



FACULTAD DE INGENIERÍA Y CIENCIAS APLICADAS

CARACTERIZACIÓN DE IMÁGENES EN GRANOS DE ARROZ (INIAP 12) Y TRIGO (CANADA WESTERN RED SPRING), CON DISTINTAS HUMEDADES POR EL MÉTODO DE VISIÓN ARTIFICIAL.

AUTOR

Anthony Bolívar Jaramillo Arias

AÑO

2020



FACULTAD DE INGENIERÍA Y CIENCIAS APLICADAS

CARACTERIZACIÓN DE IMÁGENES EN GRANOS DE ARROZ (INIAP  
12) Y TRIGO (CANADA WESTERN RED SPRING), CON DISTINTAS  
HUMEDADES POR EL MÉTODO DE VISIÓN ARTIFICIAL.

Trabajo de Titulación presentado en conformidad con los requisitos establecidos  
para optar por el título de Ingenieras Agroindustrial y de Alimentos

Profesor Guía

Ph. D. Héctor Abel Palacios Cabrera

Autor

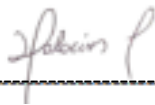
Anthony Bolívar Jaramillo Arias

AÑO

2020

## **DECLARACIÓN DEL DOCENTE GUÍA**

“Declaro haber dirigido el trabajo, Caracterización de imágenes en granos de arroz (iniap 12) y trigo (canada western red spring), con distintas humedades por el método de visión artificial, a través de reuniones periódicas con el estudiante Anthony Bolívar Jaramillo Arias, en el semestre 2020-1, orientando sus conocimientos y competencias para un eficiente desarrollo del tema escogido y dando cumplimiento a todas las disposiciones vigentes que regulan los Trabajos de Titulación”



-----  
Héctor Abel Palacios Cabrera.

Docente – Investigador de la Universidad de las Américas

C.I: 0912277480

## DECLARACIÓN DEL DOCENTE CORRECTOR

“Declaro haber dirigido el trabajo, Caracterización de imágenes en granos de arroz (iniap 12) y trigo (canada western red spring), con distintas humedades por el método de visión artificial., a través de reuniones periódicas con el estudiante Anthony Bolivar Jaramillo Arias, en el semestre 2020-1, orientando sus conocimientos y competencias para un eficiente desarrollo del tema escogido y dando cumplimiento a todas las disposiciones vigentes que regulan los Trabajos de Titulación”




---

Santiago Mauricio Olmedo Ron  
Magister en Gestión de la producción  
1705972394

## DECLARACIÓN DE AUDITORÍA DE LOS ESTUDIANTE

“Declaro que este trabajo es original, de mi autoría, que se han citado las fuentes correspondientes y que en su ejecución se respetaron las disposiciones legales que protegen los derechos de autor vigentes.



---

Anthony Bolívar Jaramillo Arias

C.I: 1104997257

## **AGRADECIMIENTOS**

Agradezco a mi familia que ha sido el eje principal para culminar mi carrera a mis amigos y mis docentes que me han apoyado.

## **DEDICATORIA**

A mi familia que ha sido el eje principal para culminar mi carrera a mis amigos y mis docentes que me han apoyado.

## Resumen

El trigo (*Triticum*), es uno de los cereales más consumidos a nivel mundial seguido del arroz (*Oriza sativa*), el incremento de la producción de trigo y arroz ha sido evidente en los últimos años , no obstante la calidad de estos cereales es crucial para mantener una inocuidad alimenticia y la humedad es el parámetro de medida para mantener un grano de calidad, en la actualidad existen equipos que sirven para detectar la humedad en cereales de forma rápida, pero trabajan con diferentes métodos que usan los rayos infra rojo , corriente alterna o termogravimetría. El presente estudio trata de caracterizar imágenes de granos de arroz (Iniap 12) y trigo (*Canada Western Red Spring*), teniendo como objetivos: Obtener una base de datos con patrones homogéneos de humedades entre 10 a 16 % del trigo y arroz y diseñar un algoritmo que correlacione los datos de visión artificial con el valor de humedad para los granos descritos, esta investigación se la realizó en diferentes etapas : se acondicionaron los granos través del método de Gough y fueron analizados los valores medios de los lotes preparados por ADEVA para determinar la homogeneidad de los patrones posteriormente se hizo la adquisición de imágenes digitales de los patrones de humedad entre 10 – 16% y se procesó con Python 3.0 para obtener un algoritmo. Fueron obtenidos muestras homogéneas en todos los lotes ensayados esto fue evidente debido a que el F calculado fue menor al F crítico en los ensayos estadísticos realizados, con respecto al algoritmo se determinó un código con una exactitud promedio entre 70-83% para el arroz Iniap 12 y una exactitud media de 45 % para el trigo CWRS.



## ABSTRACT

Wheat (*Triticum*), is one of the most consumed cereals worldwide followed by rice (*Oriza sativa*), according to the FAO in 2019, the world had a production of 2708 million tons of wheat and 476 million tons of rice which represents an increase with respect to the previous year, the increase in wheat and rice production has been evident, however the quality of these cereals is crucial to maintain food safety and humidity is the measurement parameter to maintain a Quality product, with an average humidity between 14 ± 1% maximum to avoid loss or damage due to unwanted microbial growth, currently there are devices that can detect humidity in cereals quickly, but work with an infrared vision spectrum. The present study tries to characterize images of rice grains (Iniap 12) and wheat (Canada Western Red Spring), with different humidities by an artificial vision method, that is, correlate digital images with the humidity present in rice grains and wheat by means of homogeneous humidity patterns between 10 to 16% and programming languages, in order to obtain an algorithm that uses the visible spectrum as a starting point to determine humidity. For this determination of standards, the Iso Inen 712 Standard was used, it was identified that the calculated F was less than the critical F, so I assure that the samples are homogeneous, for the determination of the algorithm, artificial vision was used for the acquisition of the photos by means of a model designed by the faculty of industrial production of the University of the Americas with horizontal view lighting, images of the patterns obtained by MATLAB were analyzed and an algorithm was obtained in the case of rice (Iniap 12) 70-80% precision and 45% for wheat (CWRS), which evidenced an algorithm that uses visible light to determine the humidity of the samples analyzed.

## ÍNDICE

|  |    |
|--|----|
| INTRODUCCIÓN.....  | 1  |
| 1. OBJETIVOS .....   | 3  |
| 1.1 Objetivo General .....   | 3  |
| 1.2 Objetivos específicos .....  | 3  |
| 2. MARCO TEÓRICO .....   | 3  |
| 2.1 Generalidades de los cereales.....   | 3  |
| 2.2 Estructura y composición de los cereales .....   | 5  |
| 2.3 Clasificación de los cereales .....  | 8  |
| 2.4 Generalidades de la producción de cereales .....   | 12 |
| 2.5 Importancia de la humedad en granos y cereales. ....                                       | 15 |
| 2.6 Generalidades de patrones .....  | 17 |
| 2.7 Generalidades de inteligencia artificial .....   | 19 |
| 2.7.1 SOFTWARE .....   | 28 |
| 3. MATERIALES Y MÉTODOS .....  | 30 |
| 3.1 Material vegetal.....  | 30 |
| 3.1.1. Localización.....   | 31 |
| 3.1.2. Equipos .....   | 32 |
| 3.2 Métodos .....  | 33 |
| 3.2.1 Método de visión artificial. ....  | 37 |
| 3.3 Estadística .....  | 45 |
| 4. RESULTADOS.....   | 45 |
| 4.1 Ensayo de homogeneidad.....  | 45 |
| 4.1.1 Preparación de patrones.....   | 45 |
| 4.2 Histogramas de distribución de colores en la imagen de arroz<br>Iniap 12 y trigo CWRS..... | 48 |
| 5. DISCUSIÓN .....   | 54 |
| 6. CONCLUSIONES .....  | 56 |
| 7. RECOMENDACIONES .....   | 56 |
| REFERENCIAS.....   | 57 |

## INTRODUCCIÓN

Los cereales concurrían desde tiempos antiguos, siendo sus antecesores plantas silvestres que modificaron su morfología en el transcurso de los tiempos con diferentes técnicas como: la hibridación, selección artificial, cruzamientos selectivos, mutagénesis selectiva, ingeniería genética, etc. La mayoría de los cereales tienen un origen en el viejo mundo que se ampliaron alrededor de la tierra, Aunque existían diferencias en su morfología, en la totalidad los cereales están protegidos por una cubierta y a su vez conformados por distintas partes en el grano, conformándose como componentes básicos: el germen, endospermo y el pericarpio,(Osca Lluch, 2013). Gran número pertenece a la familia de las Gramíneas, se definen como vegetales cultivados con sus propios granos, contienen un albumen amiláceo, listo para el consumo del ser humano tras su procesamiento, ya que el ser humano no puede digerir adecuadamente los granos o harinas crudas. (Osca,2013). Siendo uno de los alimentos básicos para la dieta humana y animal. (Owens, 2001).Por lo que la producción de esta fuente alimenticia va en aumento en el transcurso de los años.

Según la FAO, el pronóstico para el año 2019 del mundo es una producción situada a 2708 millones de toneladas con un crecimiento de 2.1 % a diferencia del año anterior, con un mayor crecimiento en el trigo , con 767 millones de toneladas que se han reportado en el año 2019, con un incremento de 5.5 % en comparación con el año 2018.(FAO, 2019). Y con respecto al arroz se registro 1099686 toneladas en el año 2019 teniendo un crecimiento del 3.1 % con respecto al año 2017.

En el transcurso de los años el incremento de producción de trigo y arroz a sido evidente, no obstante el pronóstico del crecimiento se encuentra ligado a el rendimiento sujeto a :tolerancias, plagas y enfermedades y un parámetro para regular esto es la humedad de los granos y cereales, ya que la determinación

de humedad es de suma importancia debido a la influencia y velocidad de crecimiento de microorganismos , lo que genera una descomposición de los granos, según la normas nacionales e internacionales, la humedad promedio para evitar pérdidas y calidad del cereal en el caso del arroz es de  $14 \pm 1\%$  y en el caso del trigo es de  $13 \pm 1\%$ , (Por, Abadía, & Bartosik, 2013). Existen distintos equipos que pueden medir la humedad de los granos y cereales pero están sujetos a una medición de humedad mediante rayos infrarrojos.

Siendo así la tendencia mundial en la producción agrícola general, la innovación, la precisión y análisis de los cultivos para aumentar las rentabilidades y rendimiento en las plantaciones de vegetales. Actualmente la IA (inteligencia artificial), cumple con estos requisitos , la cual se enfoca en un diseño y construcción de aparatos que pueden ser idóneas de imitar el comportamiento humano, estas técnicas surgen con la aplicación de nuevas herramientas que faciliten el trabajo del ser humano, (Allen, 2019). Funcionando con sistemas con programas computarizados en un ordenador y bases de datos que son diseñados para ser equivalente a la experiencia que se ha almacenado en los expertos, con el fin de analizar velozmente información y tener un control de los procesos que se requieran analizar, (Salazar-Campos, Salazar-Campos, Menacho, Morales, & Aredo, 2019). En consumación la agricultura se enfrenta a una adelanto tecnológica, siendo así la visión artificial una rama de la IA, (Sánchez Calle, 2005).

En si la visión artificial tiene en cuenta tres aspectos importantes siendo la adquisición, procesamiento y análisis de imágenes. (Sanchez Calle, 2004). La cual se manipula como una entrada para el nuevo mundo de muchos organismos, con una función específica, el reconocimiento y análisis de imágenes visuales mediante su procesamiento por sistemas de visión artificial, (Cantoni, Levaldi, & Zavidovique, 2011). La visión artificial o visión computarizada, es el estudio de estos procesos mencionados que ayudan a la

comprensión de las maquinas por medio de los algoritmos diseñados (Suganya, Rajaram, & Sheik Abdullah, 2018).

Como se mencionó el contenido de humedad en cereales se puede medir con equipos que utilizan el espectro de luz infrarroja, en la actualidad no se han detectado estudios en la bibliografía que determinan el contenido de humedad mediante visión artificial en el espectro visible ,la importancia de esta investigación radica en identificar un algoritmo que correlacione las imágenes digitales con la humedad presente en los granos de arroz Iniap 12 y trigo CWRS, usando la tecnología de visión artificial.

## **1. Objetivos**

### **1.1.1 Objetivo General**

Caracterizar imágenes de granos de arroz (Iniap 12) y trigo (Canada Western Red Spring), con distintas humedades por métodos de visión artificial.

### **1.1.2 Objetivos específicos**

- Obtener una base de datos con patrones de humedad homogéneos de arroz y trigo.
- Diseñar un algoritmo que correlacione los datos de visión artificial con el valor de humedad para grano de arroz (Iniap 12).
- Diseñar un algoritmo que correlacione los datos de visión artificial con el valor de humedad para grano de trigo (*Canada Western Red Spring*)

## **2. MARCO TEÓRICO**

### **2.1 Generalidades de los cereales**

Los cereales existían desde tiempos remotos, los progenitores fueron plantas silvestres que cambiaron su morfología. Todos los cereales a excepción de maíz tienen origen en el Viejo Mundo, al pasar de los tiempos se han extendido

alrededor el mundo. Gran porcentaje de cereales pertenecen a la familia de las Gramíneas. Los cereales se definen como especies vegetales cultivadas por sus propios granos, conteniendo un albumen amiláceo listo para el consumo humano o incluso para elaborar piensos de animales, dependiendo el uso, los cereales pueden estar en forma de grano o de harina reduciendo su tamaño de partícula. (Blázquez Carmona,2013)

Las regiones donde crecieron los distintos cereales fueron las siguientes:

- I. Europa, Norte de África y la zona templada de Asia Occidental: **Trigo** (*Triticum*), común hexaploide, se han evidenciado que en países cálidos se cultivaban el trigo moruno, tetraploide. **Cebada** (*Hordeum vulgare*), **Centeno** (*Secale cereale*) y **Avena** (*Avena sativa*).
- II. Sudeste de Asia: El cereal originario de esta región es el **Arroz** (*Oryza sativa*), siendo el cereal más importante en países tropicales, cultivándose desde hace milenios en Asia, En la actualidad este cereal se ha extendido alrededor del mundo.
- III. En las zonas áridas de Asia Oriental, África y India: **Panizo** (*Setaria itálica*), **mijo** (*Panicum miliaceum*), **sorgo** (*Sorghum bicolor*), **panizo manchego** (*Pennisetum typhoides*) , estos cereales se tienen registros que se cultivan en verano.
- IV. México y América central: **Maíz** (*Zea mays*) (Osca,2013).

Los cereales tienen las siguientes características botánicas:

Tabla 1.

*Caracterización botánica de los cereales.*

| <b>TAXONOMÍA</b> |           |
|------------------|-----------|
| <b>Familia</b>   | Gramíneas |

---

|              |                  |
|--------------|------------------|
| <b>Orden</b> | Glumifloras      |
| <b>Clase</b> | Monocotiledóneas |

---

A excepción del trigo sarraceno (*Fagopyron esculentum*), este pertenece a la familia de las Polygonáceas. Adaptado de: <https://doi.org/10.24133/maskay.v8i2.1059>

## 2.2 Estructura y composición de los cereales

Los cereales son los granos básicos para la alimentación, se caracterizan principalmente por ser plantas perennes, sus raíces numerosas y poco profundas, por lo general sus tallos son cilíndricos, casi siempre son huecos, por exención de los nudos, presentan una estructura floral hermafroditas, siendo la única exención el maíz. En general los miembros de la familia (gramineae), incluyen los granos de cereales, generan frutos, de una sola semilla,(Belitz, Grosch, & Schieberle, 2009), a esta fruta se la conoce como grano, Existen granos que tienen una capa en el grano o también llamado pericarpio, en algunos casos como el maíz este fruto se la conoce como cariopsis, que es un fruto simple formado por una capa que se ha fusionado, creando una piel protectora, (Knob, 2010). El pelaje de la fruta se adhiere al pelaje de la semilla y el pericarpio rodea la semilla. La semilla consta del embrión o también conocido como germen, endospermo, epidermis y la cubierta que rodea la semilla, la epidermis nuclear es la capa que engloba las semillas, encerrando el endospermo. Entre las especias más conocidas tenemos: maíz, trigo, cebada, sorgo, centeno, avena, arroz. (Shewry & Halford, 2002) .

La cariósida o grano de cereal tiene tres partes según la especie:

Estructura del grano de trigo:

Pericarpio: 7-16 %

Endospermo (núcleo central):70-85%

Germen(embrión): 2-8%

(Blass, Mateos, & Rebollar, 2010)

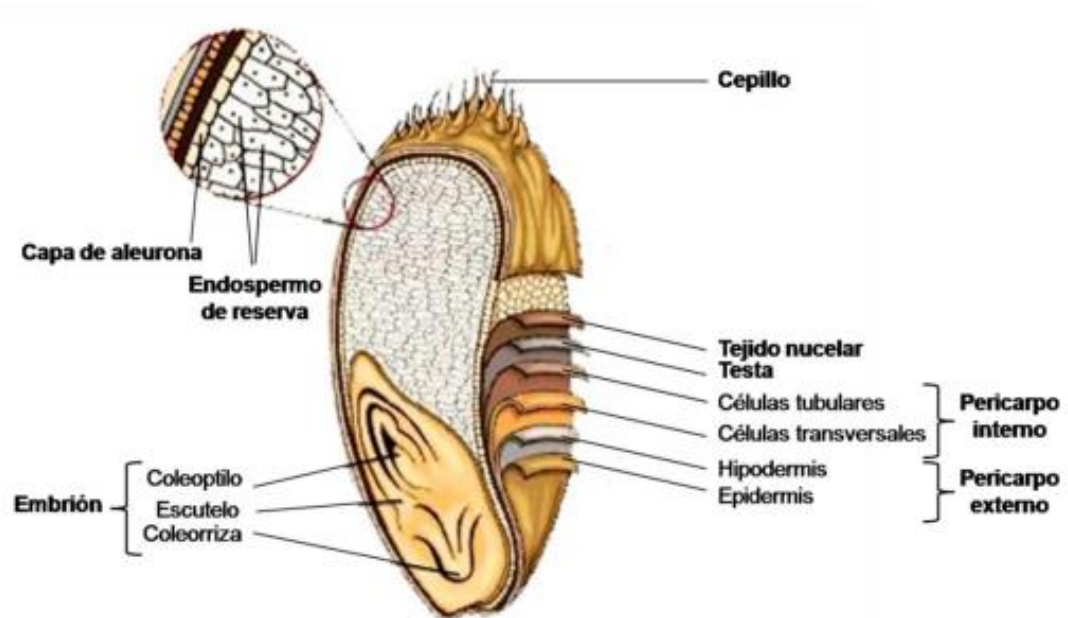


Figura 1: Capas externas e internas de la estructura del trigo. Adaptado de la enciclopedia británica (1996).

En general todos los granos de cereales contienen las mismas partes que se relacionan entre sí, A continuación, se describe, las partes del grano con mayor profundidad:

Cubierta externa (salvado): Esta conformado principalmente por dos capas: el pericarpio en el que a su vez está conformado por: epicarpio, mesocarpio y endocarpio, y otras que se encuentran más profundas siendo la testa o germen(Rowley, 1960), En otros granos de cereal se encuentra otra capa en el exterior que se denomina cascarilla, la podemos encontrar en el arroz, cebada y avena. El salvado tiene alto contenido de minerales y vitaminas pertenecientes



al grupo B, la cascarilla es lignocelulósica, forman parte de la fibra dietética que tiene el grano. (Gómez, y otros, 2007) (Ruiz & Calvo de Mora, 2015).

Endospermo de reserva: Está constituido por la mayor parte del grano, en su totalidad por células muertas que su finalidad es acumular sustancias en su citoplasma, (Domínguez and Cejudo, 2014). Las sustancias de reserva proporcionan nutrientes durante su germinación, el almidón constituye el componente principal puede englobar del 60-80 %. En si es el núcleo del grano, por lo que contiene la reserva energética de la semilla, contiene una capa externa denominada aleurona , donde esta toda la actividad enzimática, en el endospermo existen : proteínas , grasas y minerales aunque se encuentran en bajas cantidades. (Gómez, y otros, 2007)

Y finalmente el Embrión o germen: Se encuentra cercano a la base del germen, Está constituido por una capa externa denominado escutelo, esta zona es por donde se une al endospermo, el germen es la parte del grano capaz de producir una nueva planta. Está definido por un eje embrionario, este difiere a las estructuras de las dicotiledóneas,(Peter R. Shewry & Halford, 2002), el único cotiledón se encuentra reducido y formado por el escutelo la envoltura se encuentra formada por el coleóptilo, que cubre la primera hoja. El escutelo posee un epitelio que segrega enzimas hidrolíticas, que degrada las sustancias de reserva y las transporta al embrión. (Matilla, 2008).

La composición general de los granos de cereales se detalla a continuación:

Tabla 2

*Composición general de granos.*

| Nutriente | Cantidad (%) |
|-----------|--------------|
| Proteínas | 13           |

---

|                            |       |
|----------------------------|-------|
| <b>Hidratos de carbono</b> | 65-90 |
| <b>Lípidos</b>             | 1-4   |
| <b>Minerales</b>           | 1-35  |
| <b>Agua</b>                | ➤ 14  |

---

Adaptado de; <https://doi.org/10.1007/978-3-540-69934-7>

El principal hidrato de carbono es el almidón, por lo general está conformado por (75% de amilopectina. 25 % amilasa), también contiene sacarosa, rafinosa, fructosa y polisacáridos como: hemicelulosa, celulosa, pentosanos, B-glucanos y glucofructanos, (Belitz et al., 2009). En general se encuentra en el endospermo, donde acumulan gránulos cuya forma y tamaño es característico del cereal. (Gómez, y otros, 2007).

### 2.3 Clasificación de los cereales

Según la FAO, “Se refieren a cultivos cosechados solo para grano seco” por lo tanto: los cultivos cosechados verdes son para forraje, pastoreo se clasifican como forrajeros, los cultivos industriales como escoba de sorgo o sorgo dulce en almíbar son cultivos industriales, los cereales frescos que no sea un maíz dulce, aptos o no para el uso de vegetales frescos, estos se clasifican como cereales.

La FAO, abarca diecisiete cereales primarios, de los cuales primero: el maíz blanco es un componente del maíz.

Cereales según la FAO:

- Trigo (*Triticum spp.*)
- Arroz (*Oryza sativa*)
- Cebada (*Hordeum spp.*)
- Maíz (*Zea maíz*)
- Centeno (*Secale cereals*)

- Avena (*Avena sativa*)
- Mijo (*Panicum miliaceum*)
- Sorgo (*Sorghum*)
- Alforfón (*Fagopyrum esculentum*)
- Quinoa (*Chenopodium quinoa*)
- Fonio (*Phormium tenax*)
- Triticale (*triticosecale*)
- Alpiste (*Phalaris canariensis*)
- Cereales (En este incluyen los cereales identificados y separados por su relevancia internacional, por ejemplo: canagua (*Chenopodium pallidicaule*) trigo inca (*Amaranthus caudatus*), arroz salvaje (*Zizania aquatica*). (Organización de las Naciones Unidas, 1994).

### **2.3.1 Descripción de cereales: arroz y trigo**

#### **2.3.1.1 Arroz (*Oriza sativa*).**

Hace 10000 años el cultivo de arroz comenzó, en regiones de Asia, siendo un alimento indispensable para la mitad de la población mundial. Ocupa el segundo puesto entre los cereales más cosechados con respecto a la superficie terrestre,(Beighley, 2005).

Pertenece a la familia de las Angiospermas con la siguiente clasificación:

Tabla 3

*Taxonomía del arroz*

| <b>TAXONOMÍA</b> |                  |
|------------------|------------------|
| <b>Clase</b>     | Monocotyledoneae |

|                |               |
|----------------|---------------|
| <b>Orden</b>   | Glumiflora    |
| <b>Familia</b> | Poaceae       |
| <b>Tribu</b>   | Oryzeae       |
| <b>Genero</b>  | Oryza         |
| <b>Especie</b> | <i>sativa</i> |

El género *Oryza* tiene más de 24 tipos de especies silvestres, creciendo en zonas tropicales. Adaptado de : (Acevedo, Marco & Castrillo, Willian & Belmonte, 2006).

La semilla del arroz está conformada de las siguientes estructuras:




Figura 2: Estructuras de la semilla del arroz. De Giovanni, Víctor; Martínez César y Motta, Francisco. (2010). Producción Ecoeficiente del Arroz en América Latina. Tomado de: [https://ciat-library.ciat.cgiar.org/Articulos\\_Ciat/2010\\_Degiovanni-Produccion\\_eco-eficiente\\_del\\_arroz.pdf](https://ciat-library.ciat.cgiar.org/Articulos_Ciat/2010_Degiovanni-Produccion_eco-eficiente_del_arroz.pdf).

En el arroz los tejidos se pueden observar de acuerdo con dos regiones o partes generales, que se pueden observar que son la región ventral que es donde se encuentra el germen y la parte dorsal que son la cascara y los tejidos fibrosos y celulosicofibrosos.

En la cascara está conformado por la lemma y pálea, el endospermo está compuesto por una capa de aleurona el germen une el endospermo con la capa de aleurona y endospermo amiláceo.(Yoshida, 1981)

### **2.3.1.1.1 Trigo (*Triticum*)**

El trigo es un grano cultivado desde el inicio de la agricultura, su fecha exacta no se la conoce, estudios de CANDOLLE detallan que se originó en la Mesopotamia, sus orígenes comenzaron en Turquía y la India, dentro de su clasificación botánica el trigo es uno de los principales cereales que se consume en la actualidad. (Oyewole, 2016)

Tabla 4

*Taxonomía del trigo*

| <b>TAXONOMÍA</b> |                  |
|------------------|------------------|
| <b>Clase</b>     | Monocotyledoneae |
| <b>Orden</b>     | Poales           |
| <b>Familia</b>   | Poaceae          |
| <b>Genero</b>    | Triticum         |
| <b>Especie</b>   | <i>aestivum</i>  |

Adaptado de : (Oyewole, 2016)

El trigo tiene tres partes principales que lo componen, el endospermo, salvado y germen o embrión, como se detalla en la figura 1.

La piel externa como es el salvado o el pericarpio es la parte más dura del grano compuesto de fibra y minerales, el pericarpio esta unido por medio de una capa proteica que recubre el grano y conecta al salvado, el núcleo o el endospermo

está formado por proteínas y azúcares como el gluten y el almidón también contiene celulosa y finalmente el germen está constituido por ácidos grasos insaturados, minerales y vitaminas, también existen otras partes que contienen el germen que son la aleurona y la hialina, estas capas proteicas en condiciones de germinación son absorbidas por el almidón y sirven para el desarrollo del germen. (P. R. Shewry, 2009)

## 2.4 Generalidades de la producción de cereales

Los cereales son uno de los principales aspectos económicos para la mayoría de los países, en la actualidad la producción de granos permite al consumidor una dieta balanceada aparte de ser barata y una opción distinta, contribuyendo una cantidad considerable al P.I.B. (producto interno bruto). (FAO & OECD, 2018) La producción de estos cereales se encuentra dispersa en todo el mundo. También existen lugares donde se producen mejores rendimientos, pero han tenido un crecimiento constante. (Ilbery, 2017).

### 2.4.1 Producción mundial y nacional

Según la FAO la producción de cereales desde el 2019 mantienen un aproximado de 2720 millones de toneladas.



Figura 3: Producción de cereales en el mundo, Organización de las Naciones Unidas para la Alimentación y la Agricultura, 2019. Ilustración de la producción de cereales en el mundo. Tomado de: <http://www.fao.org/worldfoodsituation/csdb/es/>.

Teniendo un crecimiento firme desde el 2009, pero con perspectiva de la producción del trigo en el 2020 posee un volumen considerable de 762.6 millones de toneladas comparado al 2019 estaría el segundo nivel más sublime de todos los tiempos. A diferencia del arroz la producción mundial desde el 2015 tienen un crecimiento considerable hasta el 2019 donde su producción disminuyó debido a los efectos de la enfermedad (COVID-19). (Organización de las Naciones Unidas para la Alimentación y la Agricultura, 2019)

Tabla 5

*Mercado mundial en millones de toneladas*

|                                    | 2015/16 | 2016/17 | 2017/18 | 2018/19(estimación) | 04/2020 | 05/2020 |
|------------------------------------|---------|---------|---------|---------------------|---------|---------|
| <b>Producción mundial de arroz</b> | 495.3   | 504     | 507.7   | 514.2               | 512     | 511.2   |
| <b>Producción mundial de trigo</b> | 737.2   | 764.9   | 761.7   | 732.1               | 763.3   | 762.4   |

(Organización de las Naciones Unidas para la Alimentación y la Agricultura, 2019)

Conforme a las cifras detalladas de producción mundial del mundo, en el Ecuador se produce más de un millón de toneladas de arroz al año.

Tabla 6

*Producción de arroz en el Ecuador en toneladas*

| <b>Año</b>  | <b>Producción</b> |
|-------------|-------------------|
| <b>2017</b> | 1066614           |
| <b>2018</b> | 1350093           |
| <b>2019</b> | 1099686           |

El arroz es uno de los principales cultivos sembrados en el Ecuador especialmente en la Costa adaptado de INEC 2014.

Con respecto al trigo en el Ecuador se supera los 450000 Tm/año, El Ecuador importa el 98 % de los exigencias internas de trigo,(Instituto Nacional de Investigaciones Agropecuarias, 2007).

#### **2.4.1.1 Zonas con mayor producción de trigo y arroz en el Ecuador**

Las principales zonas para el arroz en el Ecuador son: Guayas, Los Ríos y Manabí teniendo una participación del 67.38 % de superficie sembrada en el Guayas, 25.68 % de S.S en Los Ríos y 1.64% de S.S en Manabí,(INEC, 2014).



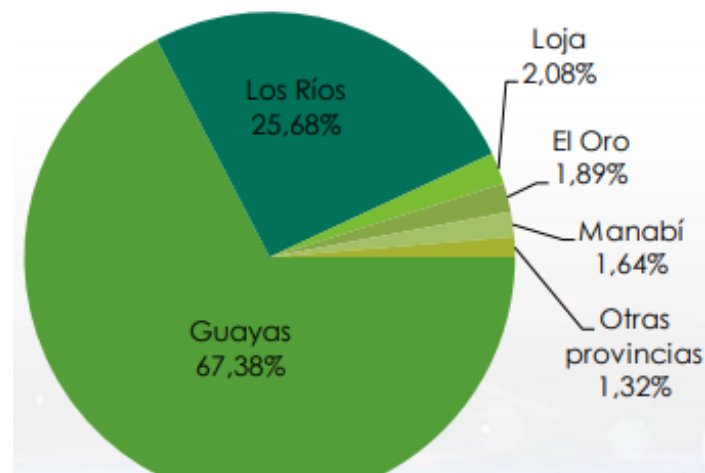


Figura 4. Participación de superficie sembrada de arroz en el Ecuador en el 2019. Recuperado del Instituto Nacional de Estadísticas y censos.

Con respecto al trigo las principales zonas de siembra son Imbabura, Pichincha, Bolívar, Cañar y Loja. (Instituto Nacional de Investigaciones Agropecuarias, 2007)

## 2.5 Importancia de la humedad en granos y cereales.

El contenido de humedad es la cantidad de agua que se encuentra en una unidad con la relación a su masa general, en los alimentos pueden aparecer en dos maneras: como agua libre que se evapora con facilidad con el incremento de temperatura o agua ligada que se encuentra en la materia combinada con proteínas (Rödel, 2001)

Todos los alimentos tienen un contenido con cierto grado de humedad, Las proporciones y cantidades de humedad difieren de acuerdo con factores externos, como tal la humedad es un parámetro que mide la calidad de los alimentos, que puede generar caracteres organolépticas y nutricionales. es uno de los principales elementos para determinar el tiempo de vida de los alimentos. (PRIOR, 1979)

La humedad en los alimentos es una medida importante en el procesamiento de alimentos puede influir en la fluidez, comprensibilidad o posesividad, en industrias alimenticias el incremento de humedad puede generar hongos y daño en los productos lo que provoca una pudrición de los mismos. (Catalano & Fucci, 2008)

Conocer la humedad de una materia permite la determinación de su mantenimiento, lo que puede facilitar su procesamiento y aumentar su conservación, frecuentemente la estabilidad de los alimentos se basa por factores decisivos tales como procesos para elaborar productos como molienda de cereales o el mezclado de productos con diferentes tamaños de partículas, etc. en esto radica la importancia del contenido de humedad ya que puede inferir en la velocidad de crecimiento de microorganismos en las masas. (FDA, 2007).

### ***2.5.1 Legislación de humedad en granos y cereales***

El reglamento técnico de los parámetros de calidad de los alimentos tiene como propósito garantizar la calidad e inocuidad alimenticia, en el Ecuador los cereales tienen medidas que se rigen a una prevención de hongos, los hongos en granos pueden ser controlados por el porcentaje de humedad, generalmente este tiene que estar entre  $14 \pm 1\%$ .(INEN, 2015) Para el arroz la humedad debe ser máximo 14 % y para el trigo la humedad máxima debe ser 13 %, para asegurar la calidad del cereal.(Por et al., 2013)

### ***2.5.2 Equipos de medición de humedad en granos y cereales.***

En la actualidad los equipos de medición de humedad en granos y cereales usan métodos de infla rojo existen diferentes equipos como son los siguientes:

**Analizador de humedad por Termobalanza:** Son balanzas que miden la humedad a través el método de peso seco, es decir pesado y secado, forma parte de las mediciones de humedad termo gravimétrico, este método mide la variación de la masa con respecto al incremento de temperatura, midiendo su

peso seco vs el peso inicial y su pérdida de masa.(Castro, Tecnológica, Pereira, & De Tecnologías, 2010)

**Analizador de humedad en línea:** Son medidas rápidas y seguras de medición de humedad por infrarrojo sin contacto con el material vegetal a gran velocidad y en línea continua y con control automatizado.

**Analizador de humedad de corriente alterna:** Son aparatos pequeños y portables que miden la humedad de cereales, por medio de corriente alterna con alta frecuencia que se aplica en la muestra, este instrumento transforma el valor de la frecuencia de la muestra en valor de humedad, y decreta un resultado gracias a sus tablas y medidas programadas.(Ochoa, 2011)

Para evaluar la precisión de metodologías y equipos de determinación de humedad se requiere la elaboración de patrones o materiales de referencia con humedad establecida y su homogeneidad confirmada.

## **2.6 Generalidades de patrones**

Como se ha conocido en la actualidad existen métodos relativos de medición, siendo los puntos de estudio de unidades las unidades y los patrones. La conexión entre la realización de un patrón y la precisión se basan en métodos primarios, estos métodos de medición para comprobar su medición, estos métodos se establecen a través de comparaciones de varios institutos. En el caso de Ecuador para la realización de estos patrones está vigente las normas INEN ISO 712. (Valdez, Valdivia , Espinoza, & Navarro, 2005).

### **2.6.1 Descripción de patrones o materiales de referencia**

La exactitud en un análisis está sujeta a métodos analíticos que pueden garantizar un estándar de datos precisos asegurando su calidad. Según Antonio Martí “Un patrón es una medida materializada, instrumento de medida, material de referencia o sistema de medida destinado a definir, realizar, conservar o reproducir una unidad o uno o varios valores de una magnitud para que sirvan de referencia” (Martí, 2006).

Por lo tanto un material de referencia (MR), tienen propiedades determinadas que se pueden utilizar para calibrar equipos, esto se consigue comprobar por métodos de medida o a su vez para una asignación de datos o valores a materiales. (Guzman, 2006)

### **2.6.2 Homogeneidad de patrones**

La homogeneidad de patrones sirve para poder determinar una comparación entre los resultados y los datos reales en condiciones impredecibles de muestras, con una intervención humana y control riguroso para poder asegurar su similitud de las muestras, disminuyendo el error en la exposición analizada con datos reales.(OFFARM, 2006) Se ha evidenciado su aplicación en la comparación de metodologías de humedad para medir la precisión de los equipos que interpretan resultados mediante métodos infla rojo y gravimétricos en el grano de trigo CWRS y su importancia radica en la similitud de las muestras(Tulcán M,2019).

La tendencia mundial en la agricultura de precisión y análisis en laboratorios de granos y cereales es el uso de métodos rápidos y precisos. Actualmente la inteligencia y visión artificiales engloban distintas tecnologías que se aplican en la producción agraria y en otras áreas, cuyo componente es la tecnología de la información y comunicación (TIC). El cual tiene como resultados una toma de

decisiones y precisa ejecución en tiempos cortos. (Ochoa Duarte, Cangrejo, & Pachón, 2012)

De esta forma, siendo que no existen metodologías para determinar humedad con visión artificial en los cereales presentados, este trabajo tiene por objetivo a través de este principio, determinar la humedad de estos.

La tendencia mundial en la agricultura de precisión y análisis en laboratorios de granos y cereales es el uso de métodos rápidos y precisos, actualmente la inteligencia y visión artificiales se utiliza para disminuir tiempos en proceso de análisis de calidad de los productos, (Xiwen, Ying, & Zhiyan, 2006).

## **2.7 Generalidades de inteligencia artificial**

La inteligencia artificial es considerada como una ciencia que permite replicar la comprensión humana mediante artefactos, por lo tanto, el objetivo principal de la IA es conseguir que una maquina posea inteligencia propia análogo a la humana, (López et al. 2017). En la IA existen muchos campos que se pueden estudiar como la robótica, la comprensión del lenguaje, reconocimiento de objetos, palabras y visión de máquinas que diferencian colores, formas, etc. Todo esto se logra mediante sistemas computacionales que están diseñados y programados de acuerdo con el desarrollo requerido, (Henaó, 2009).

### **2.7.1 Generalidades de la visión artificial.**

Existen registros de la aplicación de inspección artificial en el área alimenticia pero los problemas surgen debido a la heterogeneidad y complejidad de la naturaleza con respecto a los alimentos, según los estudios que se han realizado en gran medida depende de la calidad de las imágenes e iluminación para un correcto procesamiento y análisis de las muestras obtenidas, no se han encontrado estudios que analicen la humedad en trigo y arroz pero se han

evidenciado sistemas de visión artificial en líneas continuas de procesamiento de alimento usando luz infrarroja para determinar errores de calidad.

La visión artificial se puede delimitar como la “Inteligencia artificial”. En si es el procesamiento de información obtenidas de imágenes, está compuesta de un conjunto de procesos que están predestinados al análisis de imágenes con el fin de obtener la información especial, que se encuentra en el espectro visible de la imagen.(Klette, Schlüns, & Koschan, 1998)

Con la visión artificial es posible:

- Automatizar procesos
- Realizar controles de calidad en alimentos procesados o materias primas
- Efectuar reconocimientos visuales de objetos sin trato físico
- Realizar inspecciones a gran velocidad
- Disminuir tiempos en procesos
- Realizar inspecciones con diferentes materias.(Sanabria S & Archila D, 2011).

### **2.7.1.1 Etapas de un sistema de visión artificial**

El ser humano para captar una imagen y gestionar su información el primer paso para desarrollar este sistema de operaciones comienza por los ojos, circula a través de los nervios ópticos hasta llegar al cerebro donde se analiza la información, la visión artificial es similar a este proceso se quiere asemejar a este comportamiento inteligente, este comportamiento se define a través de cuatro fases principales.(Sobrado Malpartida & Tafur Sotelo, 2008)

Fase 1, capturar la imagen digital mediante sensores o elementos.

Fase 2, procesamiento de la imagen donde se aplican filtros (Vallejo Vizhuete, Paucar, & Martinez, 2018)

Fase 3, Segmentar la imagen: donde se aísla los partes de interés

Fase 4, Reconocimiento de objetos y análisis de características diferenciales, donde se obtiene el algoritmo.(Giloj & Solinsky, 1986).

### 2.7.1.2 Componentes de un sistema de visión artificial

Los elementos de hardware para un sistema de análisis de imágenes digitales son:

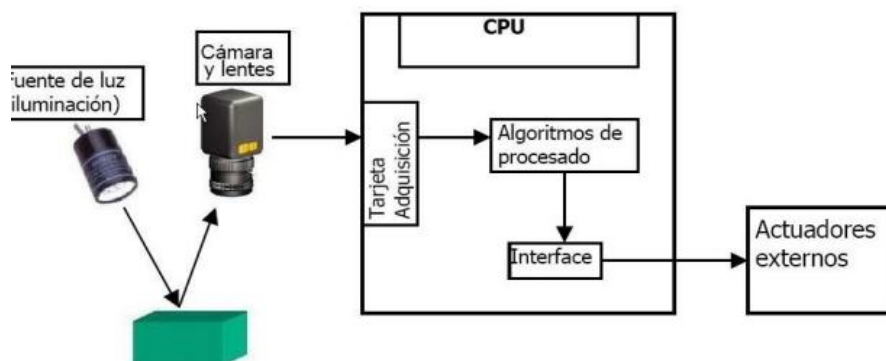


Figura 5: Componentes de un sistema de visión artificial.(2019).Visión Artificial.[Figura].Recuperado de : <http://www.adimenlehiakorra.eus/documents/29934/43025/Aplicaci%C3%B3n+pr%C3%A1ctica+de+la+visi%C3%B3n+artificial+en+el+control+de+procesos+industriales.pdf/92a1a455-ffe2-4290-be95-f9ba33c02241>

Sensor optico: El sensor puede ser una camara que produce una imagen completa.

Memoria de imagen : Almacena la información del modulo

Procesador de imagen : Analiza las imágenes captadas en la camara.

Estas etapas se encuentran comprendidas en pasos siendo primeramente la captación de la imagen posterior al procesamiento y finalmente a la actuación de la interpretación de la imagen. (Szeliski, 2010)

### **2.7.1.3 Partes de un sistema de visión artificial.**

Los componentes de un sistema de visión artificial están compuestos por :

- Computador: El cual se emplea para uso del software a utilizar
- Sistema de iluminación: Su función es proporcionar la luz adecuada al sistema utilizado
- Cámara: Captura la imagen que será analizada por el software que se implementará.

En la figura 6 se encuentra una descripción breve de los componentes de un sistema de visión artificial. (Brahmbhatt & Brahmbhatt, 2013)

### **2.7.1.4 Descripción de funcionamiento de un sistema de visión artificial**

Los pasos principales para un sistema de visión artificial son la segmentación y el análisis de las imágenes digitales, al utilizar un sistema de visión artificial y capturar la imagen se procede a segmentar las partes que se requiere analizar, es posible refinar la segmentación de partes de interés, el análisis es la segunda etapa de la segmentación de imágenes, tomando la imagen satisfactoriamente segmentada, (MASKARA, 2017) , el procesador mide los elementos de interés , hay multitud de algoritmos que ayudan a reflejar el algoritmo requerido, entre ellos se destacan los siguientes resultados:

- Detección de partes
- Análisis de objetos
- Comparación de modelos



- Medida de objetos
- Detección de fallas

Los algoritmos son usados dependiendo de las estrategias requeridas, permiten decidir las piezas correctas para guiar un robot o una herramienta de medición hacia el análisis requerido.(Brahmbhatt & Brahmbhatt, 2013)

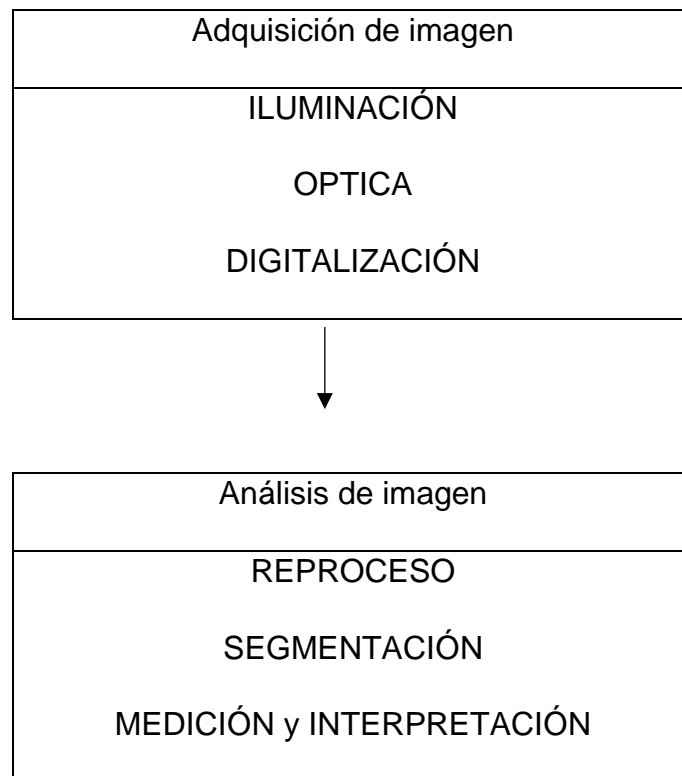


Figura 6 : Pasos para funcionamiento de un sistema de visión artificial.

Un sistema de visión artificial está sujeto a funciones principales como la adquisición y análisis de datos digitales. Este conjunto de procesos transforma la información visual en escenas que permiten almacenar la información y generar algoritmos.(Szeliski, 2010)

### 1.7.1.5 Imagen digital

La definición de una imagen digital en terminos de ejes son funciones bidimensionales compuestas por coordenadas en el plano  $x$  y  $y$ , y la amplitud ( $f$ ) que es llamada  $f$  y es la intensidad del punto gris, siendo las coordenadas  $(x, y)$  y  $f$ , son datos finitos con cantidades , y la funcion es una imagen digital con elementos llamados pixeles.(MASKARA, 2017)




Figura 7: Representación de imagen digital con la convección de ejes.

La figura 7 muestra la representación de imágenes digitales usadas bidimensionalmente como resultado de la proyección de escenas tridimensionales.

### 2.7.1.6 Tipos de imágenes digitales.

Existen 4 clases de imágenes digitales siendo las siguientes :

Tabla 7

*Tipos de imágenes digitales*

| Tipo de imagen                 | Descripción   |
|--------------------------------|---|
| <b>RGB(rojo, verde y azul)</b> | -Tienen tres canales de colores<br>-Utilizan 24 bits de color por cada pixel en la imagen |

---

|                  |  |
|------------------|--|
|                  | <ul style="list-style-type: none"> <li>-Captan hasta 16.7 millones de colores en la imagen</li> <li>-Soportan formatos como JPG,PNG ,etc</li> </ul>  |
| <b>Indexadas</b> | <ul style="list-style-type: none"> <li>-El tamaño del archivo es menor</li> <li>-Reducen los colores de una imagen digital</li> </ul>  |
| <b>Gris</b>      | <ul style="list-style-type: none"> <li>-Soportan formatos GIF Y PNG 8</li> <li>-Solo utilizan tonos grises</li> <li>-La imagen soporta hasta 256 tonos</li> <li>-Utilizan un total de brillo de 0 y 255 blanco por cada pixel</li> </ul> |
| <b>Binarias</b>  | <ul style="list-style-type: none"> <li>-Utilizan colores blanco y negro por cada pixel, representado así la imagen</li> <li>-Contiene valores de 1 o 0</li> </ul>  |

---

(Brahmbhatt & Brahmbhatt, 2013),(Giloj & Solinsky, 1986),(MASKARA, 2017)

### 2.7.2 Modelos de color

Los modelos son los espacios o sistemas de color que son específicos por cada coordenada dentro de un sistema, donde cada color representa un punto con la finalidad de especificar su color.(Parker, 2011)

#### 1.7.3 RBG

Cada color representa los componentes primarios que son: rojo, verde y azul, este modelo está basado en un sistema del plano cartesiano, el color mostrado en la figura 8, muestra los colores mencionados, los colores rojo, verde y azul se encuentran en tres vértices como se muestra en la figura 9, el color blanco está en el polo opuesto del negro y en la recta se encuentran todos los tonos de grises, gradualmente se normalizan en valores R, G, B por lo que el cubo es un unitario. (Vicente & Osca, 2009)




Figura 7: Representación de colores RGB Rongagliolo, P.(2007).Procesamiento de imágenes digitales .[Figura]. Recuperado de: [http://www2.elo.utfsm.cl/~elo328/pdf1dpp/PDI13\\_Color\\_1dpp.pdf](http://www2.elo.utfsm.cl/~elo328/pdf1dpp/PDI13_Color_1dpp.pdf)

#### 1.7.4 HSI

El modelo RGB es un modelo ideal para un sistema de visión artificial pero aun así no es el mejor, para la descripción de colores para una interpretación humana concreta, para describir esto podemos observar la figura 8, cuando vemos un objeto las personas no describen su color como un modelo R,G,B sino por su tonalidad del color, fijándonos con el color puro que se aprecia, el modelo HSI es ideal para algoritmos que se basan en colores naturales para el ser humano, este modelo consta de tres elementos, siendo el color, valor y saturación. (Hue, Saturation, Value). (Asensio, Rodríguez-Caballero, García-Navarro, & Torres, 2018), según las expresiones :

$$H = \begin{cases} \arccos \frac{(R-G)+(R-B)}{2\sqrt{(R-G)^2+(R-B)(G-B)}}, B \leq G \\ 2\pi - \arccos \frac{(R-G)+(R-B)}{2\sqrt{(R-G)^2+(R-B)(G-B)}}, B > G \end{cases} \quad \text{Ec. 1.1}$$

$$S = \frac{\max(R,G,B) - \min(R,G,B)}{\max(R,G,B)} \quad \text{Ec. 1.2}$$

$$V = \frac{\max(R,G,B)}{255} \quad \text{Ec. 1.3}$$

Figura 8 :Expresión matemática de los modelos de color RGB.Parker.(2011).Modelos matematicos de colores RGB. .[Figura] Recuperado de : [http://www.scielo.org.co/scielo.php?script=sci\\_arttext&pid=S1692-82612016000100002](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S1692-82612016000100002)

### 2.7.8 Descripción del procesamiento de imágenes digitales

El reprocesamiento es un proceso que analiza las imágenes digitales para producir información generando algoritmos, esta comprendido por 4 partes siendo :



Figura 9: Etapas de el procesamiento de imágenes digitales

El analisis comprende 5 etapas :

- Adquisición de imágenes : Adquirir imágenes de objetos a estudiar
- Preprocesamiento: Mejorar la calidad e las imágenes difitales con filtros

-Segmentación: Identificar la muestra de interés.

-Medición y interpretación: Extraer y caracterizar el objeto para obtener valores que se pueden interpretar. (Arakeri & Lakshmana, 2016)

### 2.7.9 SOFTWARE

Existen varios programas que facilitan el desarrollo de estudios empleando procesamiento de imágenes digitales entre los cuales se pueden detallar tres softwares utilizados para el análisis de imágenes digitales siendo PYTHON 3.0, MATLAB Y OPEN Centre ellos sus características son:

Tabla 8

*Caracterización general de software básicos*

| CARACTERÍSTICAS                       | PYTHON     | MATLAB     | OPENCV     |
|---------------------------------------|------------|------------|------------|
| <b>Costo</b>                          | Gratis     | Elevado    | Gratis     |
| <b>Facilidad de programación</b>      | Alta       | Media      | Alta       |
| <b>Toolkit para procesar imágenes</b> | Disponible | Disponible | Disponible |

(Alvear-Puertas, Rosero-Montalvo, Peluffo-Ordóñez, & Pijal-Rojas, 2017), (Brahmbhatt & Brahmbhatt, 2013).

#### 2.7.9.1 K-NEAREST NEIGHBORS

KNN es un algoritmo de Machine Learning, que clasifica nuevas muestras o se utiliza para predecir valores, es ideal para introducirlo al aprendizaje automático.

Es importante estratificar y cuando se realiza un `train_test_split` en clases desequilibradas o en un pequeño conjunto de datos.

Luego, como en la mayoría de los otros modelos, debe escalar sus datos. Recuerde que hay muy pocas situaciones en las que los datos no deberían escalarse. El escalado es un proceso simple que se puede hacer en solo unas pocas líneas de código. Después de importar, instanciar el `StandardScaler()`, `fit_transform` conjunto de trenes y `transform` el conjunto de prueba.

```
from sklearn.preprocessing import StandardScaler

ss = StandardScaler()

X_train = ss.fit_transform(X_train)
X_test = ss.transform(X_test)
```

Figura 9. Modelo KNN

Ahora crearemos una instancia del modelo kNN, lo ajustaremos a nuestro conjunto de pruebas y calificaremos nuestro conjunto de trenes y conjunto de pruebas por separado. No cambiaremos ninguno de los hiperparámetros por ahora, por `k_neighbors` lo que se establecerá en el valor predeterminado de 5

```
knn = KNeighborsClassifier()
knn.fit(X_train, y_train)
print('Train Score', knn.score(X_train, y_train))
print('Test Score', knn.score(X_test, y_test))
```

Figura 10. Modelo KNN Grid Search CV

Ajuste al conjunto de trenes, anote ambos conjuntos

Ahora revise las predicciones y probabilidades, que proporcionarán información sobre cuán cerca estuvo el voto para cada punto de datos. Aquí podemos observar cómo se clasificaron las 9 predicciones de nuestro conjunto de pruebas.

kNN en un GridSearchCV

Algunos de los hiperparámetros más comunes son:

- `n_neighbors`, que se mencionó anteriormente

- weights que se puede configurar como 'uniforme', donde cada vecino dentro del límite tiene el mismo peso o 'distancia', donde los puntos más cercanos tendrán más peso hacia la decisión. Tenga en cuenta que cuando weights = 'distance' la clase con el número más alto en el límite puede no "ganar el voto"

, metric que se refiere a cómo se elige la distancia de los puntos vecinos del punto desconocido. Debido a que el modelado generalmente se realiza en más de 3 dimensiones, esto puede ser difícil de visualizar.

### 3. MATERIALES Y MÉTODOS

Se utilizó materiales vegetales, equipos y métodos, los cuales se detallarán a continuación:

#### 3.1 Material vegetal

Las variedades que se usaron para la investigación fueron: Arroz (variedad: INIAP 12) sin cascara proporcionado por el INIAP-Bolicho (Tabla 9), y Trigo (variedad: Canada Western Red Spring CWRS) proporcionado por el INIAP, Santa Catalina (Tabla 10).

Tabla 9

*Localización de las muestras de arroz variedad INIAP 12.*

| Características de la zona | Descripción          |
|----------------------------|----------------------|
| <b>Provincia</b>           | Guayas               |
| <b>Cantón</b>              | Milagro              |
| <b>Lugar</b>               | INIAP-Bolicho        |
| <b>Temperatura</b>         | 24-28                |
| <b>Altitud</b>             | 11 msnm              |
| <b>Coordenadas</b>         | 2°08'05"S 79°35'14"O |



Las muestras vegetativas de trigo de la variedad (CWRS), fueron obtenidas de la siguiente localidad:

Tabla 10

*Localización de las muestras de trigo CWRS.*

| <b>Características de la zona</b> | <b>Descripción</b>                                     |
|-----------------------------------|--|
| <b>Provincia</b>                  | Pichincha  |
| <b>Cantón</b>                     | Quito  |
| <b>Lugar</b>                      | Cusubamba  |
| <b>Temperatura</b>                | 6-13 °C  |
| <b>Altitud</b>                    | 3050 msnm  |
| <b>Coordenadas</b>                | Latitud Sur 0,2798 grados y Latitud este 78,5150 grado |

### 3.1.3. Localización

El lugar donde se procedió a realizar la investigación fue en la Universidad de las Américas, sede Queri (Tabla 11).

Tabla 11

*Localización Universidad de las Américas*

| <b>Características de la zona</b> | <b>Descripción</b>            |
|-----------------------------------|-------------------------------|
| <b>Provincia</b>                  | Pichincha                     |
| <b>Cantón</b>                     | Quito                         |
| <b>Lugar</b>                      | De los Granados E12-41, Quito |
| <b>Temperatura</b>                | 8-21°C                        |
| <b>Altitud</b>                    | 2850 msnm                     |

|                    |  |
|--------------------|--|
| <b>Coordenadas</b> | Latitud Sur 0,169 grados y Latitud este 78,471 grado |
|--------------------|--|

El proyecto de titulación se llevó a cabo en la Universidad de las Américas sede Queri, en los laboratorios de procesamiento de alimentos LQ2, en el laboratorio de Investigación Científica y en los laboratorios de Ingeniería de Producción Industrial; donde se realizaron la homogenización, adquisición de imágenes digitales, procesamiento y análisis para la obtención de los algoritmos de las muestras analizadas.

### 3.1.2. Equipos

Posteriormente se catalogan la lista de materiales y equipos usados en el proyecto de investigación.

Tabla 11

*Materiales y equipos utilizados en el proyecto de investigación.*

| <b>Materiales</b>    | <b>Equipos</b>                 |
|----------------------|--------------------------------|
| Bolsas de aluminio   | Estufa                         |
| Capsulas de aluminio | Balanza analítica              |
|                      | Deshidratador                  |
|                      | Molino                         |
|                      | Horno de temperatura constante |
|                      | Medidor infla rojo             |
|                      | Equipo Agratonix MT-16         |
|                      | Cámara                         |
|                      | Equipo de iluminación          |
|                      | Software                       |

## 3.2 Métodos

La investigación se la dividió en 4 etapas, con el fin de cumplir los objetivos propuestos. Siendo la primera etapa la homogenización de las muestras, el cual se divide en 3 etapas; el secado, acondicionamiento y verificación de la homogeneidad. Posteriormente la segunda etapa es la adquisición de las imágenes digitales que se lleva a cabo con las muestras homogéneas de las humedades respectivas de cada cereal analizado. La tercera etapa es el procesamiento de imágenes digitales que se lleva a cabo mediante el software (Python 3.0) Y finalmente la cuarta etapa es la interpretación siendo los algoritmos obtenidos de la relación entre las humedades analizadas de los cereales y las imágenes digitales.

### **3.2.1 Determinación de contenido de humedad método de referencia.**

Para iniciar con el proceso, primeramente, se verifico la humedad inicial del arroz y trigo obtenido del INIAP, por medio del Agratonix MT16 (método de capacitancia), y el método de la Norma INEN ISO 712 (método de estufa), que fue utilizado para verificar la humedad de las muestras, esta norma tiene como objetivo “Determinar el contenido de humedad de los cereales, y no es aplicable a maíz ni legumbres.”

El principio del método Inen Iso 712 se basa en la pérdida de masa sufrida bajo condiciones que se describirán a continuación.

#### **3.2.1.1 Preparación de las muestras analizadas.**

Para la preparación de las muestras, hay que tener en cuenta los siguientes requisitos:

Tabla 13

*Características de las muestras que requieren molienda*

---

| <b>Características del tamaño de Proporción %<br/>partículas, mm</b> |
|--|
|--|

---

|                     |           |
|---------------------|-----------|
| $\leq 1,7$ (1,8) ^a | 100       |
| $> 1,0$ (1,0) ^b    | $< 10$    |
| $< 0,5$ (0,56) ^ a  | $\geq 50$ |

Nota: a es el tamaño normal de las muestras que no retienen el tamaño de partículas y b es el tamaño de partículas que si retienen el tamaño. recuperado de norma inen iso 712, (2013), cereales y productos de cereales. determinación del contenido de humedad. método de referencia (idt), [tabla]. recuperado de: instituto ecuatoriano de normalización.

Posterior a esto los productos que no necesiten molienda se pesan y se analizan en la capsula metálica previamente mencionada, se tomó 5 g de muestra con n una aproximación de 0.1 mg. Si las muestras ameritaban la molienda dependiendo la proporción de tamaño de partículas, se acondiciono a las medidas solicitadas, para continuar con el proceso de secado.

#### **3.2.1.1.1. Secado y pesaje método INEN ISO 712**

Se tomo las capsulas metálicas que contenían la muestra para el correcto análisis y se colocó en el horno con temperatura constante ,dejando la tapa en el secador en la parte inferior de las capsulas metálicas, tomando en cuenta la (Tabla 12), las partículas debían ser inferior o iguales a 1.7 mm en la fracción de masa de la muestra y 1 mm inferior al 10 % de la muestra , también la fracción de partículas debía ser inferior a 0.5 mm, si el 50 % de fracción era mayor no necesitaban molerse antes de la determinación, Se deja 120 minutos en el horno, con una temperatura de 130 a 133 grados Celsius , previamente precalentado por 30 minutos, no se manipula el horno hasta que culmine el tiempo solicitado, posterior al secado se retira las capsulas metálicas y se introduce en el desecador con la tapa colocada por 30 minutos , para el pesaje en general se pesa con una aproximación de 0.001 g en la balanza analítica.

Nota: para climas cálidos y secos el tiempo estimado es de 60 minutos de secado.

Para la expresión de resultado del contenido de humedad  $w_{H_2O}$  se determinó de las siguientes formulas:

Fórmula para muestras con humedad sin acondicionamiento.

$$W_{H_2O} = \left(1 - \frac{m_1}{m_0}\right) \times 100$$

Siendo:

$m_0 = m_0 - m_d$  = masa en gramos de la masa analizada.

$m_1 = m_1 - m_d$  = masa en gramos después del secado.

$m_d$  = masa en gramos de la capsula metálica con tapa.

El acondicionamiento previo se refiere a los granos que necesiten o no molienda dependiendo el tamaño de partículas como se muestra en la tabla 12 o por su humedad, que debe estar entre 9 a 15 % , por lo general las muestras vienen con humedad superior al 15 % de humedad para su acondicionamiento previo se pesan 5 gramos de muestra con una aproximación de 0.001 g y se procede a realizar el procedimiento de secado como se detalla en el apartado 3.2.1.1.1 con la diferencia de que se deja 7 a 10 minutos en el horno y se registra la muestra antes de secar con  $m_3$  y después de secar con el nombre  $m_3$ .

Fórmula para las muestras con acondicionamiento previo.

$$W_{H_2O} = \left[ (m_0 - m_1) \frac{m_3}{m_0} + m_2 - m_3 \right] \times \frac{100}{m_2} = \left(1 - \frac{m_1 m_3}{m_0 m_2}\right) \times 100$$

Siendo:

$m_0 = m_0 - m_d$  = masa en gramos de la masa analizada.

$m_1 = m_1 - m_d$  = masa en gramos después del secado.

$m_2 = m_2 - m_d$  = masa en gramos de la muestra antes del acondicionamiento

$m_3 = m_3 - m_d$  = masa en gramos de la muestra después del acondicionamiento

$m_d$  = masa en gramos de la capsula metálica con tapa.

### **3.2.1.1.1.1 Desarrollo de estándares**

Una vez obtenida la humedad inicial por medio del método INEN ISO 712, como se detalla en el apartado 3.2.1.1.1, se procede al desarrollo de acondicionamiento de humedades que están comprendidas entre 10 al 16 %, cabe recalcar que se realizaron 5 repeticiones con 250 g de muestra c/u, por cada humedad de los dos cereales analizados arroz y trigo obtenidos del INIAP.

Se colocó las muestras en fundas de aluminio y se procedió a acondicionar las humedades que se requieren, esto se realizó por medio de la fórmula de GOUGH, 1986.

$$Q = \frac{A(b - a)}{100 - b}$$

Siendo:

Q: peso en gramos del agua a añadir

A: Peso en gramos inicial de la muestra

a: contenido de humedad inicial de la muestra

b: Contenido de humedad deseado de la muestra

Este procedimiento se realizó para los dos cereales, el tiempo estimado para el acondicionamiento previo es de 5 días en un cuarto frío con temperatura entre 0-5 °C, tal como se muestra en la tabla 13.

En la investigación se realizaron 7 lotes de humedades (10-16 %), con 5 repeticiones de cada grano analizado, para la prueba de homogeneidad de las muestras arroz sin cascara y trigo CWRS, con la ayuda de un programa (EXCEL), se realizó las pruebas de análisis de varianza de homogeneidad en las humedades analizadas. Considerando los parámetros obtenidos del análisis de ADEVA.

### **3.2.2 Método de visión artificial.**

#### **3.2.2.1 Adquisición de imágenes digitales**

Primeramente, se usó un sistema para la adquisición de imágenes digitales, cumpliendo 2 requisitos:

- Que cumpla una iluminación por contraste es decir la luz emitida debe ser por el lado posterior del objeto para poder observar la coloración de los granos.
  
- El sistema de iluminación debe ser realizado con un campo oscuro para evitar variaciones de luz emitida por otros objetos

Nota: Este sistema de iluminación se muestra en el Anexo 4 y 5.

Posteriormente a la obtención de humedades homogéneas comprendidas en un rango de 10 a 16 %, se procede a la captura de imágenes digitales, Se ha utilizado el equipo de iluminación (Figura 10), creado por el laboratorio de producción industrial de la Universidad de las Américas, una cámara Samsung compuesta por elementos fotosensibles que capturan la imagen a color de acuerdo con la luz del medio, cubriendo los componentes del modelo de color RGB. En si son imágenes digitales con formato JPG con resolución de 4128\*3096 pixeles.

En las figuras 11-17 presentan imágenes digitales de muestra de las humedades comprendidas entre 10 al 16 % de humedad del trigo.



Figura 11: Imagen digital del trigo con 10 % de humedad.



Figura 12: Imagen digital del trigo con 11 % de humedad.



Figura 13: Imagen digital del trigo con 12 % de humedad.



Figura 14: Imagen digital del trigo con 13 % de humedad.



Figura 15: Imagen digital del trigo con 14 % de humedad.



Figura 16: Imagen digital del trigo con 15 % de humedad.



Figura 17: Imagen digital del trigo con 16 % de humedad.



Nota: Este procedimiento se realizó tanto para el trigo como para el arroz.

### **3.2.2.1.1. Procesamiento de datos (limpieza de errores)**

La prevención de errores consiste en, como implica su nombre, evitar que ocurran errores en el proceso de recolección, entrada y análisis de datos, de manera que los resultados que obtengamos nos resulten confiables. El proceso de prevención comienza una vez empezamos a planificar el estudio que nos interesa. Por ello, se eliminan las imágenes que contienen exceso de bordes, mucho ruido, saturación en los colores para que así no se pueda afectar la calidad de los resultados.

Por eso es importante hacer una revisión constante de los datos obtenidos para reducir el error.

#### **3.2.2.1.1.1. Medición y análisis de datos**

Para este proyecto de titulación se utilizó el lenguaje de programación Python 3.0 para procesar e interpretar las imágenes

```
In [1]: from __future__ import print_function
import os
import cv2
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import matplotlib.image as mpimg
from IPython.display import display_html
from skimage import io, img_as_float
import imquality.brisque as brisque
import scripts as simg
import argparse
import warnings
warnings.filterwarnings("ignore")
```

**Figura 18.** Algoritmo 1, importación de comandos

Nota: todas las imágenes se tomaron en las mismas condiciones

```
In [2]: file_path='C:/Users/usuario/Documents/repository/tesis-img-processing/data/arroz/arroz/'
folders_path = os.listdir(file_path)
data = []; data_imgs = []
for folder in folders_path:
    path = file_path+folder
    files = os.listdir(path)
    files = [file_path+folder+"/"+x for x in files]
    data_imgs.append(files)
    data.append([folder, len(files), files])
pdDT = pd.DataFrame(data) # values
pdDT.columns = ["folder", "images", "files_path"]
pdDT
```

Out[2]:

|   | folder | images | files_path  |
|---|--------|--------|---|
| 0 | 10     | 29     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 1 | 11     | 31     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 2 | 12     | 32     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 3 | 13     | 35     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 4 | 14     | 31     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 5 | 15     | 31     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 6 | 16     | 29     | [C:/Users/usuario/Documents/repository/tesis-i... |

**Figura 19.** Algoritmo 2, importación de datos

```
In [3]: images_path = data_imgs[0]
        image_path=images_path[0]
        image_path
        im= cv2.imread(image_path)
        snr = simg.signaltonoise(im, axis=None)
```

**Figura 20.** Algoritmo 3, clasificacion de datos.

```
In [7]: print("- Pixels: " + str(im.size))
        print("- Shape/Dimensions: " + str(im.shape))
        print("- SNR: "+str(snr))

- Pixels: 48163584
- Shape/Dimensions: (3472, 4624, 3)
- SNR: 1.8168706922229485
```

**Figura 21.** Algoritmo 4, procesado de datos

```
In [8]: gray = cv2.cvtColor(im, cv2.COLOR_BGR2GRAY)
        # find frequency of pixels in range 0-255
        histr = cv2.calcHist([gray],[0],None,[256],[0,256])
        fig=plt.figure(figsize=(16, 8))
        fig.add_subplot(1, 2, 1)
        plt.imshow(im)
        fig.add_subplot(1, 2, 2)
        # show the plotting graph of an image
        plt.plot(histr)
        plt.show()
```

**Figura 22.** Algoritmo 5, histograma de canal gris

```
In [6]: fig=plt.figure(figsize=(16, 8))
        for i, col in enumerate(['b', 'g', 'r']):
            hist = cv2.calcHist([im], [i], None, [256], [0, 256])
            plt.plot(hist, color = col)
            plt.xlim([0, 256])

        plt.show()
```

**Figura 23.** Algoritmo 6, histograma de canal RGB

Se procede a correr el programa con los comandos mencionados, para obtener el algoritmo necesitado con respecto a los colores rojo, verde, azul y gris.

Las imágenes digitales de los granos con diferentes humedades generan un algoritmo dependiendo sus colores en modelo RGB, tomando el principio de codificación de un píxel o elemento según su espacio de color, que pueden representar niveles de intensidad de dicho color donde cada nivel responde al modelo analizado.

Una vez obtenida la imagen digital se procedió a realizar el preprocesamiento con la ayuda de un sistema de cómputo número.

Donde se aplicó segmentaciones, niveles de color, rojo, verde, azul y gris, se usó los siguientes comandos en la plataforma de Python 3.0 para cada una de las imágenes digitales analizadas.

De acuerdo con el nivel de saturación, iluminación y matiz de la imagen, se puede obtener un algoritmo de cada imagen con humedades diferentes.

#### **3.2.2.1.1.1. Clasificación de resultados**

Para la interpretación de los resultados se utilizó un algoritmo de clasificación supervisada kNN, que sigue un flujo de trabajo similar al de otros modelos supervisados y es uno de los modelos más prácticos de usar.

```
X = df.drop('target', axis=1)
y = df['target']
```

Gril, G(2018). k-Neighbors Classifier with GridSearchCV Basics. [Figura]. Tomado de : <https://medium.com/@erikgreenj/k-neighbors-classifier-with-gridsearchcv-basics-3c445ddeb657>

Figura 24. Código para la predicción de resultados,

Hay que tener en cuenta que, al configurar X de esta manera, el DataFrame original no se modifica porque el comando `inplace = True` no se usa.

El siguiente código le dará un formato básico de cómo hacer un GridSearchCV que se puede adaptar para cualquier modelo con algunas pequeñas modificaciones

```
from sklearn.model_selection import GridSearchCV

grid_params = {
    'n_neighbors': [3,5,11,19],
    'weights': ['uniform', 'distance'],
    'metric': ['euclidean', 'manhattan']
}

gs = GridSearchCV(
    KNeighborsClassifier(),
    grid_params,
    verbose = 1,
    cv = 3,
    n_jobs = -1
)

gs_results = gs.fit(X_train, y_train)
```

Gril, G(2018). k-Neighbors Classifier with GridSearchCV Basics. [Figura]. Tomado de : <https://medium.com/@erikgreenj/k-neighbors-classifier-with-gridsearchcv-basics-3c445ddeb657>

Figura 25. Formato básico para adaptar el modelo GridSearch

observe que `n_neighbors` siempre es un número impar. Puede elegir un número par, pero en el caso de un empate, la decisión sobre qué clase asignar se tomará al azar cuando `weights` se establezca como uniforme. Al elegir un número impar, no hay empates. Otra cosa importante a tener en cuenta es que cuando haces un GridSearch, estás ejecutando muchos más modelos que cuando simplemente encajas y puntúas. En el GridSearch anterior hay:

4 posibilidades para `n_neighbors`\*

2 posibilidades para `weights`\*

2 posibilidades para `metric`\*

3 validaciones cruzadas

Para un total de  $4 * 2 * 2 * 3 = 48$  veces totales ejecutando el modelo. Es importante establecer de forma detallada para que reciba comentarios sobre el modelo y sepa cuánto tiempo puede llevar terminar. kNN puede tardar mucho tiempo en completarse, ya que mide las distancias individuales para cada punto en el conjunto de prueba.

Otra cosa para notar de GridSearch es eso `n_jobs = -1`. Al establecer `n_jobs` en -1, le está diciendo a la computadora que use todos sus procesadores para realizar el modelo. Tenga en cuenta que un error común es que -1 significa usar "procesadores totales -1" (es decir,  $4 - 1 = 3$  procesadores), pero la computadora lo interpreta como usar todos los procesadores.

### **3.3 Estadística**

En la investigación se realizaron 7 lotes de humedades (10-16 %), con 5 repeticiones de cada grano analizado, para la prueba de homogeneidad de las muestras arroz sin cascara y trigo CWRS, con la ayuda de un programa (EXCEL), se realizó las pruebas de análisis de varianza de homogeneidad en las humedades analizadas.

Posterior a la homogenización de las muestras se realizó la interpretación de los algoritmos de la relación de imágenes digitales de granos con las humedades analizadas, para obtener un algoritmo de cada humedad realizada, esto se realizó con la ayuda de un lenguaje de programación Phyton.

## **4. RESULTADOS**

A continuación de forma secuencial se detallan los resultados obtenidos del proyecto.

### **4.1 Ensayo de homogeneidad**

#### **4.1.1 Preparación de patrones**

De acuerdo con lo detallado en la metodología, el primer paso fue obtener la humedad inicial la cual se detalla en la tabla 12.

El contenido inicial de los granos se obtuvo mediante la Norma Inen Iso 712, para cada una de las muestras, siguiendo las indicaciones de la norma.

A continuación, se detalla el acondicionamiento de las muestras de arroz sin cascara Iniap 12

Tabla 12

*Acondicionamiento de las muestras analizadas por medio de la fórmula de Gough.*

| Lotes | Arroz INIAP 12  |                           | Trigo CWRS      |                           | Humedad deseada | Humedad obtenida |            |
|-------|-----------------|---------------------------|-----------------|---------------------------|-----------------|------------------|------------|
|       | Humedad inicial | Cantidad de agua a añadir | Humedad inicial | Cantidad de agua a añadir |                 | Arroz INIAP 12   | Trigo CWRS |
| 10 %  | <b>8.8 %</b>    | 3.33                      | 9.5 %           | 1.38                      | <b>10 %</b>     | 9.96             | 10.11      |
| 11%   | <b>8.8 %</b>    | 6.17                      | 9.5 %           | 4.21                      | <b>11%</b>      | 10.89            | 10.98      |
| 12%   | <b>8.8 %</b>    | 9.09                      | 9.5 %           | 7.1                       | <b>12%</b>      | 11.99            | 11.82      |
| 13%   | <b>8.8 %</b>    | 12.06                     | 9.5 %           | 10.05                     | <b>13%</b>      | 12.87            | 13.09      |
| 14%   | <b>8.8 %</b>    | 15.11                     | 9.5 %           | 13.08                     | <b>14%</b>      | 13.85            | 13.98      |
| 15%   | <b>8.8 %</b>    | 18.23                     | 9.5 %           | 16.17                     | <b>15%</b>      | 14.91            | 15.13      |
| 16%   | <b>8.8 %</b>    | 21.42                     | 9.5 %           | 19.34                     | <b>16%</b>      | 15.83            | 16.24      |

Nota: Las fundas de aluminio deben ser selladas con una selladora manual para evitar el índice de error.

*Como se detalla en la figura 12 el acondicionamiento de las muestras de arroz sin cascara y trigo CWRS, en base a la fórmula de Gough.*

De acuerdo con la media ( $\bar{x}$ ) de cada humedad realizada en el arroz sin cascara con luz visible, se determinó la desviación estándar (s), donde se identificó que su desviación es menor a 1 lo que demuestra que reduce el porcentaje de error en el análisis de datos.

Posterior a esto al acondicionamiento de humedades de los lotes de cada cereal en las humedades mencionadas se procedió a analizar el contenido de humedad por medio de la NORMA INEN ISO 712 mencionado en el apartado 3.2.1.1.1. cómo se detalla en la (tabla 15).

#### 4.1.2 Análisis de homogeneidad

Tabla 13



*Análisis de homogeneidad del arroz Iniap12*

| <b>Humedad</b> | <b><math>\bar{x}</math>(valor real)</b> | <b>s</b> | <b>F calculado</b> | <b>F crítico</b> |
|----------------|---|----------|--------------------|------------------|
| <b>10 %</b>    | 9.96                                    | 0.103    | 0.099              | 2.131            |
| <b>11%</b>     | 10.89                                   | 0.9      | 0.01               | 2.131            |
| <b>12%</b>     | 11.99                                   | 0.33     | 0.27               | 2.131            |
| <b>13%</b>     | 12.87                                   | 0.08     | 0.37               | 2.131            |
| <b>14%</b>     | 13.85                                   | 0.092    | 0.07               | 2.131            |
| <b>15%</b>     | 14.91                                   | 0.5      | 0.15               | 2.131            |
| <b>16%</b>     | 15.83                                   | 0.11     | 0.01               | 2.131            |

Nota: Cuando el F calculado es menor al F crítico es considerada una muestra homogénea.

Detallándose en la tabla 15 se identifica que el valor de la desviación estándar es menor a 1 como se detalla, se procede a determinar el valor de F calculado, dando menor en todas las pruebas realizadas al valor F crítico, demostrando que las humedades obtenidas del arroz sin cascar son homogéneas.

Demostrando con finalidad que se realizó un proceso adecuado de secado y acondicionamiento de los lotes, siguiendo la norma INEN ISO 712 y la fórmula de Gough, como base para la obtención de porcentaje de humedad.

Asimismo, se efectuó un análisis estadístico en Excel, entre los diferentes lotes con sus respectivas repeticiones como se detalla en la (Tabla 16 ).

**Tabla 14**

*Análisis de homogeneidad del trigo CWRS*

| <b>Lotes</b> | <b><math>\bar{x}</math> (valor real)</b> | <b>s (Desviación estándar)</b> | <b>F calculada</b> | <b>F crítico</b> |
|--------------|--|--------------------------------|--------------------|------------------|
| <b>10 %</b>  | 10.11                                    | 0.40                           | 0.33               | 2.131            |
| <b>11%</b>   | 10.98                                    | 0.94                           | 0.35               | 2.131            |
| <b>12%</b>   | 11.82                                    | 0.44                           | 0.05               | 2.131            |
| <b>13%</b>   | 13.09                                    | 0.20                           | 0.14               | 2.131            |
| <b>14%</b>   | 13.98                                    | 0.17                           | 0.15               | 2.131            |
| <b>15%</b>   | 15.13                                    | 0.42                           | 0.15               | 2.131            |
| <b>16%</b>   | 16.24                                    | 0.21                           | 0.02               | 2.131            |


Nota: Cuando el F calculado es menor al F crítico es considerada una muestra homogénea.

Se determino que los lotes realizados de humedad (10-16 %), del trigo CWRS son homogéneos ya que el F calculado es menor al F crítico

Demostrando que los procesos seleccionados para secar, acondicionar y medir el porcentaje de humedad en los diferentes granos con distintas repeticiones se efectuaron correctamente.

#### **4.2 Histogramas de distribución de colores en la imagen de arroz Iniap 12 y trigo CWRS**

A continuación, se muestra la distribución de colores en la imagen, de acuerdo con la intensidad del valor de los pixeles.




**Figura 25.** Histograma en escala de griss del arroz Iniap 12.

Nota : Los contenedores del histograma se encuentran en el rango 0 a 250, el rango cambia si se trabaja con un espacio de color diferente.

Se puede visualizar que en el gráfico la proporción de alto nivel de la intensidad del valor de los píxeles se encuentra entre el contenedor 200, esto representa que en este rango se encuentra la mayoría de los datos de la representación de los granos de arroz con diferentes humedades, el eje x refleja los contenedores que están sujetos al valor de los píxeles, siendo así si se encuentran los datos hacia el contenedor 250 los píxeles son blancos y si los datos tienen mayor agrupación hacia el contenedor 0 los píxeles son oscuros.

Al examinar un histograma en una imagen se obtiene una comprensión general sobre el contraste, distribución de la intensidad y brillo, esto dará el principio a fin de los píxeles agrupados en una imagen.


En la figura 19 se detalla el histograma en escala RGB del arroz Iniap 12



**Figura 26.** Histograma en escala RGB del arroz Iniap 12.

Se obtuvo una distribución de canales ; azul, verde y rojo en el contenedor 200. Hay un pico de valores de píxeles azul, verde y rojo claro alrededor del contenedor # 200, esto se refiere a que los granos de arroz tienen un rango de píxeles mucho mayor desde el contenedor # 180 al # 220.

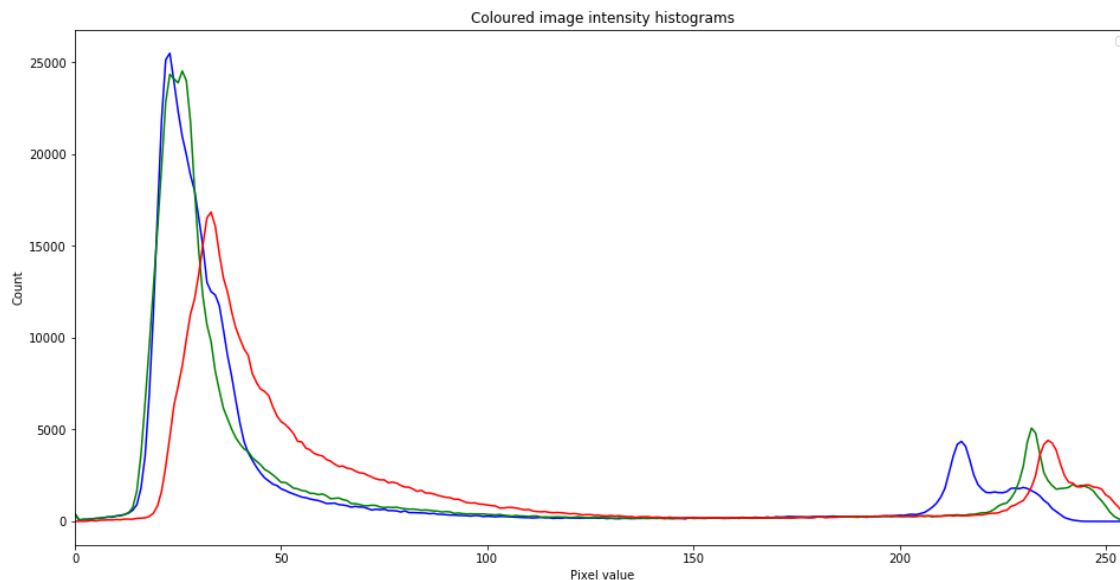
A continuación se muestra en la figura 20 el histograma en escala gris de las imágenes del trigo CWRS.



**Figura 27.** Histograma en escala gris del trigo CWRS.

Se obtuvo una distribución de colores en la imagen entre el contenedor #10 al #50, esto muestra el número de veces que ocurre cada valor de píxel en las imágenes en contraste a los contenedores del [0, 250], detallando que los granos de trigo de acuerdo con sus humedades la mayoría de los píxeles se encuentran distribuidos en el contenedor # 40, relegando que los granos proporcionan colores oscuros de acuerdo con la escala gris.

Posteriormente se encontró la intensidad de colores RGB en las imágenes de trigo CWRS como se detalla en la figura 28.



**Figura 28.** Histograma en escala RGB del trigo CWRS.

Al evaluar los canales de color azul , verde y rojo en las imágenes de trigo CWRS se obtuvo como resultado un histograma con una distribución de píxeles en el contenedor # 10 al #50.

### 4.3 Análisis de exactitud.

A continuación, se detalla en la tabla 15, la cantidad de grupos que se clasificó de acuerdo con los puntos vecinos que tenemos en cuenta a clasificar, en si se utilizó el KNN para predecir y clasificar los puntos de interés de acuerdo con los datos que lo rodean usando el algoritmo K-Nearest Neighbor Grid search.

**Tabla 15**

*Clasificación de resultados del arroz Iniap 12 para la medición de exactitud.*

| type  | Dimensions | 4 bins   | 8 bins   | 16 bins  | 32 bins  | 64 bins  | Average         |
|-------|------------|----------|----------|----------|----------|----------|-----------------|
| gray  | 1          | 0.745455 | 0.763636 | 0.901818 | 0.876364 | 0.88     | <b>0.833455</b> |
| red   | 1          | 0.752727 | 0.72     | 0.876364 | 0.821818 | 0.876364 | <b>0.809455</b> |
| green | 1          | 0.741818 | 0.836364 | 0.807273 | 0.909091 | 0.843636 | <b>0.827636</b> |
| blue  | 1          | 0.821818 | 0.847273 | 0.796364 | 0.825455 | 0.843636 | <b>0.826909</b> |
| RG    | 2          | 0.472727 | 0.603636 | 0.483636 | 0.44     | 0.552727 | <b>0.510545</b> |

|               |   |                 |                 |                 |                 |                 |                 |
|---------------|---|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| <b>GB</b>     | 2 | 0.843636        | 0.789091        | 0.752727        | 0.64            | 0.698182        | <b>0.744727</b> |
| <b>BR</b>     | 2 | 0.687273        | 0.683636        | 0.654545        | 0.658182        | 0.581818        | <b>0.653091</b> |
| <b>HSV 2d</b> | 2 | 0.552727        | 0.505455        | 0.498182        | 0.501818        | 0.574545        | <b>0.526545</b> |
| <b>RGB</b>    | 3 | 0.636364        | 0.694545        | 0.661818        | 0.64            | 0.636364        | <b>0.653818</b> |
| <b>HSV</b>    | 3 | 0.643636        | 0.632727        | 0.621818        | 0.654545        | 0.64            | <b>0.638545</b> |
|               |   | <b>0.689818</b> | <b>0.707636</b> | <b>0.705455</b> | <b>0.696727</b> | <b>0.791919</b> |                 |

Se obtuvo mayor exactitud con 83.34 % en la escala gris de 1 dimensión de color, analizando diferentes Bins (Grupos) en la evaluación de pixeles de [0, 250] contenedores, los canales rojo verde y azul en 1 dimensión mostraron una exactitud promedio de 82.09%, pero las dimensiones 2 y tres mostraron menor porcentaje de exactitud.

A continuación, se muestra la clasificación de interés usando el algoritmo KNN grid search.

**Tabla 16**

*Clasificación de resultados del trigo CWRS para la medición de exactitud.*

| type          | Dimensions | 4 bins          | 8 bins     | 16 bins         | 32 bins         | 64 bins         | Average         |
|---------------|------------|-----------------|------------|-----------------|-----------------|-----------------|-----------------|
| <b>gray</b>   | 1          | 0.257143        | 0.371429   | 0.342857        | 0.4             | 0.314286        | <b>0.337143</b> |
| <b>red</b>    | 1          | 0.457143        | 0.4        | 0.4             | 0.4             | 0.428571        | <b>0.417143</b> |
| <b>green</b>  | 1          | 0.285714        | 0.314286   | 0.428571        | 0.485714        | 0.428571        | <b>0.388571</b> |
| <b>blue</b>   | 1          | 0.285714        | 0.342857   | 0.371429        | 0.4             | 0.4             | <b>0.36</b>     |
| <b>RG</b>     | 2          | 0.342857        | 0.457143   | 0.371429        | 0.457143        | 0.457143        | <b>0.417143</b> |
| <b>GB</b>     | 2          | 0.4             | 0.428571   | 0.485714        | 0.514286        | 0.514286        | <b>0.468571</b> |
| <b>BR</b>     | 2          | 0.4             | 0.428571   | 0.457143        | 0.514286        | 0.457143        | <b>0.451429</b> |
| <b>HSV 2d</b> | 2          | 0.428571        | 0.428571   | 0.485714        | 0.4             | 0.371429        | <b>0.422857</b> |
| <b>RGB</b>    | 3          | 0.371429        | 0.4        | 0.4             | 0.428571        | 0.371429        | <b>0.394286</b> |
| <b>HSV</b>    | 3          | 0.342857        | 0.428571   | 0.485714        | 0.428571        | 0.314286        | <b>0.4</b>      |
|               |            | <b>0.357143</b> | <b>0.4</b> | <b>0.422857</b> | <b>0.442857</b> | <b>0.450794</b> |                 |

Nota: Para el análisis de predicción y clasificación de datos del trigo CWRS, se tenían escasos datos en la humedad 10%,11%,12%,13%. teniendo un promedio de 10 datos

por cada humedad que se requería analizar, para la humedad del 14% al 16 % si se tenían los datos necesarios para el análisis.

Como se detalla en la tabla 16 se obtuvo una exactitud para la escala de 1 dimensión inferior al 50 % de exactitud, analizando las diferentes muestras de humedad del 10% al 16 %, se pudo obtener 46.8 % de exactitud en la dimensión 2 (GB), indicando que los granos se pueden predecir y clasificar con mayor exactitud en los colores rojo y azul de dos dimensiones.

Esto puede constatar que el algoritmo para el caso del trigo CWRS se tuvo baja precisión debido a carencia de datos para la humedad 10% al 13 %.

## **5. DISCUSIÓN**

En base a los resultados obtenidos de la homogenización de las muestras, es crucial indicar que el conjunto de datos obtenidos presenta una distribución con una desviación estándar inferior a 1 detallándose en la tabla 15 y 16, como se detalló esto muestra que el error es mínimo , dando lugar a una homogeneidad entre todos los porcentajes de humedad es decir del 10% al 16 %, El valor obtenido tiene un margen de error de 0.02 , según Tulcán en el 2019, el valor obtenido difiere con su investigación un 3.5 % de error en base a la húmedas obtenidas, en si en las investigaciones el sesgo de error es insignificante, pero la diferencia entre estos dos resultados es debido al método utilizado ya que Tulcán utilizo la norma INEN 1235 siendo una norma desactualizada y en la investigación se utilizó la Norma INEN ISO 712, siendo la norma actual para la medición de contenido de humedad.



De acuerdo a los resultados obtenidos se pudo apreciar un histograma con una proporción de canales gris y RGB en la figura 18 y 19, una distribución de alto nivel de intensidad sobre el valor de píxeles en el rango de contenedor 200, al trazar el histograma, el eje X muestra los contenedores que usan representando de [0, 250], esto puede variar dependiendo que tipo de escala de color se esté usando pero, los resultados obtenidos mostraron una exactitud de 83.8 % de acuerdo a la escala gris de una dimensión, podemos notar que la tabla 15 tenemos mejores resultados al clasificar las humedades 10% al 16% considerando la columna del grupo 64 bins y las filas de una dimensión, sé identifico que el algoritmo mejora sustancialmente si consideramos estos resultados, cuando se consideran todos los resultados obtenidos en la tabla 15 no son mejores, son buenos resultados pero la selección de atributos de cada imagen se analiza con menor porcentaje de aciertos, por más que los resultados de toda la tabla no son mejores, son buenos resultados y su constancia sería una ventaja para utilizar visión artificial para analizar las húmedas en granos de arroz Iniap 12. Este porcentaje de exactitud varía dependiendo las dimensiones analizadas debido a que se usó la k-NN with GridSearch, existen distintas técnicas con algoritmos que reflejan mejores resultados. (Rosebrock, 2014)

Con respecto al trigo CWRS como se detalla en el data set tabla 16, podemos observar que la exactitud en todas las escalas de color, canales, dimensiones y grupos analizadas es inferior al 55 %, esto se debe a la insuficiencia de datos de humedades entre 10% al 13% de humedad ya que al analizar con el algoritmo la k-NN with GridSearch, predice o clasifica las muestras, es un algoritmo sencillo y de aprendizaje automático que busca valores en el punto de datos más similares y para mejorar la exactitud es necesario importar mayor cantidad de datos para reflejar una exactitud superior. (López, 2013)

## 6. CONCLUSIONES

A partir del trabajo realizado en este proyecto de titulación y del análisis de los resultados obtenidos en el capítulo anterior se desarrollaron las siguientes conclusiones.

Se obtuvo una base de datos con siete patrones de humedad del 10% al 16% homogénea del arroz INIAP 12 con doscientos diez imágenes y siete patrones de humedad entre los mismos rangos para el trigo CWRS con ciento treinta y siete imágenes, se verificó con la Norma INEN ISO 712 y el análisis de varianza los resultados obtenidos, de esta manera se pudo constatar que los datos obtenidos fueron patrones homogéneos.

Se diseñó un algoritmo del arroz INIAP 12 con una exactitud media de 83.34% en el canal gris de una dimensión, siendo el grupo analizado con mejor exactitud en el algoritmo desarrollado para la caracterización de imágenes que correlaciona la visión artificial con la humedad entre 10 % al 16 %.

Para el caso del trigo CWRS se obtuvo un algoritmo con una exactitud media inferior al 50% para el caso de todos los canales de color con distintas dimensiones analizadas, se pudo constatar que para el grupo 64 bins en la dimensión 2 de rojo y azul se obtuvo 51.4 % de exactitud.

## RECOMENDACIONES

- Es crucial la limpieza de la materia prima para eliminación de impurezas que puedan generar una variación en la determinación de humedad ya sea para la determinación de patrones homogéneos y captación de datos

ya que, si existen granos partidos, molidos o con residuos puede generar cambios significativos en la exactitud del algoritmo.

- El dispositivo de iluminación debe estar en un lugar sin pendientes y debe ser utilizado bajo las mismas condiciones y características para probar su funcionalidad.
  
- Extender la base de datos para mejorar la exactitud del algoritmo.
  
- Al analizar los datos deben existir el mismo número de muestras analizadas de cada parámetro.
  
- Transformar en un aplicativo móvil, con la finalidad de reducir el procesamiento e interpretación desde un smartphone los resultados obtenidos de humedad con los granos analizados.

.

## REFERENCIAS

- Acevedo, Marco & Castrillo, Willian & Belmonte, U. (2006). Origen, evolución y diversidad del arroz. *Agronomía Tropical*, 35–56. Retrieved from [https://www.researchgate.net/publication/262462682\\_Origen\\_evolucion\\_y\\_diversidad\\_del\\_arroz](https://www.researchgate.net/publication/262462682_Origen_evolucion_y_diversidad_del_arroz)
- Allen, M. (2019). Artificial intelligence (AI). In *The Chief Security Officer's Handbook* (pp. 35–65). <https://doi.org/10.1016/B978-0-12-818384-7.00003-3>
- Alvear-Puertas, V., Rosero-Montalvo, P., Peluffo-Ordóñez, D., & Pijal-Rojas, J. (2017). Internet de las Cosas y Visión Artificial, Funcionamiento y Aplicaciones: Revisión de Literatura. *Enfoque UTE*, 8(1), 244–256. <https://doi.org/10.29019/enfoqueute.v8n1.121>
- Arakeri, M. P., & Lakshmana. (2016). Computer Vision Based Fruit Grading System for Quality Evaluation of Tomato in Agriculture industry. *Procedia Computer Science*, 79, 426–433. <https://doi.org/10.1016/j.procs.2016.03.055>
- Asensio, C., Rodríguez-Caballero, E., García-Navarro, F. J., & Torres, J. A. (2018). Image analysis to qualify soil erodibility into a wind tunnel. *Ciencia e Agrotecnología*, 42(3), 240–247. <https://doi.org/10.1590/1413-70542018423008218>
- Beighley, D. H. (2005). Growth and production of rice. *Soil, Plant Growth and Crop Production*, 2, 1–12.
- Belitz, H. D., Grosch, W., & Schieberle, P. (2009). Food chemistry. In *Food Chemistry*. <https://doi.org/10.1007/978-3-540-69934-7>
- Blázquez Carmona, F. (2013). *Diccionario de las ciencias humanas*. Retrieved from <http://www.digitaliapublishing.com.bibliotecavirtual.udla.edu.ec/visor/35397>

- Brahmbhatt, S., & Brahmbhatt, S. (2013). Introduction to Computer Vision and OpenCV. In *Practical OpenCV* (pp. 3–5). [https://doi.org/10.1007/978-1-4302-6080-6\\_1](https://doi.org/10.1007/978-1-4302-6080-6_1)
- Cantoni, V., Levaldi, S., & Zavidovique, B. (2011). Natural and Artificial Vision. In *3C Vision* (pp. 1–18). <https://doi.org/10.1016/b978-0-12-385220-5.00001-2>
- Castro, W. P., Tecnológica, U., Pereira, D. E., & De Tecnologías, F. (2010). *DISEÑO Y CONSTRUCCIÓN DE UN SISTEMA PARA LA MEDICIÓN DE CONTENIDO DE HUMEDAD EN GRANOS*.
- Catalano, P., & Fucci, F. (2008). A System for Food Drying Using Humidity Control and Low Temperature. *Agricultural Engineering International: CIGR Journal*. Retrieved from [https://www.researchgate.net/publication/256374442\\_A\\_system\\_for\\_food\\_drying\\_using\\_humidity\\_control\\_and\\_low\\_temperature](https://www.researchgate.net/publication/256374442_A_system_for_food_drying_using_humidity_control_and_low_temperature)
- FAO. (2019). *Crop Prospects and Food Situation, Quaterly global report No.3, september 2019*. Retrieved from <https://www.fao.org/giews/english/cpfs/l5455e/l5455E.html>
- FAO, & OECD. (2018). Chapter 6. Meat. *OECD-FAO Agricultural Outlook 2018-2027*, 149–162. <https://doi.org/10.1787/agr-outl-data-en>
- FDA. (2007). Water Activity in Foods. In *Water Activity in Foods*. <https://doi.org/10.1002/9780470376454>
- Giloi, W., & Solinsky, J. C. (1986). INTRODUCTION TO MACHINE VISION. In *Autom and Rob in the Textile and Apparel Ind*. Retrieved from [https://www.assemblymag.com/ext/resources/White\\_Papers/Sep16/Introduction-to-Machine-Vision.pdf](https://www.assemblymag.com/ext/resources/White_Papers/Sep16/Introduction-to-Machine-Vision.pdf)
- Ilbery, B. (2017). Agricultural production. In *A European Geography* (pp. 151–153). <https://doi.org/10.4324/9781315841540-10>
- INEC. (2014). Encuesta de superficie y producción agropecuaria continua. In *Instituto Nacional de Estadísticas y Censos*. <https://doi.org/10.4206/agrosur.1974.v2n2-09>

- INEN. (2015). *NTE INEN 616*. Retrieved from [http://181.112.149.204/buzon/normas/nte\\_inen\\_616-4.pdf](http://181.112.149.204/buzon/normas/nte_inen_616-4.pdf)
- Instituto Nacional de Investigaciones Agropecuarias. (2007). Trigo. Retrieved May 25, 2020, from <http://tecnologia.iniap.gob.ec/index.php/explore-2/mcereal/rtrigo>
- Klette, R., Schlüns, K., & Koschan, A. (1998). Computer vision: three-dimensional data from images. *Computer Vision: Three-Dimensional Data from Images*, (January). <https://doi.org/10.4102/hts.v72i1.3282>
- MASKARA, S. L. (2017). Computer Vision, Artificial Intelligence and Robotics - A cursory Overview of Some of Wonders of Modern Science and Technology. *IEEE*, 1–38. Retrieved from [https://www.researchgate.net/publication/322629078\\_Computer\\_Vision\\_Artificial\\_Intelligence\\_and\\_Robotics\\_-\\_A\\_cursory\\_Overview\\_of\\_Some\\_of\\_the\\_Wonders\\_of\\_Modern\\_Science\\_and\\_Technology](https://www.researchgate.net/publication/322629078_Computer_Vision_Artificial_Intelligence_and_Robotics_-_A_cursory_Overview_of_Some_of_the_Wonders_of_Modern_Science_and_Technology)
- Ochoa Duarte, A., Cangrejo, L., & Pachón, A. (2012). *Actualidad y tendencias de la Agricultura de Precisión*. (December 2012), 0–14. Retrieved from [https://www.researchgate.net/publication/324156309\\_Actualidad\\_y\\_tendencias\\_de\\_la\\_Agricultura\\_de\\_Precision](https://www.researchgate.net/publication/324156309_Actualidad_y_tendencias_de_la_Agricultura_de_Precision)
- Ochoa, E. (2011). Instructivo: Determinación del contenido de humedad. *COLANTA*.
- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2019). Situación Alimentaria Mundial. Retrieved May 25, 2020, from <http://www.fao.org/worldfoodsituation/csdb/es/>
- Osca Lluch, J. M. (2013). *Cultivos herbáceos extensivos: cereales*. Editorial de la Universidad Politécnica de Valencia.
- Owens, G. (2001). *Cereals processing technology*. CRC Press.
- Oyewole, C. (2016). *Diagnosticando a gestão do conhecimento em uma organização utilizando o método: Organizational Knowledge Assessment*,

- OKA Evaluating knowledge management in an organization with Organizational Knowledge Assessment Method* por Marcos Antônio Papa e. (November), 1–17. <https://doi.org/10.13140/RG.2.2.13776.92164>
- Parker, J. R. (2011). Algorithms for Image Processing and Computer Vision, Second Edition. In *Wiley Publishing, Inc* (secunda, Vol. 2). Retrieved from <https://books.google.com.ec/books?hl=es&lr=&id=BK3oXzpxC44C&oi=fnd&pg=PR1&dq=parker+algorithms+for+image+processing+and+computer+vision&ots=ISqDeiAELE&sig=AH8pKThJfRZNHcdntT4s8UTgurs#v=onepage&q=parker+algorithms+for+image+processing+and+computer+vision&>
- Por, E., Abadía, B., & Bartosik, R. (2013). *PRECOP-Proyecto Eficiencia de Cosecha y Postcosecha de Granos*.
- PRIOR, B. A. (1979). Measurement of Water Activity in Foods: A Review. *Journal of Food Protection*, 42(8), 668–674. <https://doi.org/10.4315/0362-028x-42.8.668>
- Rödel, W. (2001). Water activity and its measurement in food. In *Instrumentation and Sensors for the Food Industry* (pp. 453–483). <https://doi.org/10.1533/9781855736481.2.453>
- Rowley, J. R. (1960). The exine structure of “cereal” and “wild” type grass pollen. *Grana Palynologica*, 2(2), 9–15. <https://doi.org/10.1080/00173136009429441>
- Salazar-Campos, O., Salazar-Campos, J., Menacho, D., Morales, D., & Aredo, V. (2019). Improvement of the classification of green asparagus using a Computer Vision System. *Brazilian Journal of Food Technology*, 22. <https://doi.org/10.1590/1981-6723.14018>
- Sanabria S, J. J., & Archila D, J. F. (2011). Detección y análisis de movimiento usando visión artificial. *Scientia et Technica Año XVI*, 49.
- Sanchez Calle, A. (2004). *Actas de la “I Jornada sobre Visión Artificial y Biometría”*. Retrieved from <https://bit.ly/2ZfoUD8>
- Sánchez Calle, Á. (2005). *Aplicaciones de la visión artificial y la biometría*

- informática*. Retrieved from <http://books.google.com/books?id=eHgdPq3iO7sC&pgis=1>
- Shewry, P. R. (2009). Wheat. *Journal of Experimental Botany*, Vol. 60, pp. 1537–1553. <https://doi.org/10.1093/jxb/erp058>
- Shewry, Peter R., & Halford, N. G. (2002). Cereal seed storage proteins: Structures, properties and role in grain utilization. *Journal of Experimental Botany*, 53(370), 947–958. <https://doi.org/10.1093/jexbot/53.370.947>
- Sobrado Malpartida, E., & Tafur Sotelo, J. C. (2008). Sistema de visión artificial para el reconocimiento y manipulación de objetos utilizando un brazo robot. *CISCI 2008 - Séptima Conferencia Iberoamericana En Sistema, Cibernética e Informática 5to SIECI 2008, 3er Simposium Internacional En Comunicación Del Conocimiento y Conferencias, CCC 2008 - Memorias*, 1, 134–139.
- Szeliski, R. (2010). *Computer Vision: Algorithms and Applications*. Retrieved from <http://szeliski.org/Book/>.
- Vallejo Vizhuete, H. E., Paucar, J., & Martinez, O. (2018). Visión artificial mediante el coeficiente de correlación para exámenes de retinoscopía. *MASKAY*, 8(2), 75. <https://doi.org/10.24133/maskay.v8i2.1059>
- Xiwen, L., Ying, Z., & Zhiyan, Z. (2006). Research progress in farming information acquisition technique for precision agriculture- Retrieved May 26, 2020, from [http://en.cnki.com.cn/Article\\_en/CJFDTotai-NYGU200601037.htm](http://en.cnki.com.cn/Article_en/CJFDTotai-NYGU200601037.htm)
- Yoshida, S. (1981). Fundamentals of Rice Crop Science. *Fundamentals of Rice Crop Science*, 65–109. Retrieved from [http://books.irri.org/9711040522\\_content.pdf](http://books.irri.org/9711040522_content.pdf)



# **ANEXOS**

**ANEXO 1. Patrones de muestras acondicionar.**



**ANEXO 2. Sistema de iluminación adaptado para la adquisición de imágenes digitales de cereales, vista horizontal**



**Anexo 3.** Sistema de iluminación adaptado para la adquisición de imágenes digitales de cereales, vista vertical.



**ANEXO 3.** Código para el análisis e interpretación de las imágenes usando PYTHON 3.0 para el arroz INIAP 12.

```

from __future__ import print_function
import os
import cv2
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import matplotlib.image as mpimg
from IPython.display import display_html
from skimage import io, img_as_float
import imquality.brisque as brisque
import scripts as simg
import argparse
import warnings
warnings.filterwarnings("ignore")

```

- Assumption: All images were taken under the same conditions

In [2]:

```

file_path='C:/Users/usuario/Documents/repository/tesis-img-processing/
data/arroz/arroz/'
folders_path = os.listdir(file_path)
data = []; data_imgs = []
for folder in folders_path:
    path = file_path+folder
    files = os.listdir(path)
    files = [file_path+folder+"/"+x for x in files]
    data_imgs.append(files)
    data.append([folder, len(files), files])
pdDT = pd.DataFrame(data) # values
pdDT.columns = ["folder", "images", "files_path"]
pdDT

```

Out[2]:

|   | folder | images | files_path  |
|---|--------|--------|---|
| 0 | 10     | 29     | [C:/Users/usuario/Documents/repository/tesis-i... |

|   | folder | images | files_path  |
|---|--------|--------|---|
| 1 | 11     | 31     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 2 | 12     | 32     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 3 | 13     | 35     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 4 | 14     | 31     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 5 | 15     | 31     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 6 | 16     | 29     | [C:/Users/usuario/Documents/repository/tesis-i... |

In [3]:

```
images_path = data_imgs[0]
image_path=images_path[0]
image_path
im= cv2.imread(image_path)
snr = simg.signaltonoise(im, axis=None)
```

In [7]:

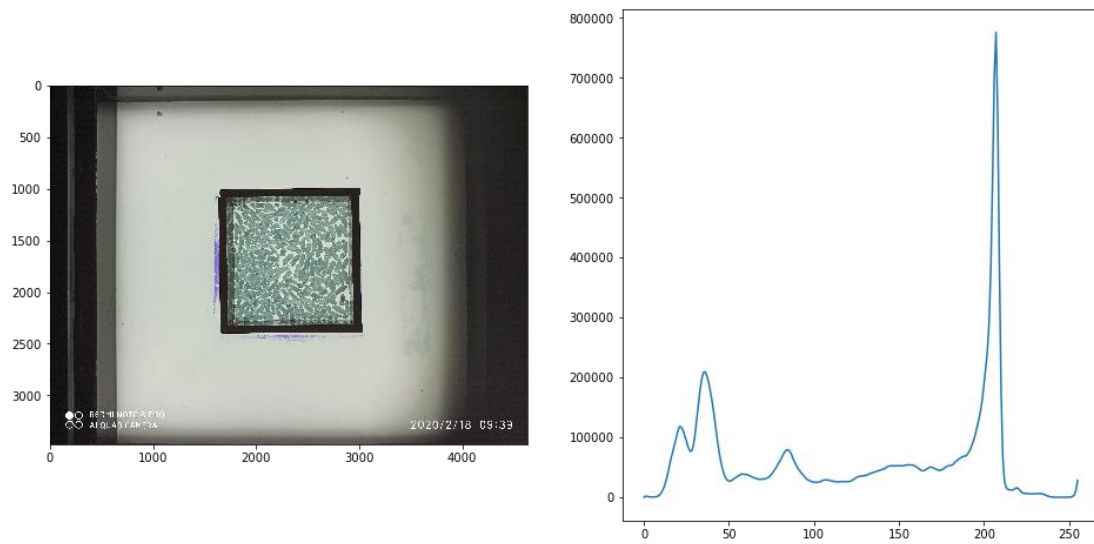
```
print("- Pixels: " + str(im.size))
print("- Shape/Dimensions: " + str(im.shape))
print("- SNR: "+str(snr))

- Pixels: 48163584
- Shape/Dimensions: (3472, 4624, 3)
- SNR: 1.8168706922229485
```

In [8]:

```
gray = cv2.cvtColor(im, cv2.COLOR_BGR2GRAY)
# find frequency of pixels in range 0-255
histr = cv2.calcHist([gray],[0],None,[256],[0,256])
fig=plt.figure(figsize=(16, 8))
fig.add_subplot(1, 2, 1)
plt.imshow(im)
fig.add_subplot(1, 2, 2)
# show the plotting graph of an image
```


```
plt.plot(histr)
plt.show()
```



In [6]:

```
fig=plt.figure(figsize=(16, 8))
for i, col in enumerate(['b', 'g', 'r']):
    hist = cv2.calcHist([im], [i], None, [256], [0, 256])
    plt.plot(hist, color = col)
    plt.xlim([0, 256])

plt.show()
```



#### ANEXO 4. Código para el análisis de las imágenes usando Python 3.0 del grano del trigo CWRS.

In [4]:

```
import pandas as pd
import os
import matplotlib.pyplot as plt
import warnings
import cv2
import numpy as np
import scripts as simg
import seaborn as sns
warnings.filterwarnings("ignore")
from sklearn.neighbors import KNeighborsClassifier
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
from sklearn.decomposition import PCA
```

In [5]:

```
file_path='C:/Users/usuario/Documents/repository/tesis-img-processing/
data/trigo/trigo/'
folders_path = os.listdir(file_path)
data = []; data_imgs = []
for folder in folders_path:
    path = file_path+folder
    files = os.listdir(path)
    files = [file_path+folder+"/"+x for x in files]
    data_imgs.append(files)
    data.append([folder, len(files), files])
pdDT = pd.DataFrame(data) # values
pdDT.columns = ["folder", "images", "files_path"]
pdDT
```

Out[5]:

|   | folder | images | files_path  |
|---|--------|--------|---|
| 0 | 10     | 9      | [C:/Users/usuario/Documents/repository/tesis-i... |
| 1 | 11     | 10     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 2 | 12     | 9      | [C:/Users/usuario/Documents/repository/tesis-i... |
| 3 | 13     | 4      | [C:/Users/usuario/Documents/repository/tesis-i... |
| 4 | 14     | 41     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 5 | 15     | 29     | [C:/Users/usuario/Documents/repository/tesis-i... |
| 6 | 16     | 31     | [C:/Users/usuario/Documents/repository/tesis-i... |

In [6]:

```
images_path = data_imgs[2]
image_path=images_path[3]
image_path
im= cv2.imread(image_path)
snr = simg.signaltonoise(im, axis=None)
```

In [7]:

```
print("- Pixels: " + str(im.size))
print("- Shape/Dimensions: " + str(im.shape))
print("- SNR: "+str(snr))
- Pixels: 38340864
- Shape/Dimensions: (4128, 3096, 3)
- SNR: 1.6346267981774274
```

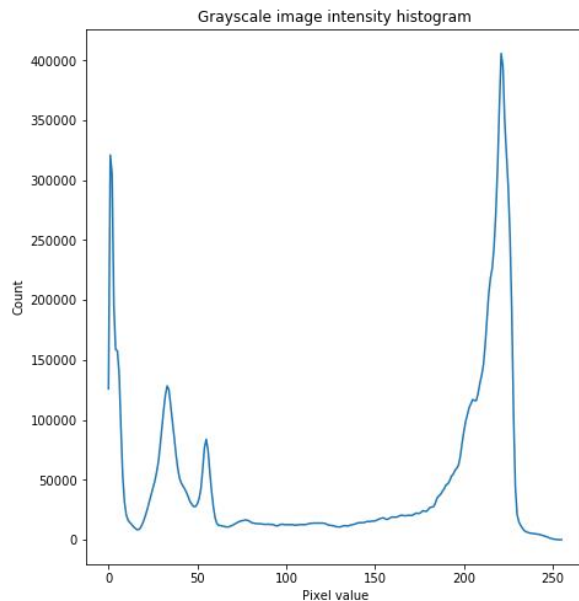

In [12]:



```

gray = cv2.cvtColor(im, cv2.COLOR_BGR2GRAY)
# find frequency of pixels in range 0-255
histr = cv2.calcHist([gray],[0],None,[256],[0,256])
fig=plt.figure(figsize=(16, 8))
fig.add_subplot(1, 2, 1)
plt.imshow(im)
fig.add_subplot(1, 2, 2)
# show the plotting graph of an image
plt.plot(histr)
plt.title('Grayscale image intensity histogram')
plt.xlabel('Pixel value')
plt.ylabel('Count')
plt.show()

```



In [13]:

```

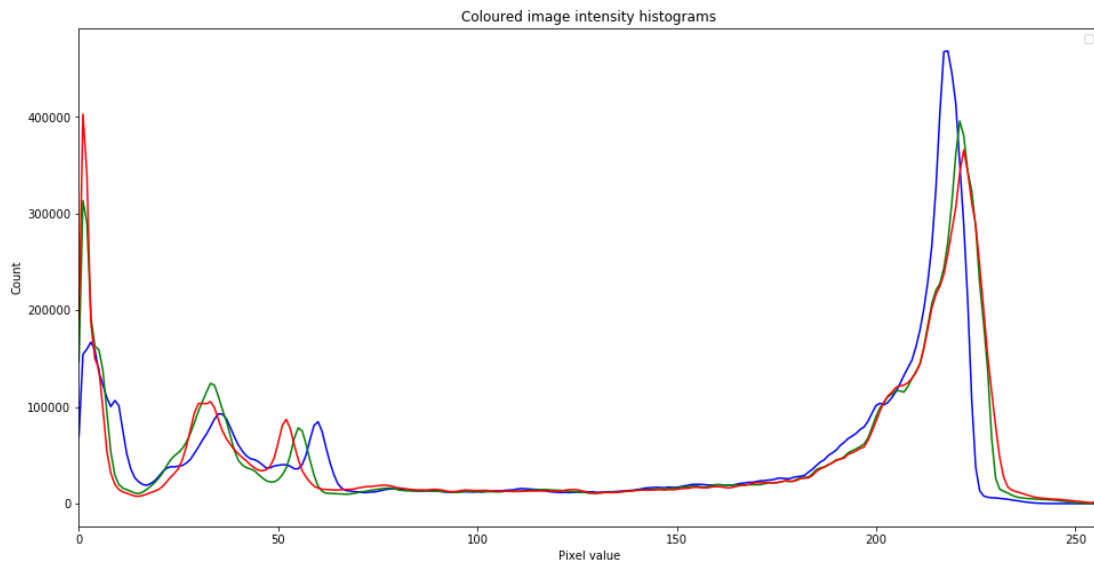
fig=plt.figure(figsize=(16, 8))
for i, col in enumerate(['b', 'g', 'r']):
    hist = cv2.calcHist([im], [i], None, [256], [0, 256])
    plt.plot(hist, color = col)
    plt.xlim([0, 256])
plt.title('Coloured image intensity histograms')
plt.xlabel('Pixel value')
plt.ylabel('Count')

```

```
plt.legend()
```

```
plt.show()
```

No handles with labels found to put in legend.



In [10]:

```
w1=.40; w2=.40;
```

```
h1=.60; h2=.60;
```

```
imCut=simg.cut_image(im, w1, w2, h1, h2)
```

In [15]:

```
gray = cv2.cvtColor(imCut, cv2.COLOR_BGR2GRAY)
```

```
# find frequency of pixels in range 0-255
```

```
histr = cv2.calcHist([gray],[0],None,[256],[0,256])
```

```
fig=plt.figure(figsize=(16, 8))
```

```
fig.add_subplot(1, 2, 1)
```

```
plt.imshow(imCut)
```

```
fig.add_subplot(1, 2, 2)
```

```
# show the plotting graph of an image
```



```
plt.plot(histr)
```

```
plt.title('Grayscale image intensity histogram')
```

```
plt.xlabel('Pixel value')
```

```
plt.ylabel('Count')
```

```
plt.show()
```



In [16]:

```
fig=plt.figure(figsize=(16, 8))
for i, col in enumerate(['b', 'g', 'r']):
    hist = cv2.calcHist([imCut], [i], None, [256], [0, 256])
    plt.plot(hist, color = col)
    plt.xlim([0, 256])

plt.title('Coloured image intensity histograms')
plt.xlabel('Pixel value')
plt.ylabel('Count')
plt.legend()
plt.show()
No handles with labels found to put in legend.
```

Coloured image intensity histograms

