con cierto contenido de humedad.

**Fuente:** Elaboración propia.



**Figure 28.** Muestras de la Cantera de Sechura con porcentaje de humedad.

**Fuente:** Elaboración propia.



**Figura 29.** Muestras de la Cantera Cerro Mocho con porcentaje de humedad.

**Fuente:** Elaboración propia.

Como se puede apreciar en las anteriores imágenes, a medida que aumentábamos el porcentaje de humedad, la arena tomaba una apariencia más lodosa, lo cual nos permitía desarrollar con más exactitud el trabajo, cabe resaltar que cada cantera era diferente, puesto que la cantera que tomaba una apariencia más lodosa era Moyobamba.

### 3.3 Toma de imágenes en la Cámara Hiperespectral

Una vez realizado el procedimiento anteriormente mencionado se continúa con el estudio a partir de imágenes hiperespectrales, mediante la cámara hiperespectral. Se usa el programa *SpectrononPro* para el análisis de cada muestra. El cual proporciona una gráfica reflectancia vs longitud de onda, definiendo así la firma espectral.

A continuación, explicaremos los pasos realizados en la cámara hiperespectral y los datos que se llegaron obtener.

#### 3.3.1 Procedimiento en la cámara hiperespectral

1. Se insertan las muestras de arena en un recipiente libre de impurezas, para no obtener resultados erróneos.



**Figura 30.** Muestra de Arena de la Cantera de Sechura

**Fuente:** Elaboración propia.

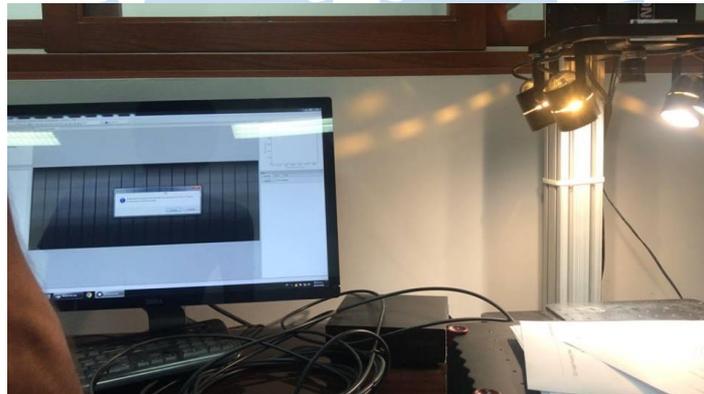
2. Se prosigue a ponerlo en la cámara hiperespectral. Luego, empieza la etapa de traslación, en donde se capta la imagen. Cabe resaltar que la cámara hiperespectral cuenta con una iluminación muy potente, como se puede ver en la siguiente imagen cuenta con 4 focos, por lo cual estas imágenes son de alta calidad.



**Figura 31.** Faja transportadora de la Cámara Hiperespectral

**Fuente:** Elaboración propia.

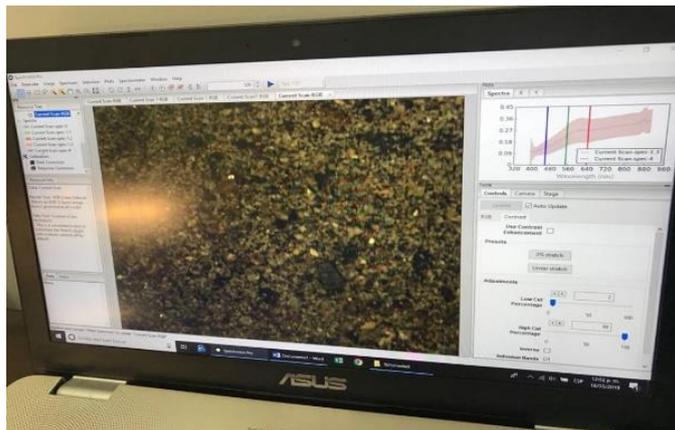
3. La cámara hiperespectral está conectada a una computadora, y mediante el programa *SpectrononPro*, se aprecia como la cámara hiperespectral va captando la imagen mediante la traslación.



**Figura 32.** Conexión entre computadora y cámara Hiperespectral.

**Fuente:** Elaboración propia.

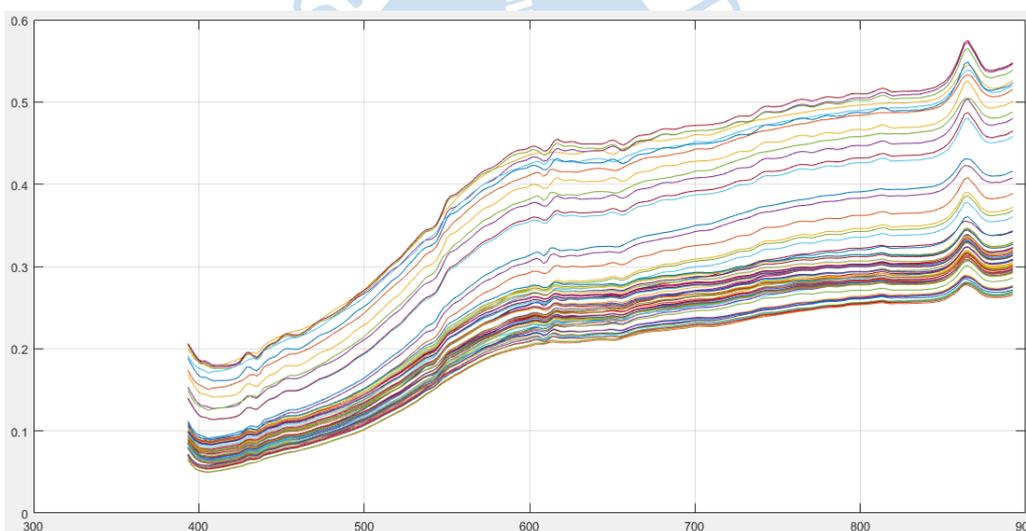
4. Terminado este proceso, empieza el análisis de la imagen captada, se escoge una porción de la imagen para el estudio, pero en esta ocasión se decide escoger toda, ya que poseía en toda su extensión la muestra.



**Figura 33.** Programa SpectronPro.

**Fuente:** Elaboración propia.

5. Finalmente se importa el espectro y proyecta la firma espectral, que es una gráfica reflectancia vs longitud de onda.



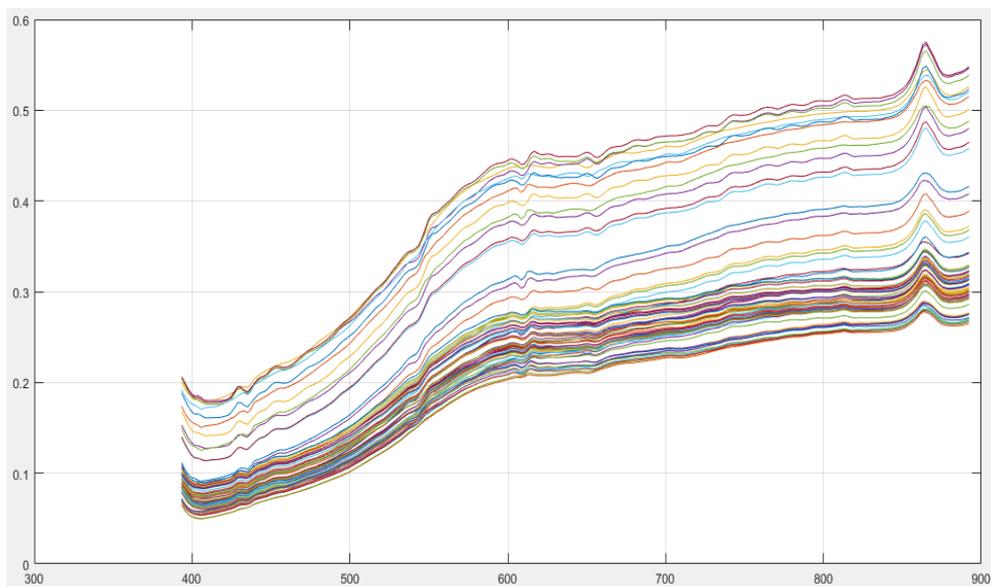
**Figura 34.** Firma Espectral.

**Fuente:** Elaboración propia.



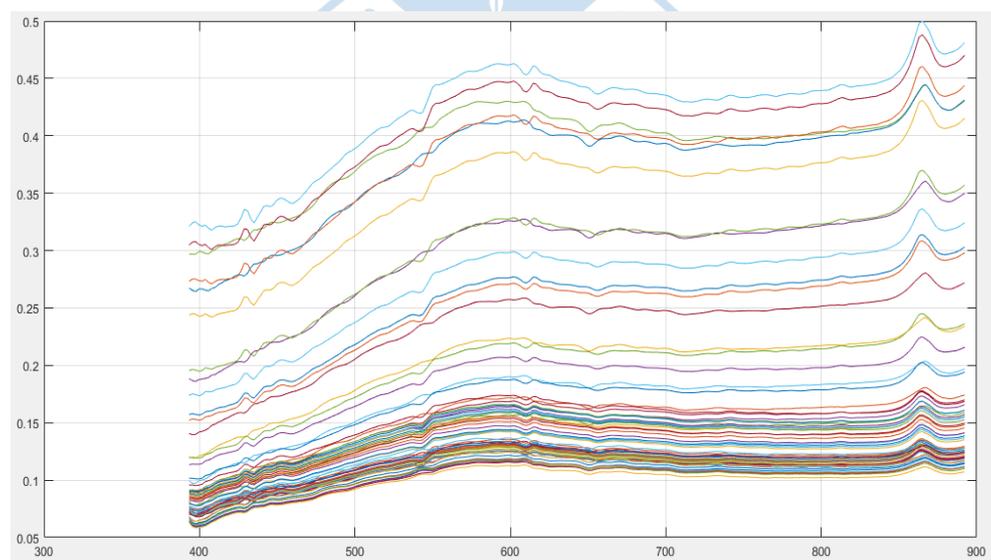
## Capítulo 4

### Resultados



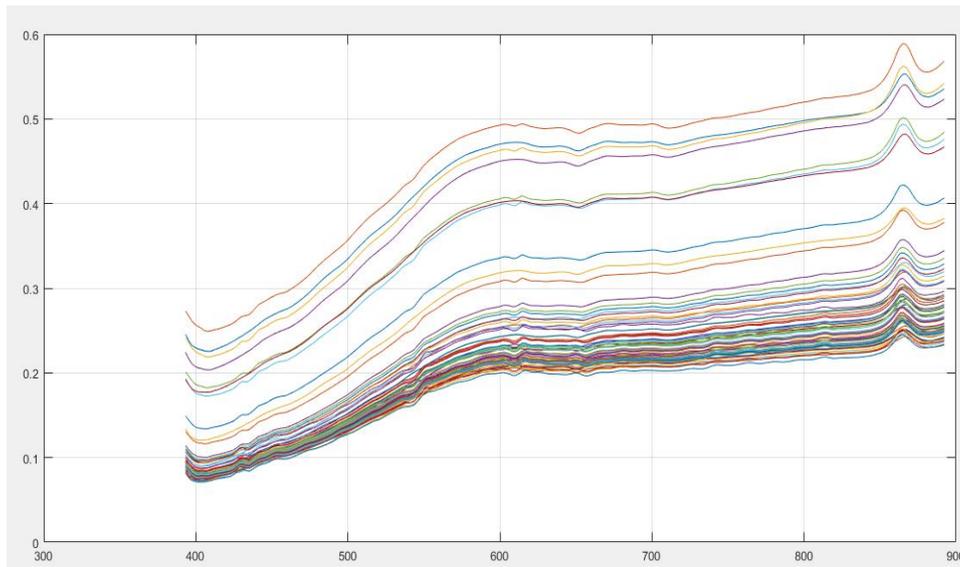
**Figura 35.** Firmas Espectrales de Cerro Mocho.

**Fuente:** Elaboración propia.



**Figura 36.** Firmas Espectrales de Moyobamba.

**Fuente:** Elaboración propia.



**Figura 37.** Firmas Espectrales de Sechura.

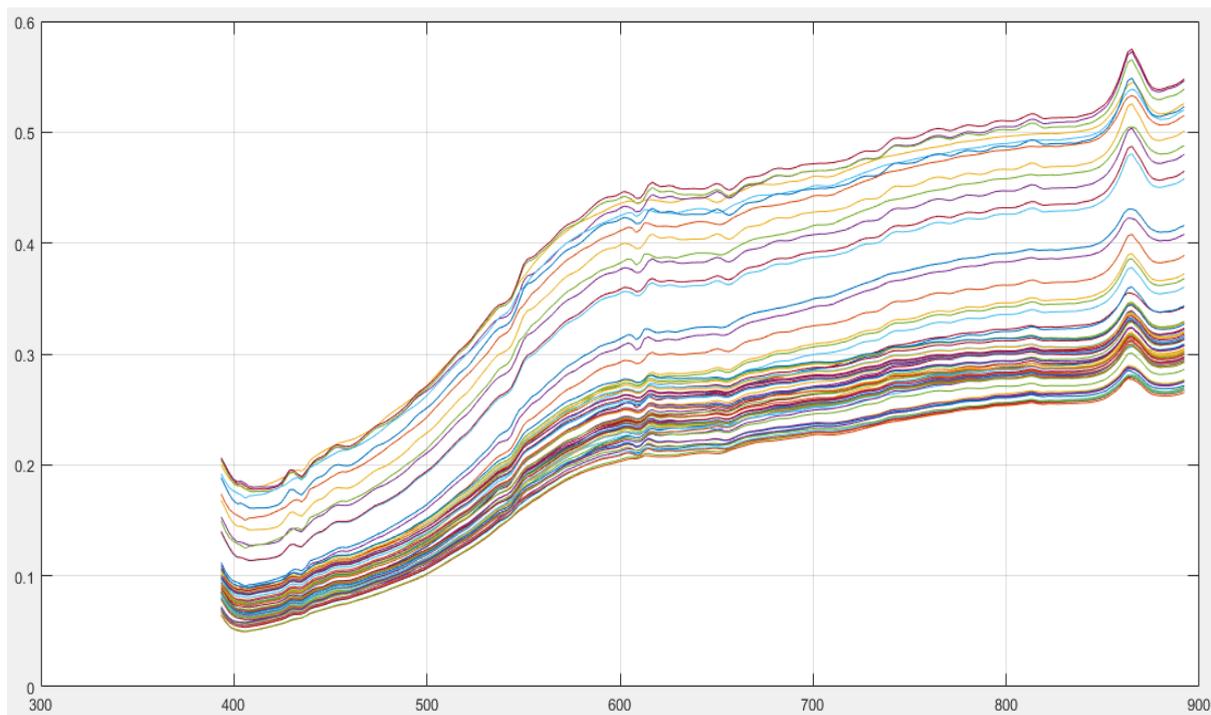
**Fuente:** Elaboración propia.

## 4.1. Análisis por recta de regresión en Excel

### 4.1.1. Cerro Mocho

Con los datos obtenidos se graficaron las firmas espectrales en Matlab, con la ayuda de los cubos espectrales que nos arrojaba el programa *SpectrononPro*.

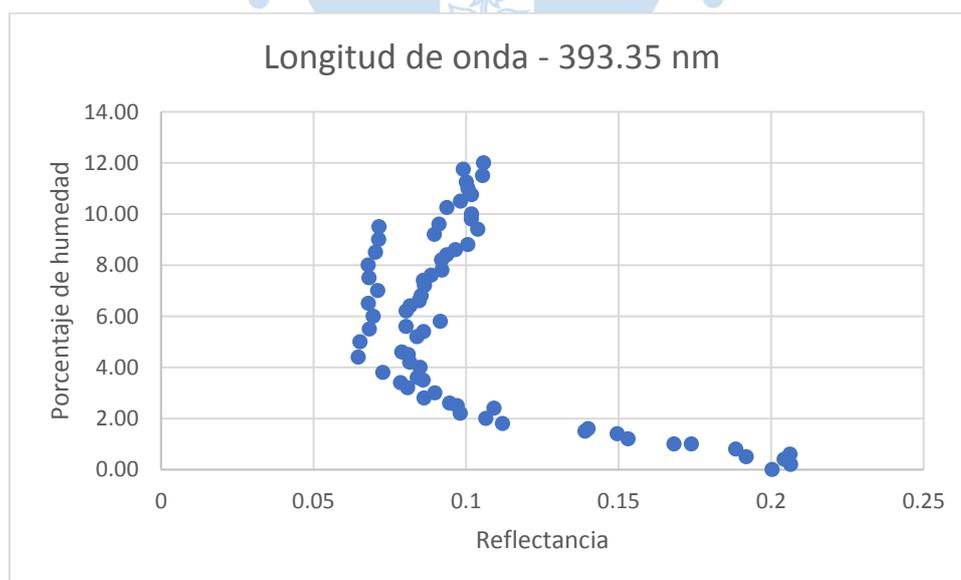
Un paso fundamental de este proyecto es la elección de bandas, es decir en cual nos vamos a centrar para su estudio, ya que basarnos en las 240 bandas sería un problema ya que habría data que quizás no aporte información relevante. Por ello decidimos poner en un solo código las firmas (Las 65 firmas espectrales en una sola gráfica), para poder identificar las bandas que usaremos para la regresión.



**Figura 38.** Firmas Espectrales de Cerro Mocho.

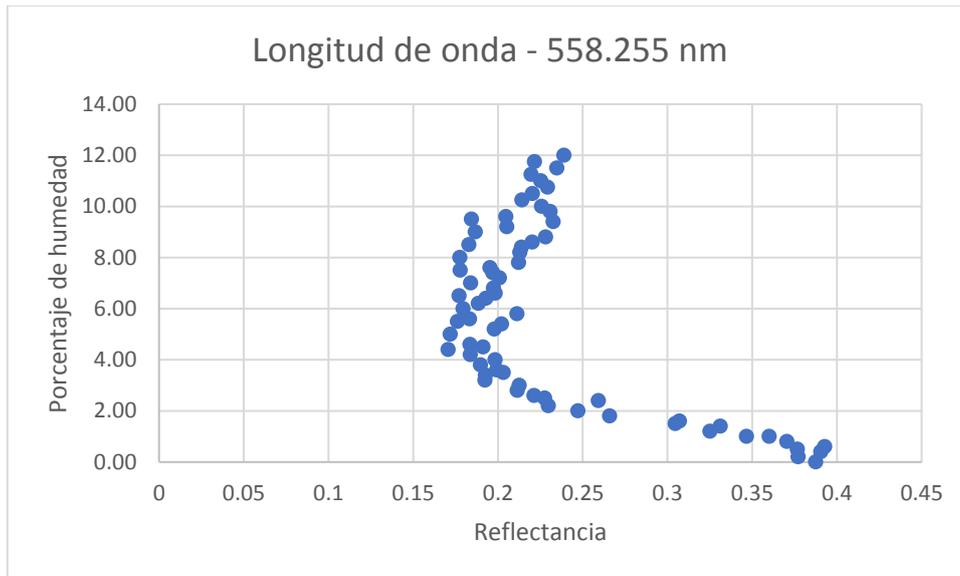
**Fuente:** Elaboración propia.

Para el análisis hemos escogido 4 bandas para darnos una idea de cuanto información puede proporcionarnos cada una de ellas y si es que todas siguen un mismo patrón que pueda ser analizado posteriormente.



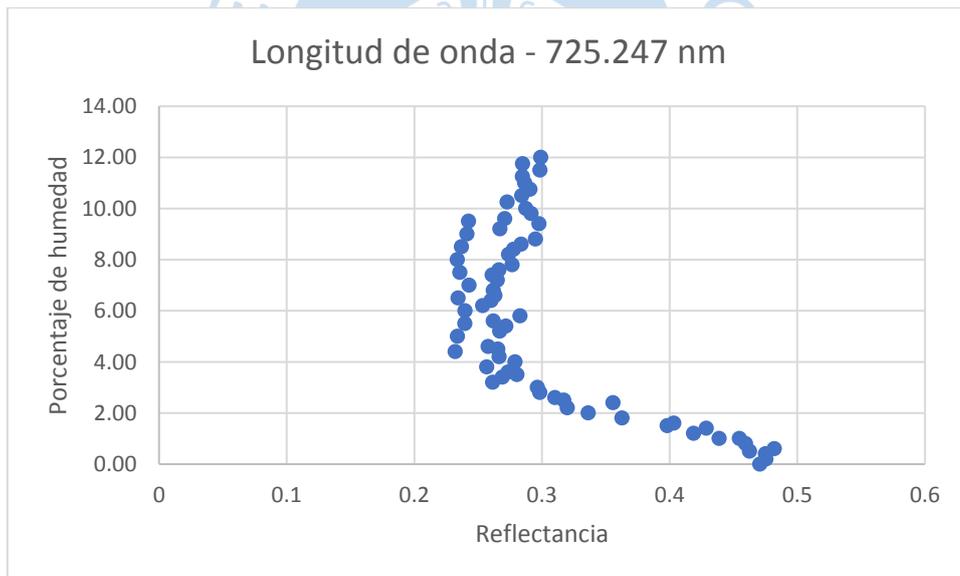
**Figura 39.** Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 393.35 nm de la Cantera de Cerro Mocho.

**Fuente:** Elaboración propia.



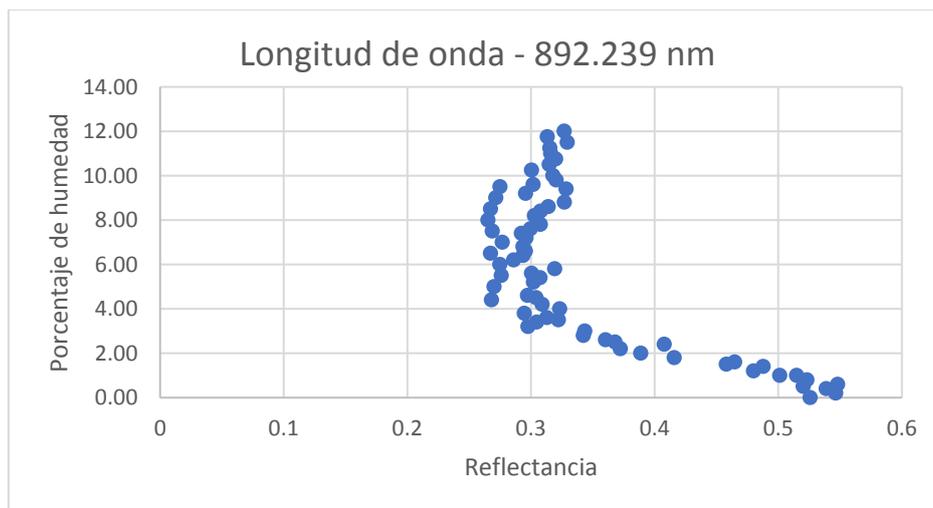
**Figura 40.** Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 558.255 nm de la Cantera de Cerro Mocho.

**Fuente:** Elaboración propia.



**Figura 41.** Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 725.247 nm de la Cantera de Cerro Mocho.

**Fuente:** Elaboración propia.



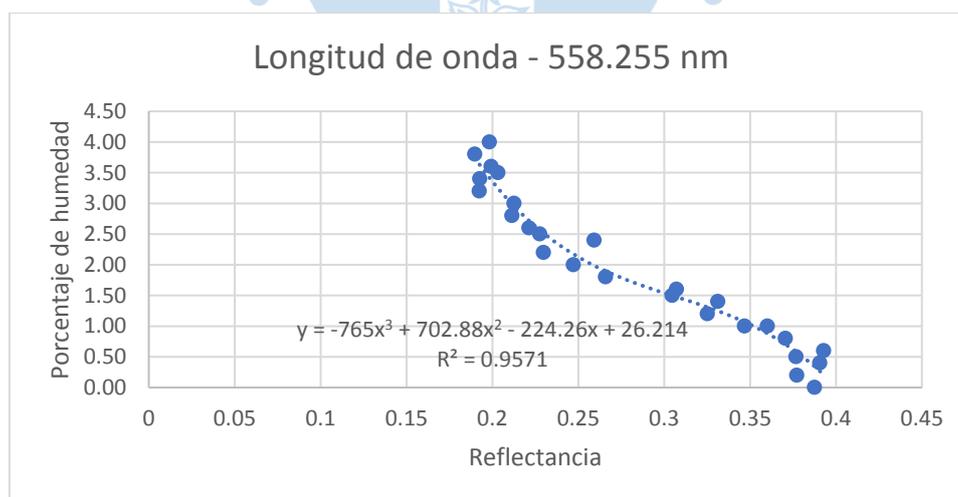
**Figura 42.** Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 892.239 nm de la Cantera de Cerro Mocho.

**Fuente:** Elaboración propia.

Analizando las gráficas se puede observar que aproximadamente desde el 0% hasta el 4% de humedad se puede ver una cierta linealidad, a partir del 4% los resultados de reflectancia tienen aproximadamente el mismo valor, se podría decir que desde 4% se satura.

Es por ello que para la recta de regresión se han escogido los valores del 0 al 4% de humedad. Proseguimos a hacer la recta de regresión, la cual nos da la siguiente ecuación:

$$y = -765x^3 + 702.88x^2 - 224.26x + 26.214$$



**Figura 43.** Recta de regresión para la longitud de onda de 558.255 nm de la cantera de Cerro Mocho.

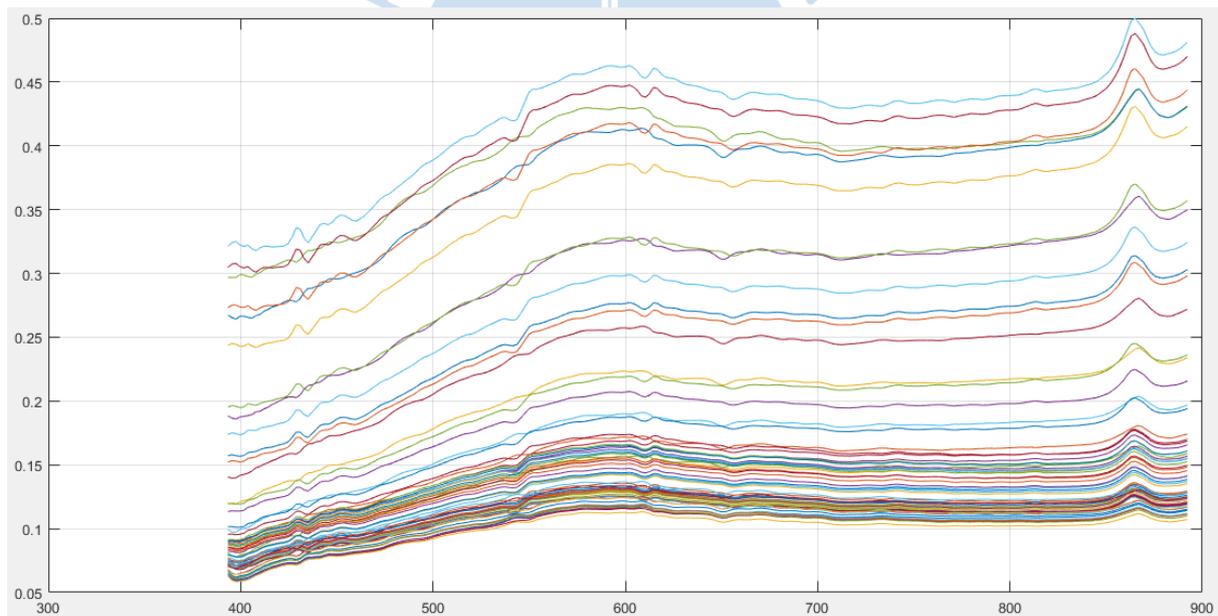
**Fuente:** Elaboración propia.

Como vemos nos encontramos con una recta de tercer orden, la cual está en función de reflectancia y se obtendrá como resultado el porcentaje de humedad solo para la longitud de onda de 558.255 nm, con este ajuste se puede predecir correctamente el porcentaje de humedad de 0% a 4% solo para esta longitud de onda.

#### 4.1.2. Moyobamba

Para la Cantera de Moyobamba se realizó el mismo procedimiento que para la cantera anterior, cabe resaltar que las firmas espectrales no son parecidas ya que la arena es diferente. Por ejemplo, al momento de esta ser humedecida se ponía muy densa, con una consistencia parecida a la del cemento.

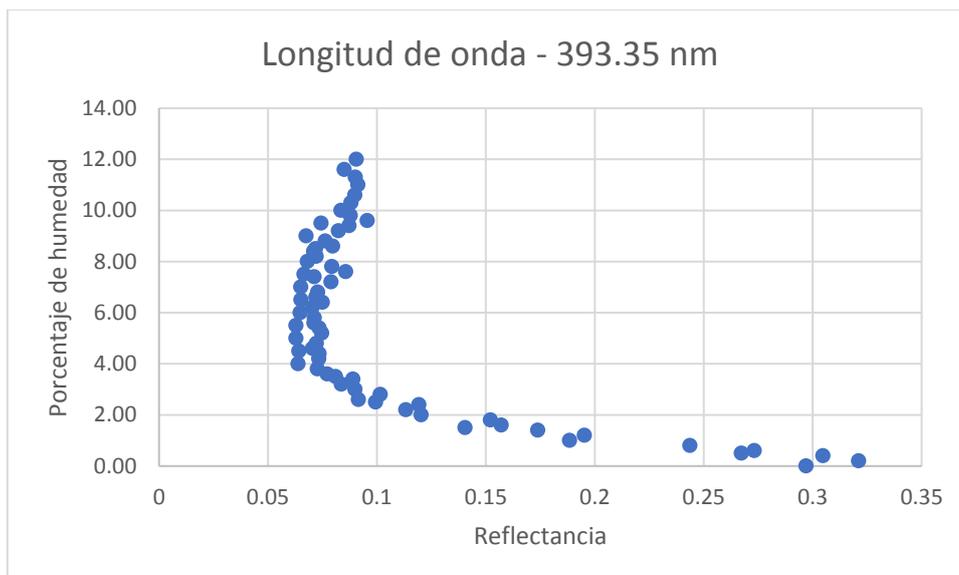
Para la elección de bandas, es decir en cual nos vamos a centrar para su estudio, decidimos poner en un solo código las firmas (Las 65 firmas espectrales en una sola gráfica), para poder identificar las bandas que usaremos para la regresión.



**Figura 44.** Firmas Espectrales de Moyobamba.

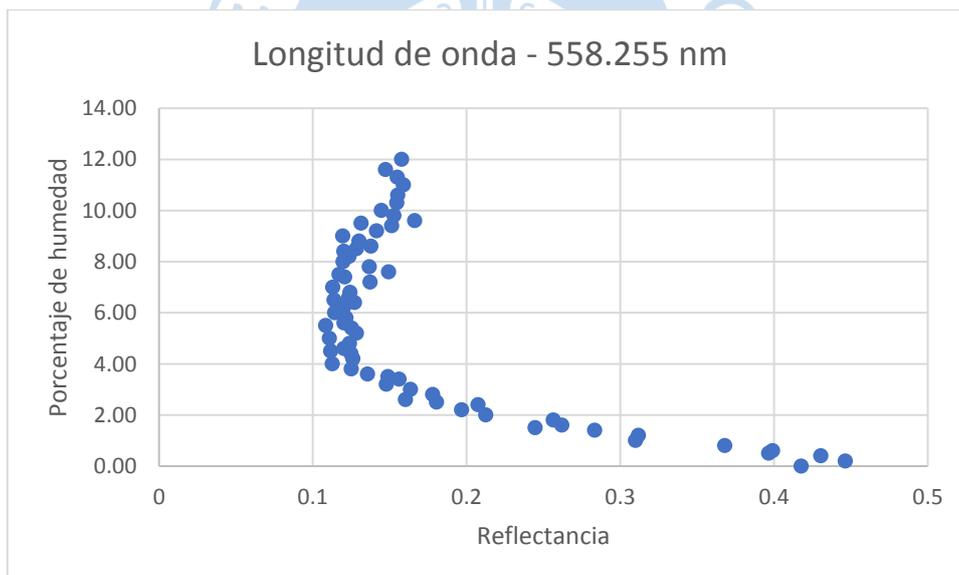
**Fuente:** Elaboración propia.

Para el análisis hemos escogido 4 bandas para darnos una idea de cuanta información puede proporcionarnos cada una de ellas y si es que todas siguen un mismo patrón que pueda ser analizado posteriormente.



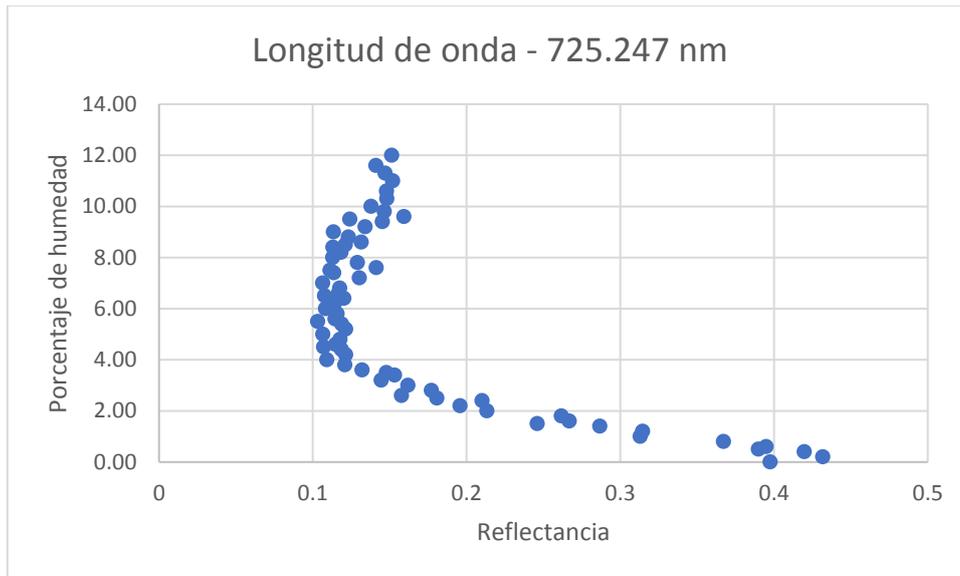
**Figura 45.** Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 393.35 nm de la Cantera de Moyobamba.

**Fuente:** Elaboración propia.



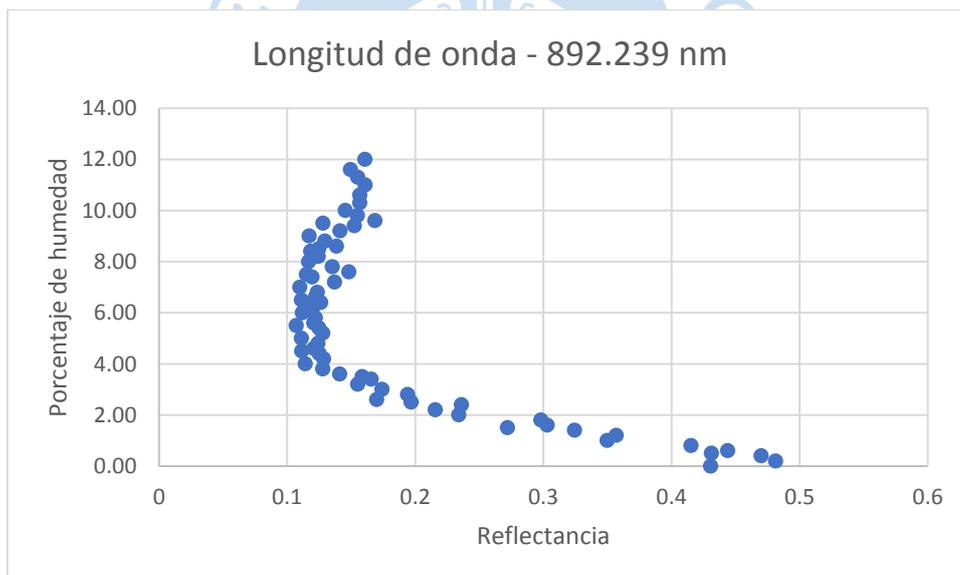
**Figura 46.** Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 558.255 nm de la Cantera de Moyobamba.

**Fuente:** Elaboración propia.



**Figura 47.** Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 725.247 nm de la Cantera de Moyobamba.

**Fuente:** Elaboración propia.



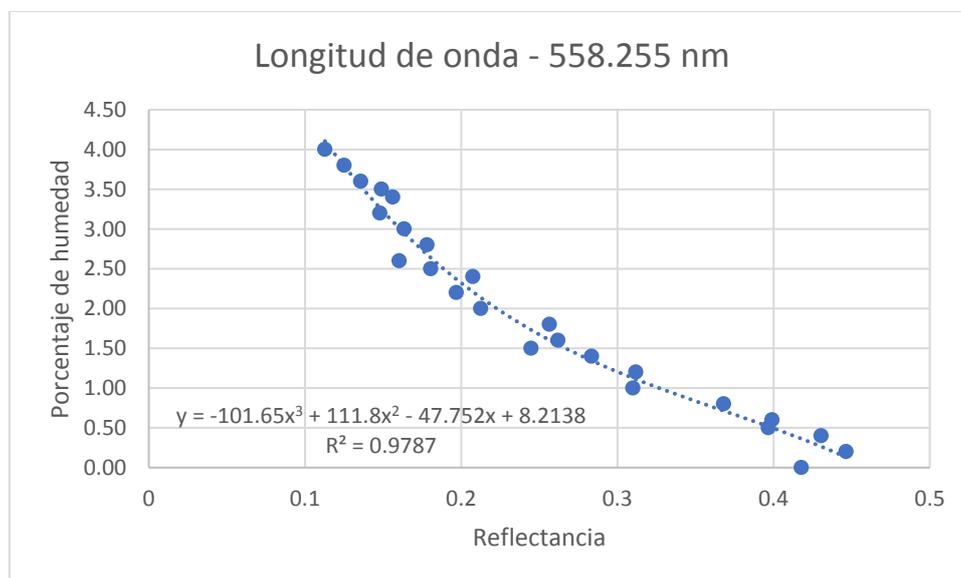
**Figura 48.** Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 892.239 nm de la Cantera de Moyobamba.

**Fuente:** Elaboración propia.

Analizando las gráficas se puede observar que aproximadamente desde el 0% hasta el 4% de humedad se puede ver una cierta linealidad, a partir del 4% los resultados de reflectancia tienen aproximadamente el mismo valor, se podría decir que desde 4% se satura.

Es por ello que para la recta de regresión se han escogido los valores del 0 al 4% de humedad. Proseguimos a hacer la recta de regresión, la cual nos da la siguiente ecuación:

$$y = -101.65x^3 + 111.8x^2 - 47.752x + 8.2138$$



**Figura 49.** Recta de regresión para la longitud de onda de 558.255 nm de la cantera de Moyobamba

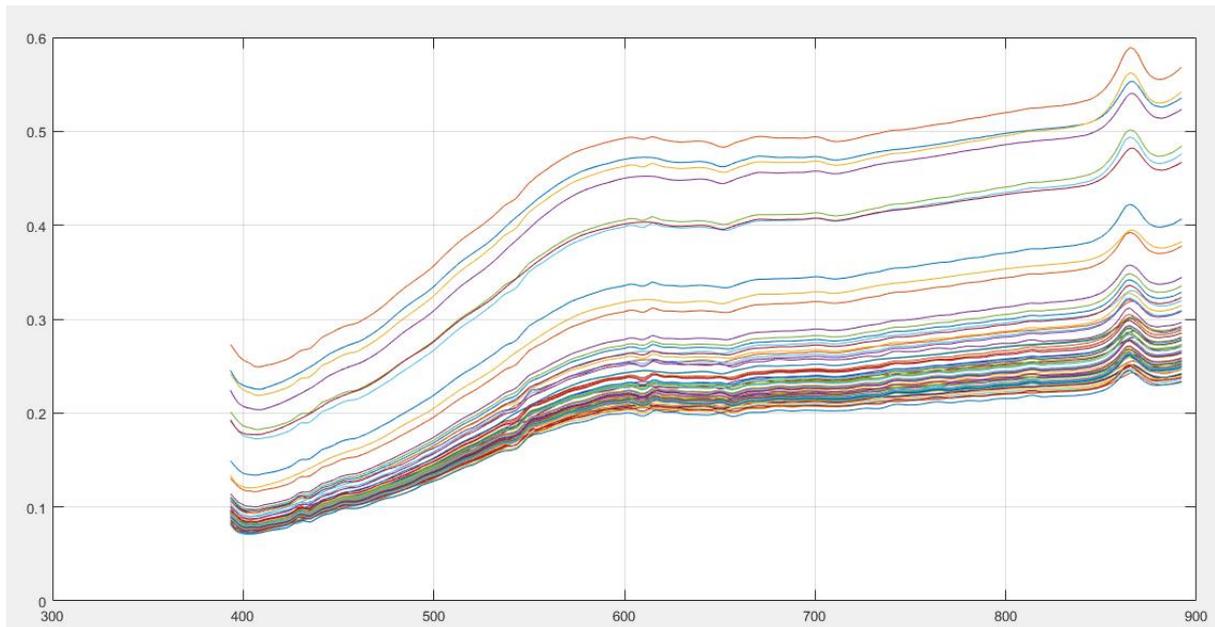
**Fuente:** Elaboración propia

Como vemos nos encontramos con una recta de tercer orden, la cual está en función de reflectancia y se obtendrá como resultado el porcentaje de humedad solo para la longitud de onda de 558.255 nm, con este ajuste se puede predecir correctamente el porcentaje de humedad de 0% a 4% solo para esta longitud de onda.

#### 4.1.3. Sechura

Para la Cantera de Sechura realizamos los mismos pasos que para las canteras anteriores, cabe resaltar que las firmas espectrales no son parecidas ya que la arena es diferente, pero que hay cierto parecido entre Cerro Mocho y Sechura.

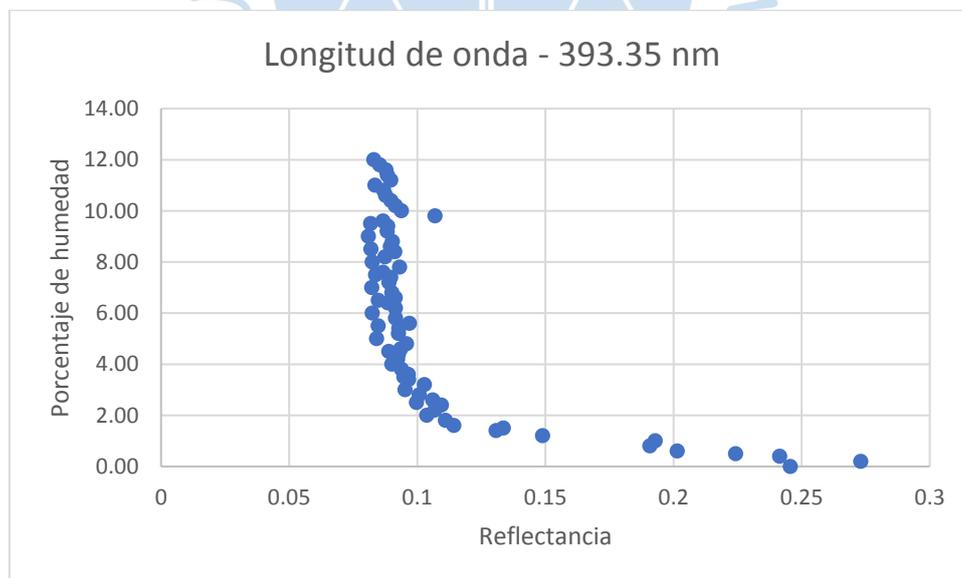
Para la elección de bandas, es decir en cual nos vamos a centrar para su estudio, decidimos poner en un solo código las firmas (Las 65 firmas espectrales en una sola gráfica), para poder identificar las bandas que usaremos para la regresión.



**Figura 50.** Firmas Espectrales de Sechura.

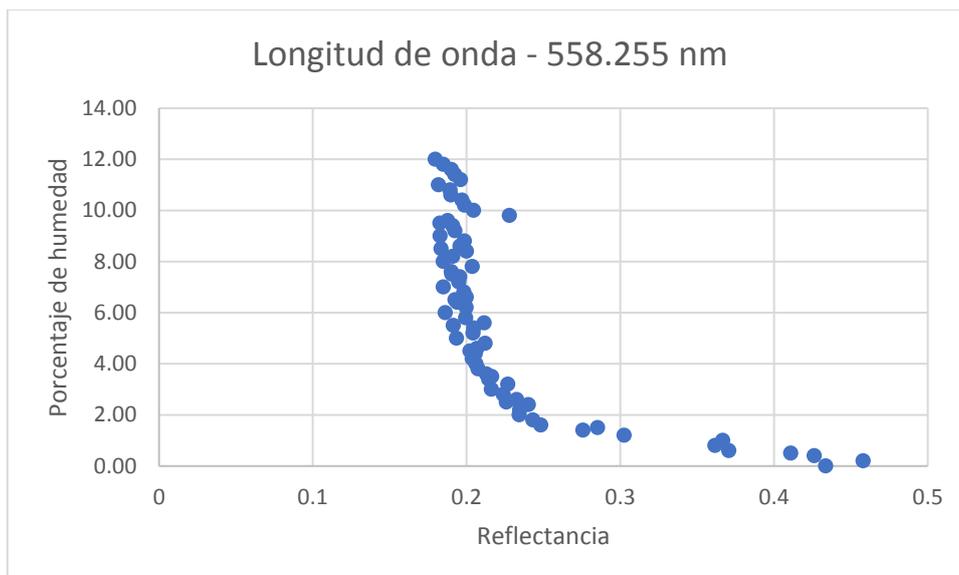
**Fuente:** Elaboración propia.

Para el análisis hemos escogido 4 bandas para darnos una idea de cuanta información puede proporcionarnos cada una de ellas y si es que todas siguen un mismo patrón que pueda ser analizado posteriormente.



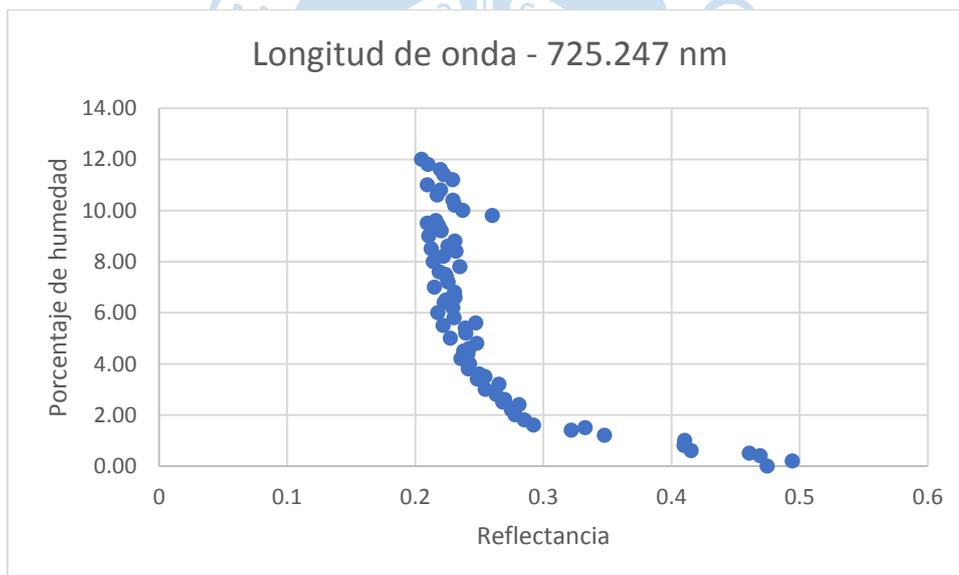
**Figura 51.** Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 393.35 nm de la Cantera de Sechura

**Fuente:** Elaboración propia



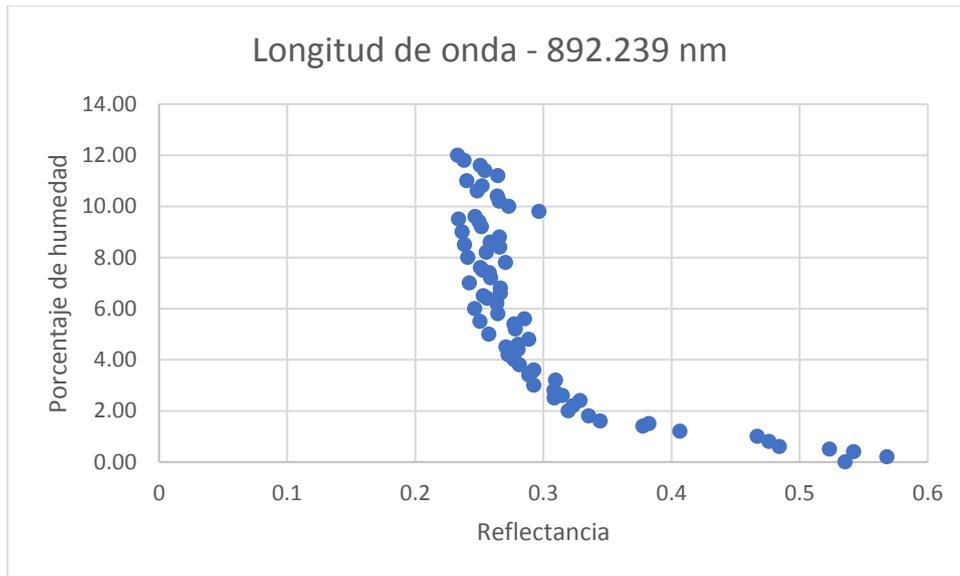
**Figura 52.** Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 558.255 nm de la Cantera de Sechura

**Fuente:** Elaboración propia



**Figura 53.** Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 725.247 nm de la Cantera de Sechura.

**Fuente:** Elaboración propia.



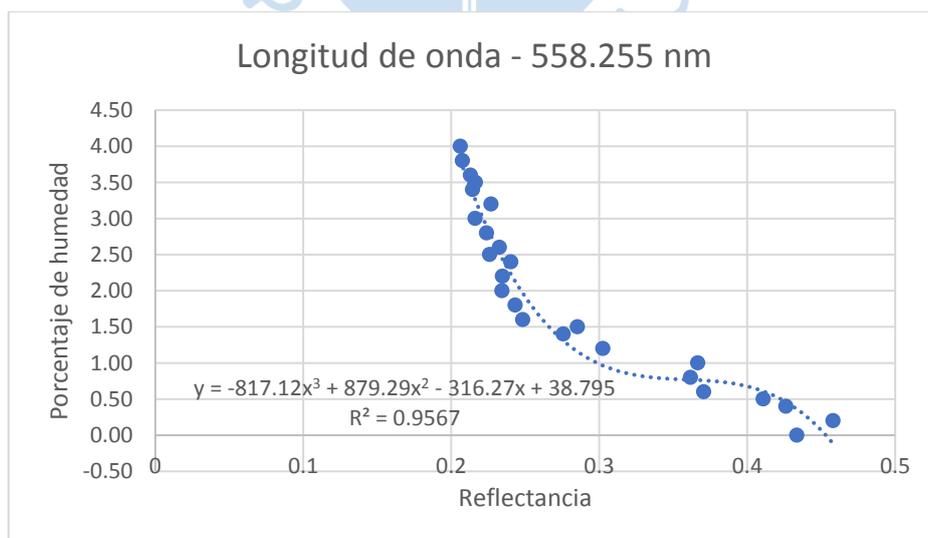
**Figura 54.** Gráfica del porcentaje de humedad vs reflectancia para una longitud de onda de 892.239 nm de la Cantera de Sechura.

**Fuente:** Elaboración propia.

Analizando las gráficas se puede observar que aproximadamente desde el 0% hasta el 4% de humedad se puede ver una cierta linealidad, a partir del 4% los resultados de reflectancia tienen aproximadamente el mismo valor, se podría decir que desde 4% se satura.

Es por ello que para la recta de regresión se han escogido los valores del 0 al 4% de humedad. Proseguimos a hacer la recta de regresión, la cual nos da la siguiente ecuación:

$$y = -817.12x^3 + 879.29x^2 - 316.27x + 38.795$$



**Figura 55.** Recta de regresión para la longitud de onda de 558.255 nm de la cantera de Sechura.

**Fuente:** Elaboración propia.

Como vemos nos encontramos con una recta de tercer orden, la cual está en función de reflectancia y se obtendrá como resultado el porcentaje de humedad solo para la longitud de onda de 558.255 nm, con este ajuste se puede predecir correctamente el porcentaje de humedad de 0% a 4% solo para esta longitud de onda.

Ese simple análisis nos sirvió para poder confirmar la relación que hay entre el porcentaje de humedad y la información obtenida por las firmas espectrales, es por eso que se procedió a crear un algoritmo más complejo que analiza de una forma mucho más eficiente, que otorga resultados válidos y con mucha información.

#### **4.2. Análisis por Redes neuronales.**

Se ha utilizado un algoritmo que recoge la información del Excel, analiza la carpeta de datos, compara los valores de todas las firmas espectrales y las tiene etiquetadas por nombre junto con el porcentaje de humedad; lo que facilita el procesamiento de los datos obtenidos a través de las 195 muestras.

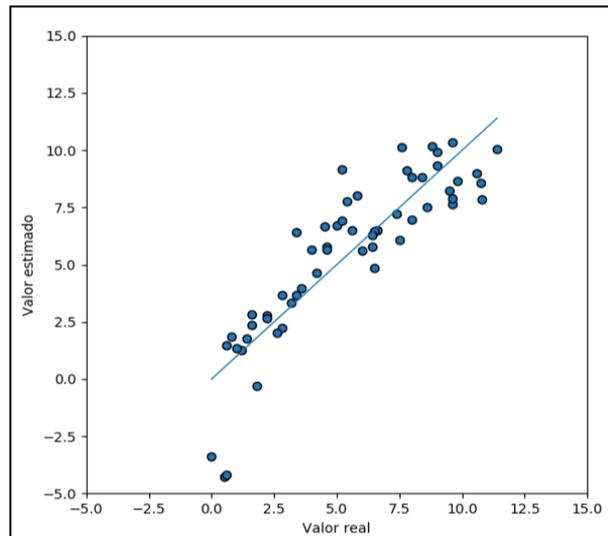
El principal objetivo de esta transformada es disminuir la alta dimensionalidad implícita de una imagen hiperespectral (240 bandas), ya que siempre existen variaciones que no son deseadas como errores en la medición de datos, interacciones ambientales, y entre otros factores que afectan la predicción del modelo elaborado.

Este código analiza una parte de las firmas espectrales, les saca el promedio, y así pasan la transformada avanza de Fourier, reconstruye la señal y de las 240 bandas quedan 60, la cuales son ricas en información pues no tiene valores redundantes. Esta transformada es capaz de reconocer un patrón de onda sin necesidad de tener todos los datos, por lo que se pasa de un lado a otro por la reconstrucción de señal sin perder información.

Se utilizaron el 70% de las muestras para el entrenamiento y las restantes fueron para la validación (59 muestras).

El algoritmo usa una capa de redes neuronales *multilayer perceptron backpropagation* la cual tiene dos capas de 5 neuronas cada una ocultas, tiene 60 datos de entrada, la función de activación es lineal, pero el modelo no es lineal.

Haciendo uso de un algoritmo basado en la transformada *Wavelet*, se evaluaron las 59 muestras de prueba y se obtuvo la siguiente gráfica:



**Figura 56.** Regresión dada por las redes neuronales.

**Fuente:** Elaboración propia.

Se obtuvo como resultado una correlación de 0.87, entonces se podría decir que, a menor cantidad de información, más eficiente va a ser el algoritmo de *machine learning*, por lo que a más información no necesariamente es mejor (si no se analiza por la influencia que tenga), por lo que si se hace un subespacio de bandas (transformada avanzada de Fourier o *Wavelet*) será mejor.

Como se puede apreciar en la gráfica, existen datos que no siguen la tendencia de los demás, sin embargo, son muy pocos, por lo que la correlación no es muy lejana a la unidad.

Los valores que no siguen la tendencia de los demás son quizás producto de que la arena no estaba muy escarmentada en la toma de la imagen en la cámara espectral o por los factores externos mencionados anteriormente.

A continuación, se presentará una tabla que muestra los diferentes tipos de muestras a las que se les aplicó el algoritmo, además muestra el valor de predicción y el error existente.

**Tabla 1.** Resultados al aplicar redes neuronales.

	Muestras	Prueba	Predicción	Diferencia
0	SEC1.2	1.20	1.27	0.07
1	CM2.8	2.80	2.22	0.58
2	SEC4	4.00	5.84	1.84
3	MOY5.2	5.2	9.28	4.08
4	MOY0.5	0.50	-4.25	4.75

5	SEC3.6	3.60	3.97	0.37
6	CM9.6	9.60	7.55	2.05
7	CM2.6	2.60	1.78	0.82
8	MOY7.8	7.80	9.22	1.42
9	MOY7.6	7.60	10.25	2.65
10	SEC9.6	9.60	7.99	1.61
11	CM3.2	3.20	3.15	0.05
12	MOY2.8	2.80	3.70	0.90
13	CM1.6	1.60	2.92	1.32
14	SEC5.6	5.60	6.31	0.71
15	MOY8.6	8.60	7.69	0.91
16	MOY0.6	0.60	-4.03	4.63
17	MOY8	8.00	7.26	0.74
18	SEC11.4	11.40	9.99	1.41
19	MOY9	9.00	9.76	0.76
20	MOY9.6	9.60	10.45	0.85
21	SEC2.2	2.20	2.73	0.53
22	MOY0.2	0.20	-6.12	6.32
23	CM8	8.00	8.98	0.98
24	SEC4.5	4.50	6.75	2.25
25	MOY8.4	8.40	8.73	0.33
26	MOY0.4	0.40	-5	5.40
27	MOY4.6	4.60	5.59	0.99
28	CM5.4	5.40	7.91	2.51
29	MOY6	6.00	5.66	0.34
30	MOY8.8	8.80	10.13	1.33
31	MOY1.6	1.60	2.5	0.9
32	CM4.2	4.20	4.8	0.6
33	SEC7.4	7.40	7.25	0.15
34	MOY10.6	10.60	9.01	1.59
35	SEC6.6	6.60	6.57	0.03
36	CM3.4	3.40	6.84	3.44
37	SEC6.5	6.50	6.45	0.05

38	MOY1.4	1.40	1.79	0.39
39	CM1	1.00	1.34	0.34
40	SEC0.6	0.60	1.57	0.97
41	MOY9.5	9.50	8.32	1.18
42	SEC6.4	6.40	6.20	0.20
43	MOY3.4	3.40	3.59	0.19
44	CM9.8	9.80	8.54	1.26
45	MOY5	5.00	7	2
46	CM6.4	6.40	6	0.4
47	SEC10.8	10.80	7.81	2.99
48	CM7.5	7.50	6.09	1.41
49	MOY0	0.00	-3.35	3.35
50	MOY6.5	6.50	4.87	1.63
51	SEC4.6	4.60	5.69	1.09
52	MOY2.2	2.20	2.78	0.58
53	MOY1.8	1.80	-0.23	2.03
54	CM5.2	5.20	7.09	1.89
55	SEC0.8	0.80	1.81	1.01
56	CM10.75	10.75	8.40	2.35
57	CM9	9.00	9.48	0.48
58	SEC5.8	5.80	7.87	2.07

Fuente: Elaboración propia.

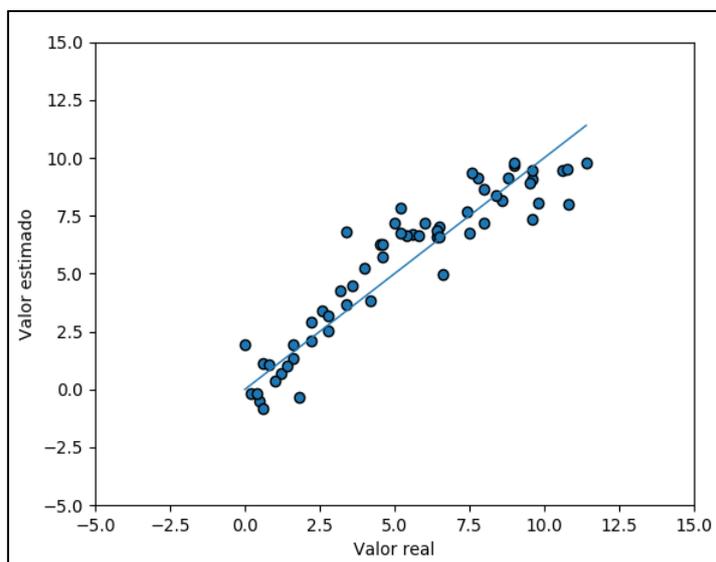
Como se puede apreciar los errores no son tan grandes, pues existen valores que son muy cercanos al valor del porcentaje de humedad de referencia, sin embargo, esos errores afectan a la eficiencia del algoritmo.

#### 4.3. Análisis con algoritmos genéticos

Los sistemas que operan con inteligencia artificial se encuentran elaborados por múltiples algoritmos lo cuales tienen por finalidad encontrar un patrón en los datos, para así clasificar, predecir, identificar modelos y agruparlos convenientemente. El proceso de aprendizaje automático toma importancia cuando no se tiene un modelo matemático o es muy complicado de modelar por métodos de identificación. Este proceso tiene como objetivo encontrar un

modelo a partir de información pasada, datos de entrada y salida; buscar una relación entre ellos y proporcionar información suficiente para validar la confiabilidad de las predicciones a través de experimentos.

En este caso a las 59 muestras, se les aplicó este algoritmo, el cual seleccionó aquellas bandas que contienen una cantidad de información necesaria tal que pueda describir por completo la firma espectral del material y sus características, eliminando las que no son necesarias para que no afecte a la eficiencia del modelo y pueda aumentar el nivel de confianza. A continuación, se muestra el gráfico obtenido al aplicar este algoritmo a nuestro conjunto de datos.



**Figura 57.** Regresión dada por los algoritmos genéticos.

**Fuente:** Elaboración propia.

Aplicando algoritmos genéticos la correlación mejora de tal manera que el nivel de confianza aumentó, y esto lo hace determinando las bandas que interesan y anulando las bandas que no tienen mucha importancia, obteniéndose una correlación de 0.93 (93%), el cual es un valor muy alto. Además, en la gráfica se puede observar como todos los datos tienden hacia la misma dirección.

A continuación, se presentará una tabla el cual pertenece a diferentes tipos de muestras en donde se le aplicó el algoritmo y el error existente.

**Tabla 2.** Resultados aplicando algoritmos genéticos.

	Etiqueta	Prueba	Predicción	Diferencia
0	SEC1.2	1.20	0.68	0.52
1	CM2.8	2.80	2.70	0.10

2	SEC4	4.00	5.31	1.31
3	MOY5.2	5.2	7.84	2.64
4	MOY0.5	0.50	-0.62	1.12
5	SEC3.6	3.60	4.44	0.84
6	CM9.6	9.60	7.39	2.21
7	CM2.6	2.60	3.51	0.91
8	MOY7.8	7.80	9.18	1.38
9	MOY7.6	7.60	9.26	1.66
10	SEC9.6	9.60	9.18	0.42
11	CM3.2	3.20	4.21	1.01
12	MOY2.8	2.80	3.21	0.41
13	CM1.6	1.60	2.11	0.51
14	SEC5.6	5.60	6.63	1.03
15	MOY8.6	8.60	8.08	0.52
16	MOY0.6	0.60	-0.77	1.37
17	MOY8	8.00	7.40	0.60
18	SEC11.4	11.40	9.84	1.56
19	MOY9	9.00	9.78	0.78
20	MOY9.6	9.60	9.40	0.20
21	SEC2.2	2.20	2.91	0.71
22	MOY0.2	0.20	-0.23	0.43
23	CM8	8.00	8.47	0.47
24	SEC4.5	4.50	6.28	1.78
25	MOY8.4	8.40	8.38	0.02
26	MOY0.4	0.40	-0.20	0.60
27	MOY4.6	4.60	6.30	1.70
28	CM5.4	5.40	6.57	1.17
29	MOY6	6.00	7.17	1.17
30	MOY8.8	8.80	9.09	0.29
31	MOY1.6	1.60	1.26	0.34
32	CM4.2	4.20	4.04	0.16
33	SEC7.4	7.40	7.73	0.33
34	MOY10.6	10.60	9.41	1.19

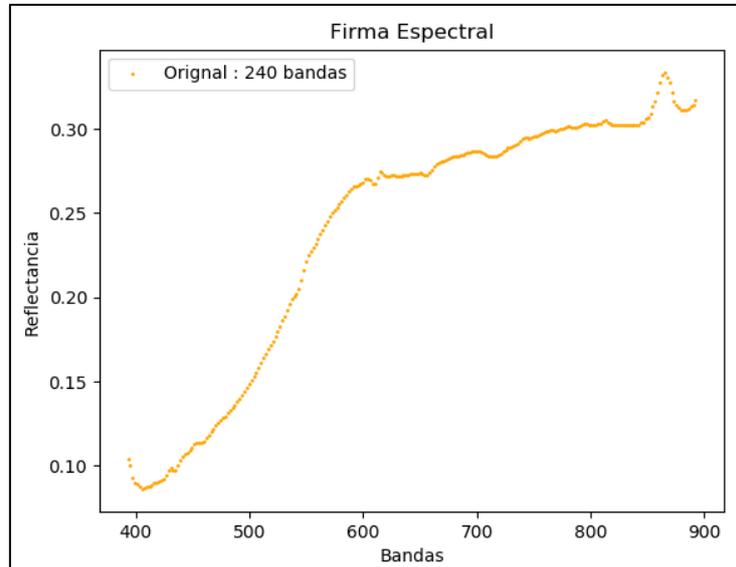
35	SEC6.6	6.60	4.99	1.61
36	CM3.4	3.40	6.80	3.40
37	SEC6.5	6.50	6.99	0.49
38	MOY1.4	1.40	0.86	0.54
39	CM1	1.00	0.59	0.41
40	SEC0.6	0.60	1.18	0.58
41	MOY9.5	9.50	9.11	0.39
42	SEC6.4	6.40	6.58	0.18
43	MOY3.4	3.40	3.65	0.25
44	CM9.8	9.80	8.02	1.78
45	MOY5	5.00	7.26	2.26
46	CM6.4	6.40	6.74	0.34
47	SEC10.8	10.80	8.19	2.61
48	CM7.5	7.50	6.73	0.77
49	MOY0	0.00	1.85	1.85
50	MOY6.5	6.50	6.55	0.05
51	SEC4.6	4.60	5.72	1.12
52	MOY2.2	2.20	2.11	0.09
53	MOY1.8	1.80	-0.41	2.21
54	CM5.2	5.20	6.78	1.58
55	SEC0.8	0.80	0.94	0.14
56	CM10.75	10.75	9.44	1.31
57	CM9	9.00	9.77	0.77
58	SEC5.8	5.80	6.47	0.67

Fuente: Elaboración propia.

Como se puede apreciar los errores son mínimos, hay muchos que tienden aproximadamente a 0, eso quiere decir que están muy cerca del valor de referencia, lo que se ve referenciado en el aumento de la correlación a comparación del anterior método.

Comparando los 2 métodos, el método de redes neuronales es bueno, ya que la correlación no está muy alejada de la unidad, sin embargo, al utilizar algoritmos genéticos se obtuvieron resultados óptimos esto es debido a que relaciona muy bien los datos y hacen que todos tiendan a una misma dirección, sin desviarse ninguno. Además, escoge los datos que contienen más

información, aquellos datos que puedan describir el comportamiento espectral del material (firma espectral), sin necesidad de utilizar las 240 bandas. En este caso 27 bandas son las de mayor importancia.

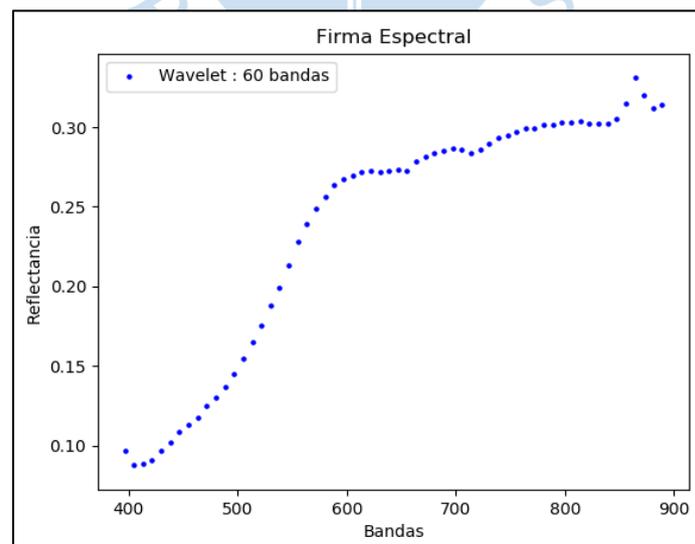


**Figura 58.** Firma espectral original.

**Fuente:** Elaboración propia.

Esta gráfica corresponde a la firma espectral de la arena con un porcentaje de humedad de 9.8%, a la cual la definen 240 bandas.

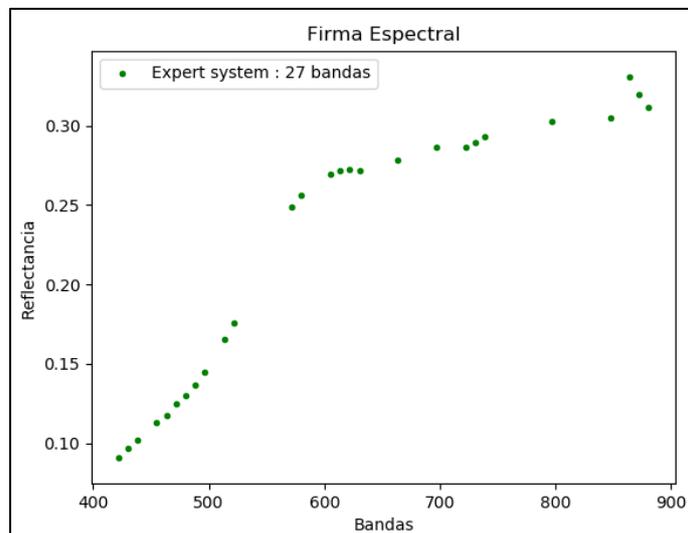
Utilizando la transformada avanzada de Fourier, se escogieron solo 60 bandas obteniendo un buen valor de correlación (0.83), como ya se mencionó anteriormente.



**Figura 59.** Firma espectral por redes neuronales.

**Fuente:** Elaboración propia.

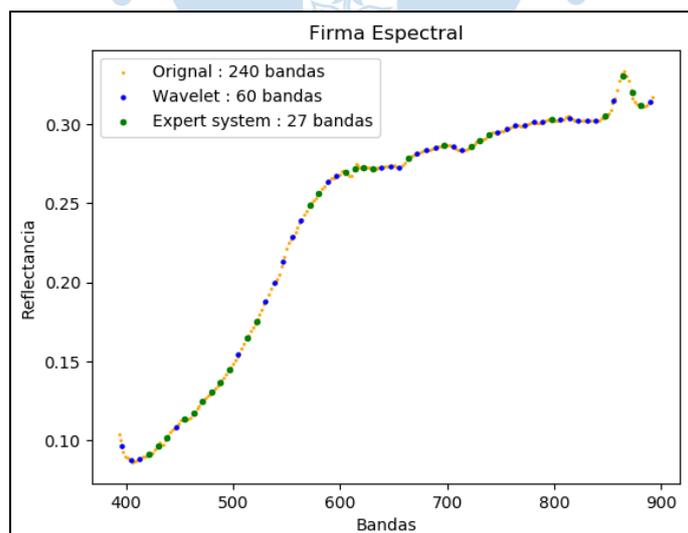
Finalmente utilizando algoritmos genéticos solo se necesitan 27 bandas para poder describir de perfectamente la firma espectral del material. Es aquí donde la correlación incrementó hasta llegar a 0.93, muy cerca de la unidad.



**Figura 60.** Firma espectral por algoritmos genéticos.

**Fuente:** Elaboración propia.

Concluyendo el disminuir las bandas hasta un número mucho menor al proporcionado por la cámara hiperespectral y eligiendo además los datos que aportan la mejor información, hacen que el valor de correlación aumente hasta llegar a un valor muy elevado, dando así un valor de predicción eficiente.



**Figura 61.** Firma espectral combinando los 2 métodos utilizados

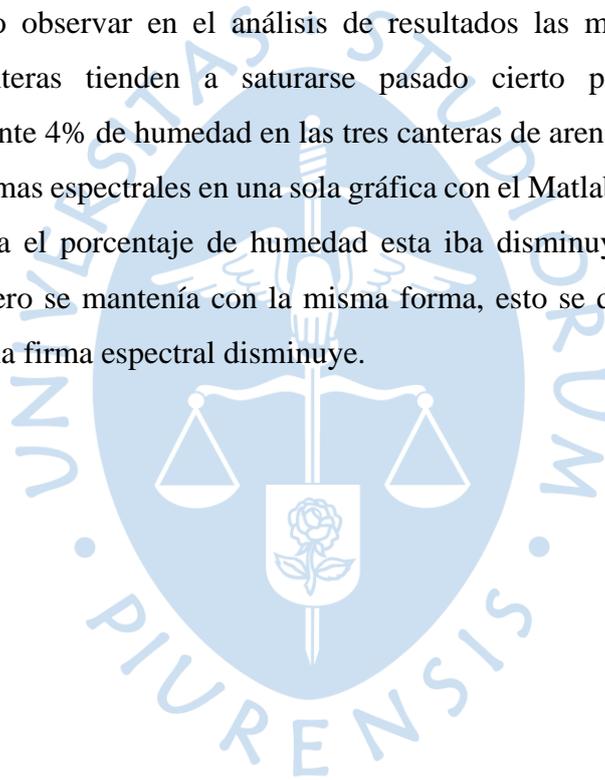
**Fuente:** Elaboración propia.



## Conclusiones

- 1) La cámara hiperespectral es una máquina muy eficiente debido a que nos ayuda a capturar la imagen del objeto, para poderlo visualizar por un medio digital se utilizó el software *SpectronPro*, con el cual se ha podido calcular la firma espectral (huella digital del material) de las diferentes canteras que hemos evaluado.
- 2) El método realizado con la transformada *Wavelet* es eficiente, ya que permite eliminar las multicolinealidades y la dimensionalidad existente en el cubo de 240 bandas, resultando así 60 bandas con información significativa, permitiéndonos hallar una correlación aceptable de 0.87.
- 3) A partir de las bandas obtenidas con el sistema experto (redes neuronales), podemos llegar a comprar un espectrómetro con menor número de bandas, ya que nuestro modelo te dice que bandas son las de mayor relevancia, reduciendo el costo y el tiempo de procesamiento.
- 4) El sistema experto (algoritmos genéticos) optimiza el anterior método descartando aquellas bandas que aportan menos información, permaneciendo así las que son relevantes y describen completamente el sistema y es así como se redujeron a 27 bandas de las 60 seleccionadas anteriormente (redes neuronales), obteniendo como resultado una correlación de 0.93, relativamente ideal, lo que demuestra que el sistema funciona.
- 5) Al obtener el valor preciso de la humedad en la arena en cualquier instancia se puede saber si es o no factible que tenga ese porcentaje y si no es así rápidamente poder modificar para que así al momento de realizar la mezcla y dar como producto el concreto tengan las propiedades mecánicas que se pensó en un principio.
- 6) El programa es veloz por la reducción de bandas, además se usa un lenguaje de programación rápido, que es el Python, se puede integrar con un módulo de actualización y una base de datos, en conclusión, es accesible, además es implementable en tiempo real.

- 7) Hay menos probabilidad de que un error sea grande, los errores que se producen no son por el modelo si no que se desarrollan por causas externas que no depende de este, el sistema frente a perturbaciones no se desvía, esto se demuestra escogiendo firmas aleatoriamente y funciona de la misma forma en todas las pruebas, esto quiere decir que el sistema es robusto.
- 8) Cuando se aplica la recta de regresión en Excel se obtienen valores aproximados del porcentaje de humedad, sin embargo, esta ecuación es muy particular pues solo sirve para la cantera de análisis, para cierta longitud de onda y solo puede predecir de 0% a 4% de humedad, es por ello que mediante el método de regresión múltiple no es factible realizar este trabajo debido a que no se tienen en cuenta otros factores.
- 9) Como se pudo observar en el análisis de resultados las muestras de arena de las diferentes canteras tienden a saturarse pasado cierto porcentaje de humedad, aproximadamente 4% de humedad en las tres canteras de arena analizadas.
- 10) Al sacar las firmas espectrales en una sola gráfica con el Matlab se apreció que mientras más aumentaba el porcentaje de humedad esta iba disminuyendo en sus valores de reflectancia, pero se mantenía con la misma forma, esto se debe a que mientras más agua contiene la firma espectral disminuye.



## Recomendaciones

- Para que las firmas espectrales en el software *SpectrononPro* sean lo más exactas posibles, se tiene que realizar el procedimiento adecuado para el cálculo de la humedad que, posteriormente se va a añadir a cada una de las muestras de diferentes canteras, ya que si no es así habrá error al momento de compararlas con las demás firmas obtenidas.
- El proceso de secado de las canteras que se quiere evaluar se tiene que hacer en un horno con una temperatura de aproximadamente de  $110 \pm 5^{\circ}\text{C}$  y tienen que quedarse por lo menos 1 día para que así la humedad tienda a 0 y no influya en la toma de datos con la cámara hiperespectral.
- Se debe de calibrar de manera correcta la cámara hiperespectral porque si se pasa por alto, los datos que se obtendrán serán erróneos ya que habrá problemas de calidad e incluso de modificación de datos, en otras palabras, el instrumento será inestable. Es por eso por lo que es importante calibrar porque garantiza que la desviación de los datos sea mínima.
- Como se sabe, una parte de la cámara hiperespectral está conformada por 4 focos, el cual transfiere calor en exceso, eso quiere decir que, al realizar la captura de foto de una muestra, rápidamente se tiene que extraer del soporte de la cámara porque puede llegar a secar la muestra mínimamente, que de igual manera influirá si es que se quiere realizar otra toma, ya que en algunos casos la foto obtenida no es la que se requiere.
- Un posible trabajo a futuro es crear un sensor con solo introducir la arena, este nos arroje los datos, es decir nos muestre su contenido de humedad, además, un plus sería que reconozca que tipo de arena se le está presentando.



## Referencias bibliográficas

- Cherre Pupuche, C. V. (2019). Medición de parámetros de calidad de harina de pescado usando imágenes hiperespectrales e inteligencia artificial.
- Fallas, G. G., Madrigal, C. H., García, M. P., Valenciano, I. R., Vega, L. D. R., & Guzmán, G. S. (2012). Efecto de la variación agua/cemento en el concreto. *Tecnología en marcha*, 25(2), 80-86.
- Fiszelew, A. B. E. L., García-Martínez, R., & de Buenos Aires, T. (2002). Generación automática de redes neuronales con ajuste de parámetros basado en algoritmos genéticos. *Revista del Instituto Tecnológico de Buenos Aires*, 26, 76-101.
- González, Y. D., & Romero, Y. F. (2012). Patrón Modelo-Vista-Controlador. *Telemática*, 11(1), 47-57.
- Izaurieta, F., & Saavedra, C. (2000). *Redes neuronales artificiales*. Departamento de Física, Universidad de Concepción Chile.
- Matich, D. J. (2001). *Redes Neuronales: Conceptos básicos y aplicaciones*. Universidad Tecnológica Nacional, México.
- Matilla Vicente, M. D. C. (2005). *Influencia de los efectos térmicos en la medida de la masa: análisis de las corrientes de convección por termografía infrarroja* (Doctoral dissertation, Telecomunicacion).
- Mena Frau, C., & Montecinos Guajardo, R. (2006). Comparación de redes neuronales y regresión lineal para estimar productividad de sitio en plantaciones forestales, utilizando geomática. *Bosque (Valdivia)*, 27(1), 35-43.
- Morales, Y. J., & Torres, C. O. (2009). Correlación digital de imágenes comprimidas por transformada wavelet. *Bistua: Revista de la Facultad de Ciencias Básicas*, 7(1), 1-5.
- Padilla, D. P. A., & Mumañ, F. C. (2008). *Métodos de identificación dinámica*. Facultad de Ingeniería Eléctrica. Universidad de Oriente.

- Pedrosa, María José (2016). Panorama mundial de la construcción [Internet]. <https://www.construccion-pa.com/noticias/panorama-mundial-la-construccion>.
- Pinos-Vélez, E., Encalada, S., Gamboa, E., Robles-Bykbaev, V., Ipanaqué, W. y Chacón, CL (julio de 2017). Desarrollo de un sistema de apoyo para el diagnóstico presuntivo de glaucoma mediante el procesamiento de imágenes biomédicas del fondo de ojo humano en Ecuador. En Conferencia internacional sobre factores humanos aplicados y ergonomía (págs. 100-109). Springer, Cham.
- Ramírez, G., Vasquez, M., Camardiel, A., Pérez, B., & Galindo, P. (2005). Multicollinearity Detection by Means of the h-Plot of the Correlation Matrix Inverse. *Revista Colombiana de Estadística*, 28(2), 207-219.
- Reyes, J. M. R., Bohorquez, J. S., & Ipanaqué, W. (2016). Evaluation of spectral relation indexes of the Peruvian's cocoa beans during fermentation process. *IEEE Latin America Transactions*, 14(6), 2862-2867.
- Soto Bohórquez, J. C. (2017). Evaluación de la calidad de los granos de cacao por imágenes hiperespectrales basadas en técnicas de lógica difusa.
- Soto, J., Granda, G., Prieto, F., Ipanaqué, W. y Machacuay, J. (2015, abril). Evaluación de la calidad del grano de cacao mediante el uso de imágenes hiperespectrales y técnicas de lógica difusa. En la Duodécima Conferencia Internacional sobre Control de Calidad por Visión Artificial 2015 (Vol. 9534, p. 95340M). Sociedad Internacional de Óptica y Fotónica.
- Soto, J., Paiva, E., Ipanaqué, W., Reyes, J., Espinoza, D. y Mendoza, D. (octubre de 2017). Evaluación de la calidad del grano de cacao mediante el uso de índice hiperespectral para determinar el estado de fermentación con un análisis no destructivo. En 2017 Conferencia CHILENA de Ingeniería Eléctrica, Electrónica, Tecnologías de la Información y las Comunicaciones (CHILECON) (págs. 1-5). IEEE.
- Soto, J., Ruiz, J., Ipanaqué, W., & Chinguel, C. (2016, October). New hyperspectral index for determining the state of fermentation in the non-destructive analysis for organic cocoa violet. In 2016 IEEE International Conference on Automatica (ICA-ACCA) (pp. 1-6). IEEE.

**Anexos**





Anexo A. Artículo presentado en el 2019 CHILEAN Conference on Electrical, Electronics, Engineering, Information and Communication Technologies, 2019, Chile.

# Determination of Moisture Content in Concrete Aggregates using Machine Learning algorithms and Hyperspectral Imaging

Miguel Delgado, Edson Effio, Ney Farfán, William Ipanaqué, Juan Soto.

**Abstract**— *The quantification of moisture content in various economic areas and in different industrial processes has been a parameter investigated over many years because it serves to estimate the quality, durability and other important parameters at commercial and environmental level. This paper presents a summary of the advancement obtained in recent years in moisture measurement techniques, as well as a new classification of the most representative methods, as mentioned in research and scientific articles. The applications of traditional direct techniques, such as the Karl Fischer titration or the thermogravimetric method are discussed, as well as approaches that use NIR image processing, neural networks, or microwaves, among others. Environmental applications such as soil moisture measurement using radiometry and prediction algorithms are reviewed as well. Furthermore, the most prominent methods are analysed in detail, describing the way they are performed, their advantages and disadvantages, the most relevant applications and the main challenges that should be investigated further.*

**Keywords**- moisture, hyperspectral image, concrete aggregate.

## I. INTRODUCCIÓN

A nivel mundial, uno de los sectores con mayor crecimiento es el de la construcción [1]; tanto de edificios, centros comerciales, casas, etc. Para su realización, el concreto es un elemento indispensable, debido a su duración [2], alta resistencia, impermeabilidad, facilidad de producción y economía. Este se fabrica mezclando homogéneamente: cemento, agua, arena, grava y para casos especiales se adhieren aditivos.

Este artículo ha sido posible por el apoyo de FONCECYT-SENCICO en el proyecto "Tecnologías facilitadores basadas en técnicas de microondas para la medición en tiempo real del contenido de humedad en materiales de la construcción" - Contrato 108-2017. Agradecemos también al Laboratorio de Sistemas Automáticos de Control y Laboratorio de Ensayo de Materiales de la Universidad de Piura por el apoyo recibido. Finalmente agradecemos a nuestros familiares por el apoyo incondicional, que nos brindaron desde el inicio de este gran proyecto.

Th J. Soto. Author is with Automatic Control System Laboratory, Universidad de Piura, Piura, 20001 PE (juan.soto@udep.pe)

W. Ipanaqué. Author is with Automatic Control System Laboratory, Universidad de Piura, Piura, 20001 PE (william.ipanaque@udep.pe).

M. Delgado. Author is with Automatic Control System Laboratory, Universidad de Piura, Piura, 20001 PE (miguel.delgado@pregrado.udep.edu.pe).

N. Farfan. Author is with Automatic Control System Laboratory, Universidad de Piura, Piura, 20001 PE (ney.farfán@pregrado.udep.edu.pe).

E. Effio. Author is with Automatic Control System Laboratory, Universidad de Piura, Piura, 20001 PE (edson.effio@pregrado.udep.edu.pe)

Actualmente, la elaboración del concreto [3] no cuenta con instrumentos para la medición en línea de la humedad, sino se obtiene mediante métodos en el laboratorio y eso ocasiona ciertas variaciones del contenido de humedad en el concreto afectando a las propiedades del producto.

Existen métodos de medición del contenido de humedad en los agregados de concreto, estos pueden ser directos e indirectos. Tenemos el método térmico gravimétrico [4], en el que después de 24 horas recién se obtiene el resultado, esta sería una dificultad teniendo en cuenta que el contenido de humedad en los agregados varía de un día para otro. Otro método es el químico, en el cual se determina el contenido de humedad realizando reacciones químicas. La aplicación de este método es laboriosa y no es aplicable en línea. Por otro lado, la medición indirecta permite una medición en línea mediante una previa calibración por métodos directos. Se divide en dos grupos: Medición activa y pasiva. La medición pasiva utiliza componentes electrónicos "pasivos" ya sea capacitancias o resistencias para poder calcular el contenido de humedad acorde a la variación de los parámetros. La medición activa se basa en los principios electromagnéticos y permite la automatización del proceso. El uso de imágenes hiperespectrales ha tenido buen éxito en bio ingeniería [5] y en agroindustria: [6], [7], [8], [9].

## II. MATERIALES Y MÉTODOS.

### A. *Materia Prima*

Para este estudio se utilizaron 3 canteras de arena, las cuales son: Moyobamba, Cerro Mocho y Sechura todas ubicadas en Perú. Al llegar al laboratorio, se prosiguió a realizar las mediciones estándares de cada cantera para que así todas estén parametrizadas y el porcentaje de error sea mínimo. Por ende, las muestras fueron almacenadas en un horno por 1 día a una temperatura de 110+-5°C para que así la humedad logre disminuir totalmente.

### B. *Preparación de las muestras*

Al extraer las muestras del horno, de cada cantera se decidió obtener 65 muestras de cada una de ellas con el objetivo de administrarle diferente porcentaje de humedad.

La humedad que se le agregó a la arena fue por decisión grupal, se comenzó desde 0% y se aumentó cada 0.2%, llegando a 12% en la última muestra, además se tomaron datos cada 0.5% para obtener un mayor número de muestras.

Los gramos de agua que se añadieron a las 65 muestras se calcularon de la siguiente manera:

$$\text{gramos de cada muestra} * \% \text{ de humedad} = \text{gramos de agua}$$

Como ya se conoce los gramos de cada muestra (200g) y el porcentaje de humedad, fácilmente se logra calcular cuánto gramos de agua hay que añadirle a cada una de ellas.

Una vez realizado esto se prosigue al estudio a partir de imágenes hiperespectrales [10], mediante la cámara hiperespectral [11]. Se usa el programa Spectronpro [12] para el análisis de cada muestra. El cual proporciona una gráfica reflectancia vs longitud de onda, definiendo la firma espectral.

### C. Procedimiento en la cámara hiperespectral

Se insertan las muestras de arena en un recipiente libre de impurezas, para no obtener resultados erróneos.

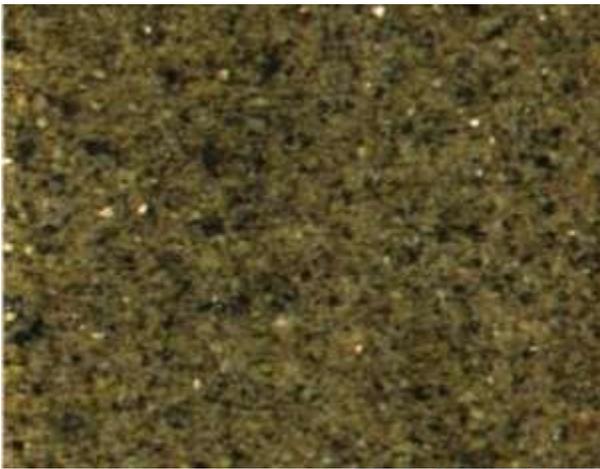


Fig. 1: Muestra de Arena de la Cantera de Sechura.

Se empieza la etapa de traslación, en donde se capta la imagen. La cámara hiperespectral está conectada a una computadora, se hace uso del software Spectronpro y se guarda el cubo espectral.

Se escoge una región de interés de la imagen (ROI) para el estudio.

Finalmente se importa el espectro y proyecta la firma espectral, que es una gráfica reflectancia vs longitud de onda.

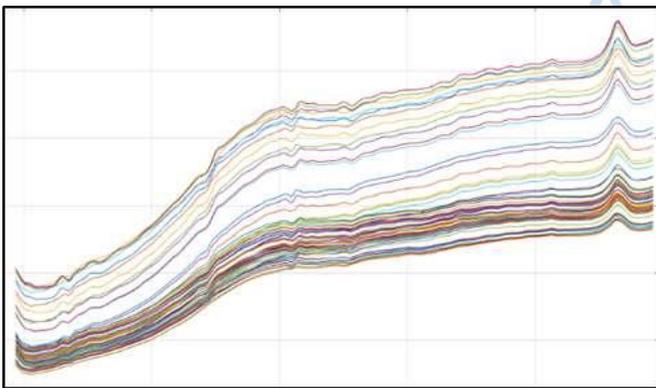


Fig. 2: Firmas espectrales de la cantera de Cerro Mocho con diferente porcentaje de humedad.

## III. RESULTADOS Y DISCUSIONES

Una vez obtenida la firma espectral de cada una de las muestras, fueron analizadas con ayuda del software Python [13].

El cubo conformado por 240 bandas tiene multicolinealidades [14] y bastante dimensionalidad, por lo tanto, se realizó un algoritmo de reducción de información y características [15], que nos proporciona mejores resultados con una data más comprimida. Se utilizó la transformada wavelet que es una extensión de la transformada avanzada de Fourier [16], esta atenaza secciones de la firma espectral, analiza una por una consecutivamente y luego reconstruye esas secciones, la cual no solo analiza la frecuencia si no también su espectro, forma y tiempo de desplazamiento [17].

### 3.1. Discusión de resultados utilizando redes neuronales.

Se manguó las bandas a 60, las cuales son ricas en información, pues no tienen valores redundantes.

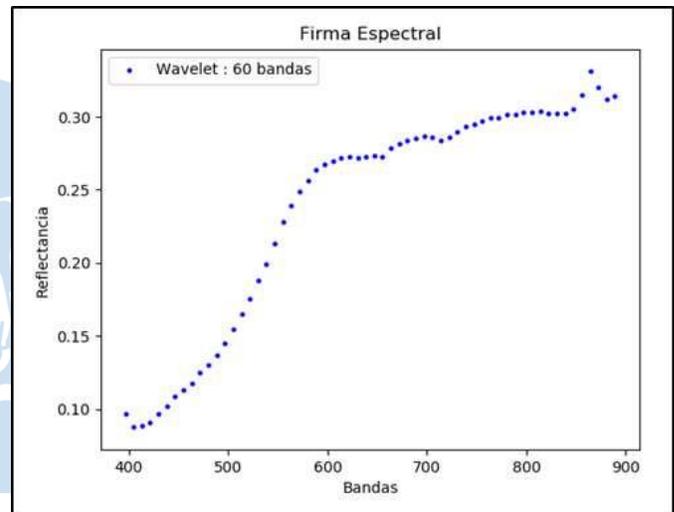


Fig. 3. Firma espectral de las 60 bandas

Estas se ingresan al machine learning[18], obteniéndose un sistema MISO (Multivariable Input Simple Out) [19]. Se tomaron 70% de las muestras para entrenar y 30% para probar aleatoriamente [20], se usó una capa de redes neuronales multilayer perceptron backpropagation[21] en donde el número de capas de entrada son las 60 bandas, 1 capa de salida de 1 neurona que es la correlación y dos capas ocultas de 5 neuronas cada una.

Como se mostrará en la siguiente tabla la predicción al utilizar la transformada de wavelet junto con las redes neuronales, se asemeja bastante a algunos datos de prueba, con diferencias mínimas en la mayoría de los casos, sin embargo, existen datos atípicos pues la diferencia que existe entre los valores de prueba y predichos es significativa.

	ETIQUETA	PRUEBA	PREDICCION	DIFERENCIA
0	SEC1.2	1.2	1.15	0.05
1	CM2.8	2.8	2.31	0.49
7	CM2.6	2.6	2.02	0.58
34	MOY10.6	10.6	9.06	1.54
14	SEC5.6	5.6	6.33	0.73
36	CM3.4	3.4	6.66	3.26
19	MOY9	9	9.58	0.58
29	MOY6	6	5.72	0.28
32	CM4.2	4.2	4.74	0.54
33	SEC7.4	7.4	7.15	0.25
41	MOY9.5	9.5	8.29	1.21
47	SEC10.8	10.8	7.85	2.95

Tabla N°01: Datos obtenidos en Transformada de Wavelet

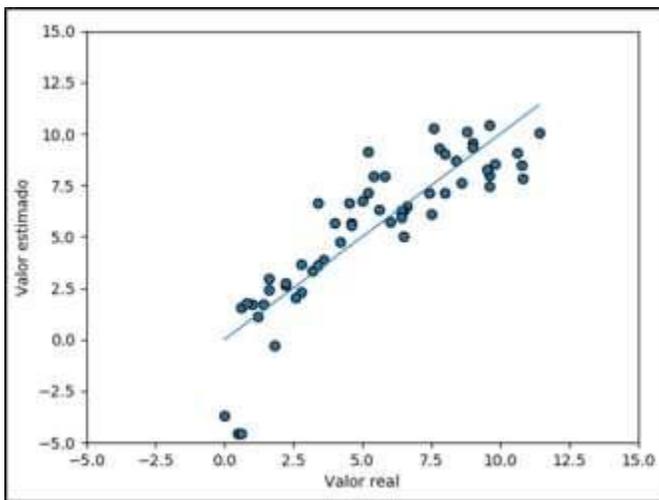


Fig. 4. Correlación Transformada de Wavelet

Como se puede apreciar en la Fig. 4, existen datos que no siguen la tendencia de los demás, sin embargo, son muy pocos. Gracias a este método se obtiene un valor de correlación de 0.87, el cual es un resultado muy aceptable. Los valores que no siguen la tendencia de las demás quizás sean debido a que la arena no estaba muy escaamentada en la toma de la imagen de la cámara espectral.

### 3.2. Discusión de resultados utilizando sistema experto.

Los sistemas que operan con algoritmos genéticos [22] se encuentran elaborados por múltiples algoritmos el cual tiene por finalidad encontrar un patrón en los datos [23], para así clasificar, predecir, identificar modelos y agrupándolos convenientemente. El proceso de aprendizaje automático [24] toma importancia cuando no se tiene un modelo matemático [25] o es muy complicado de modelar por métodos de identificación [26].

Para optimizar el modelo se utilizó un sistema experto, que emplea múltiples técnicas de inteligencia artificial, es un sistema a lazo cerrado que examina las menos y más significativas dentro de las 60 bandas para optimizar la correlación en cada iteración, multiplica la matriz de bandas con otra formada por 0 y 1, en donde las primeras son las

bandas que proporcionan menos información y las otras las que proporcionan más información, eliminando las que se multiplican por 0, este proceso se repite hasta encontrar el punto óptimo, en donde la correlación sea máxima y los datos sean los menores posibles, quedando el vector de número de bandas más relevantes.

Al aplicar este algoritmo el número de bandas se redujo a 27 las que contienen la mayor cantidad de información, estas se muestran en la Fig. 5.

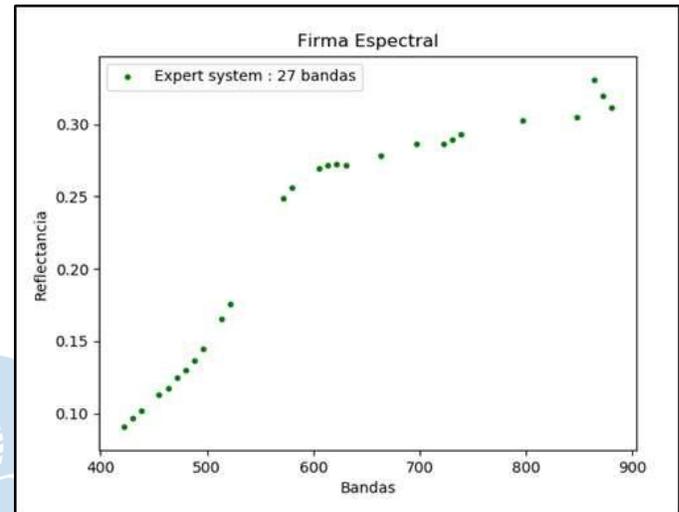


Fig. 5. Firma espectral de 27 bandas

El vector de bandas se retorna al modelo simple de inteligencia artificial y se ensaya con el nuevo número de bandas, se reajusta la red neuronal, obteniéndose una correlación más alta por lo que se comprueba el buen funcionamiento del sistema y del modelo.

Como se mostrará en la siguiente tabla la predicción al utilizar los sistemas expertos junto con las redes neuronales, se asemeja bastante a algunos datos de prueba, con diferencias mínimas en todos los casos, los resultados obtenidos son admisibles y se redujo bastante la diferencia que existía por el otro método de reducción de bandas.

	ETIQUETA	PRUEBA	PREDICCION	DIFERENCIA
0	SEC1.2	1.2	0.77	0.43
1	CM2.8	2.8	2.67	0.13
2	SEC4	4	5.23	1.23
4	MOY0.5	0.5	-0.66	1.16
5	SEC3.6	3.6	4.38	0.78
10	SEC9.6	9.6	9.11	0.49
11	CM3.2	3.2	4.31	1.11
12	MOY2.8	2.8	3.12	0.32
13	CM1.6	1.6	2.12	0.52
14	SEC5.6	5.6	6.51	0.91
22	MOY0.2	0.2	-0.21	0.41
32	CM4.2	4.2	4.07	0.13

Tabla N°02: Datos obtenidos en mediante Inteligencia Artificial.

Gracias al método de sistemas expertos [27] en conjunto con las redes neuronales, hacen que la correlación mejore de tal manera que el nivel de confianza aumente, y esto lo hace determinando las bandas que interesan y anulando las bandas que no tienen mucha importancia, por lo que la correlación mejoró al 0.93, el cual es un valor muy alto, por lo que el modelo si funciona.

En la Fig. 6 se muestra el gráfico de la correlación.

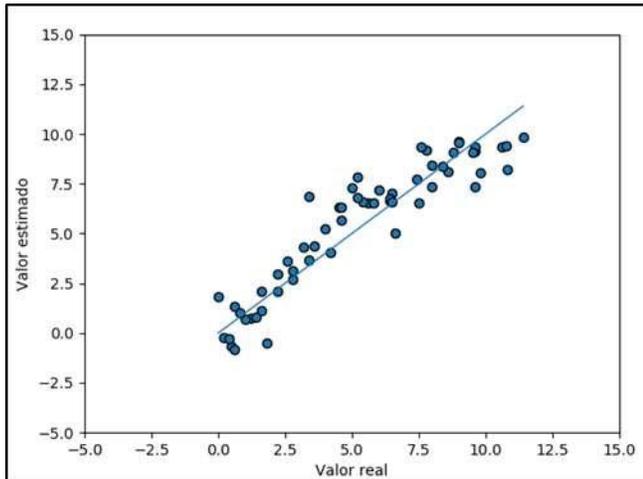


Fig. 6. Correlación Inteligencia Artificial

Finalmente se realizó una gráfica la cual está compuesta por los 2 métodos explicados anteriormente como la firma espectral tomada directamente de la cámara.

En la Fig. 7 se puede observar como todos los datos tienden hacia la misma dirección, también se eliminan los datos atípicos que se encontraron con el primer método.

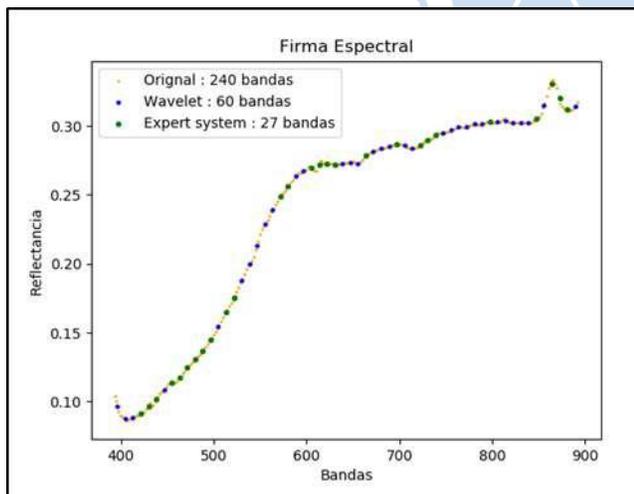


Fig. 7. Gráfica superponiendo la firma espectral original, la de redes neuronales y algoritmos genéticos.

#### IV. CONCLUSIONES

1) El método realizado con la transformada Wavelet es eficiente, ya que permite eliminar las multicolinealidades y la dimensionalidad existente en el cubo de 240 bandas, resultando así 60 bandas ricas en información y permitiéndonos hallar una correlación aceptable de 0.87.

- 2) El sistema experto optimiza el anterior método descartando aquellas bandas que aportan menos información, permaneciendo así las que son relevantes y describen completamente el sistema, reduciéndose así a 27 bandas de las 60 seleccionadas anteriormente y obteniendo como resultado una correlación de 0.93, relativamente ideal, lo que demuestra que el sistema funciona.
- 3) A partir de las bandas obtenidas con el sistema experto, podemos llegar a comprar un espectrómetro con menor número de bandas, ya que nuestro modelo te dice que bandas son las de mayor relevancia, reduciendo el costo y el tiempo de procesamiento.
- 4) El programa es rápido por la reducción de bandas, además se usa un lenguaje de programación rápido, que es el python, se puede integrar con un módulo de actualización y una base de datos, en conclusión, es accesible, además es implementable en tiempo real.
- 5) Hay menos probabilidad de que un error sea grande, los errores que se producen no son por el modelo si no que se desarrollan por causas externas que no depende de este, el sistema frente a perturbaciones no se desvía, esto se demuestra escogiendo firmas aleatoriamente y funciona de la misma forma en todas las pruebas, esto quiere decir que el sistema es robusto.

#### V. AGRADECIMIENTOS

Este artículo ha sido posible por el apoyo de FONCECYT-SENCICO en el proyecto "Tecnologías facilitadoras basadas en técnicas de microondas para la medición en tiempo real del contenido de humedad en materiales de la construcción" - Contrato 108-2017. Agradecemos también al Laboratorio de Sistemas Automáticos de Control y Laboratorio de Ensayo de Materiales de la Universidad de Piura por el apoyo recibido. Finalmente agradecemos a nuestros familiares por el apoyo incondicional, que nos brindaron desde el inicio de este gran proyecto.

#### VI. REFERENCIAS

- [1] Pedrosa, María José (2016). Panorama mundial de la construcción [Internet]. <https://www.construccion-pa.com/noticias/panorama-mundial-la-construccion>.
- [2] Valdés, Adriana (2017). Durabilidad del concreto: Conceptos y sostenibilidad. <http://www.hormigonespecial.com/blog/?p=349>.
- [3] Guevara, G; Hidalgo, C; Pizarro, M; Rodríguez, I; Rojas, L; Segura, G. Efecto de la variación del agua/cemento en el concreto. Tecnología en Marcha. Vol. 25, N° 2. Abril-Junio 2012. pp 80-86.
- [4] Matilla Vicente M (2005). Influencia de los efectos térmicos en la medida de la masa: análisis de las corrientes de convección por termografía infrarroja. Tesis doctoral España. Capítulo IV.
- [5] Pinos-Vélez, E., Encalada, S., Gamboa, E., Ipanaqué, W., Chacón, C.L. 2018. Development of a support system for the presumptive diagnosis of glaucoma through the processing of biomedical images of the human eye fundus in Ecuador.
- [6] Soto, J., Paiva, E., Ipanaqué, W., Espinoza, D., Mendoza, D. Cocoa bean quality assessment by using

- hyperspectral index for determining the state of fermentation with a non-destructive análisis (2017), CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies, CHILECON 2017 – Proceedings.
- [7] Ruiz Reyes, J.M. and Soto Bohorquez, J. and Ipanaque, W. Evaluation of spectral relation indexes of the Peruvians cocoa beans during fermentation process. *IEEE Latin America* (2016). volume 14, pp: 2862-2867. Contributor: Ruiz Reyes, J.M. Soto Bohorquez, J. Ipanaque, W.
- [8] Soto, J. and Ruiz, J. and Ipanaqué, W. and Chinguel, C. New hyperspectral index for determining the state of fermentation in the non-destructive analysis for organic cocoa violet. *IEEE International Conference on Automatica, ICA-ACCA 2016*. Contributor: Soto, J. Ruiz, J. Ipanaqué, W. Chinguel, C.
- [9] Soto, J. and Granda, G. and Prieto, F. and Ipanaque, W. and Machacuay, J. Cocoa bean quality assessment by using hyperspectral images and fuzzy logic techniques. *Proceedings of SPIE - The International Society for Optical Engineering* (2015), volume: 9534. Contributor: Soto, J. Granda, G. Prieto, F. Ipanaque, W. Machacuay, J.
- [10] Camacho Velasco A; Vargas García C; Rojas Morales F; Castillo Castelblanco S; Arguello Fuentes H. *Advances in Intelligent Systems and Computing*. Vol. 24, N°. 40, (2015), pp. 17-29.
- [11] Yao-Ze F, Gamal E, Sun A, Scannell, Des W y Morcy N. Imágenes hiperespectrales en el infrarrojo cercano y regresión de mínimos cuadrados parciales para la determinación rápida y sin reactivos de enterobacterias en filetes de pollo. *Food Chemistry*, vol. 138, pp. 1829–1836, 2013.
- [12] Soto-Bohórquez J. Evaluación de la calidad de los granos de cacao por imágenes hiperespectrales basadas en técnicas de lógica difusa (2017). pp 25- 27.
- [13] Challenger-Pérez, Ivett, Díaz-Ricardo, Yanet, Becerra-García, Roberto Antonio, El lenguaje de programación Python. *Ciencias Holguín [en línea]* 2014, XX (Abril-Junio)
- [14] Ramirez G, Vasquez M, Camardiel A, Perez B, Galindo P. Multicollinearity Detection by Means of the h-Plot of the Correlation Matrix Inverse (2005).
- [15] Rivero Pérez J. Machine learning techniques for intrusion detection in computer networks.. Universidad de Cienfuegos “Carlos Rafael Rodríguez” (2014).
- [16] Morales, Y. J.; Torres, C. O. Correlación Digital De Imágenes Comprimidas Por Transformada Wavelet Bistua: *Revista de la Facultad de Ciencias Básicas*, vol. 7, núm. 1, 2009, pp. 1-5 Universidad de Pamplona Pamplona, Colombia
- [17] Cortés J, Cano H, Chaves J. Del Análisis De Fourier A Las Wavelets - Transformada Continua Wavelet (Cwt). pp. 134-138 (2007).
- [18] Matich D, *Redes Neuronales: Conceptos básicos y Aplicaciones*, Rosario: Universidad Tecnológica Nacional – Facultad Regional Rosario (2001).
- [19] Velasco Pérez A, Álvarez Ramírez J, y R. Solar González. Multiple input–single output (MISO) control of a CSTR (2011).
- [20] Cherre-Pupuche C. Medición de parámetros de calidad de harina de pescado usando imágenes hiperespectrales e inteligencia artificial Pág 13-15 (2019).
- [21] S, Mohd Arif W. Comparative Study of Back Propagation Learning Algorithms for Neural Networks (2013).
- [22] Fiszelew & García-Martínez. Generación automática de redes neuronales con ajuste de parámetros basado en algoritmos genético (2002).
- [23] Fernández Romero Y, Díaz González Y, Patrón de Modelo-Vista-Controlador. *Revista Telemática*. Vol. 11. No. 1 (2012).
- [24] Arafet P, Chang F, Torres M, Dominguez H. *Métodos de Identificación dinámica* Autores (2008).
- [25] Izaurieta F y Saavedra C, *Redes Neuronales Artificiales*, Departamento de Física, Universidad de Concepción, Concepción, Chile (2000).
- [26] Nieto N; Orozco D. El uso de la transformada wavelet discreta en la reconstrucción de señales senosoidales. *Scientia Et Technica*, vol. XIV, núm. 38, junio, 2008, pp. 381-386. Universidad Tecnológica de Pereira.
- [27] Pereira, Colombia, Carlos Mena F, Montecinos Guajardo R. Comparación de redes neuronales y regresión lineal para estimar productividad de sitio en plantaciones forestales, utilizando geomática. Universidad de Talca, Departamento de Gestión Forestal Ambiental (2016).