



Revista EDUCATECONCIENCIA.
Volumen 20, No. 21.
E-ISSN: 2683-2836
ISSN: 2007-6347
Periodo: octubre - diciembre 2018
Tepic, Nayarit. México
Pp. 76 - 88
Doi: <https://doi.org/10.58299/edu.v20i21.89>

Recibido: 06 de noviembre del 2018
Aprobado: 04 de diciembre del 2018
Publicado: 30 de diciembre del 2018

**Caracterización de cultivos con imágenes de VANT'S de alta resolución
utilizando Teoría de Redes**

**Characterization of crops with high resolution VANT'S images using Network
Theory**

Autores

Víctor Genaro Luna Fernández

Benemérita Universidad Autónoma de Puebla,
México
vgluna@hotmail.com

Esmeralda Vidal Robles

Benemérita Universidad Autónoma de Puebla,
México
vidalesmeralda@hotmail.com

Alfredo Halam Abascal Alonso

Benemérita Universidad Autónoma de Puebla,
México
halam.abascal@gmail.com

Carla Daniela Cortes Quiroz

Benemérita Universidad Autónoma de Puebla,
México
carli.cts794@gmail.com

Caracterización de cultivos con imágenes de VANT'S de alta resolución utilizando Teoría de Redes

Characterization of crops with high resolution VANT'S images using Network Theory

Autores

Víctor Genaro Luna Fernández

Benemérita Universidad Autónoma de Puebla, México
vgluna@hotmail.com

Esmeralda Vidal Robles

Benemérita Universidad Autónoma de Puebla, México
vidalesmeralda@hotmail.com

Alfredo Halam Abascal Alonso

Benemérita Universidad Autónoma de Puebla, México
halam.abascal@gmail.com

Carla Daniela Cortes Quiroz

Benemérita Universidad Autónoma de Puebla, México
carli.cts794@gmail.com

Resumen

El mapeo de la vegetación es de suma importancia en la agricultura de precisión, debido a que se relaciona directamente con la calidad y el crecimiento del cultivo. Se presenta un análisis de color a partir del uso de imágenes de alta resolución tomadas con un dron, en donde se pudo identificar la calidad del cultivo de maíz utilizando imágenes con una resolución de 1cm. x pixel en la región de Atlixco, Puebla, se utilizó la teoría de redes y el lenguaje de programación Python 2.7, y se formaron matrices de adyacencia para los colores Rojo (R), Verde (G) y azul (B). Los resultados obtenidos muestran que es posible mediante estos análisis conocer la calidad de un cultivo.

Palabras clave: matriz de adyacencia, python, teoría de redes, VANT'S

Abstract

The mapping of vegetation is of utmost importance in precision agriculture, because it is directly related to the quality and growth of the crop. A color analysis is presented from the use of high resolution images taken with a drone, where the quality of the corn crop could be identified using images with a resolution of 1cm. x pixel in the region of Atlixco, Puebla, the theory of networks and the programming language Python 2.7 was used, and adjacency matrices were formed for the colors Red (R), Green (G) and blue (B). The results obtained show that it is possible through these analyzes to know the quality of a crop.

Keywords: adjacency matrix, python, network theory, VANT'S

Introducción

México es considerado como el centro de origen, domesticación y dispersión del maíz (*Zea mays* L.). A la fecha se han descrito 59 razas potencialmente diferentes (Kato et al., 2009). Como en el continente americano se reportaron unas 300 razas, la variación en México representa 22.7 % de la diversidad del maíz en el continente (Serratos, 2009). Esta diversidad está presente aun a nivel de microrregiones, a la que Muñoz (2015) denomina patrón etnofitogenético o patrón varietal y lo define como el conjunto de grupos de variedades de maíz, los estratos o niveles ambientales y las relaciones entre ellos.

El Estado de Puebla ocupa el octavo lugar en superficie cosechada de maíz (INEGI, 2010) y 93 % de esa área se cultiva en condiciones de temporal (INEGI, 2007). Existen 15 microrregiones de maíz en el Estado de Puebla con una amplia variación en días a floración femenina, color de grano y características agronómicas (Gil et al., 2004). Esta diversidad también ha sido reportada para el Valle de Puebla (Hortelano, 2008).

El maíz es el cultivo con mayor superficie en el municipio de Atlixco, Puebla. Durante el periodo 2016 se sembraron 3,672 ha, de las cuales 74 % se cultivaron en condiciones de temporal (INEGI, 2007), donde solamente se cosechó 35 % de la producción total de grano. Los bajos rendimientos se deben principalmente a los suelos pobres y degradados y a la baja precipitación pluvial (650 mm anuales, en promedio) con un régimen de lluvias mal distribuido (Muñoz, 2005). Pese a estas adversidades, los productores cultivan maíz todos los años con fines de autoconsumo y como costumbre cultural. Esto ha permitido proteger y mantener la diversidad genética local. El aprovechamiento de las variedades locales puede ayudar a la preservación in situ de la diversidad genética local, mediante la agricultura tradicional (Herrera et al., 2014).

A este respecto la modernización de las prácticas agrícolas a través del procesamiento y análisis de imágenes de alta resolución surge como un nuevo desafío, principalmente en relación con el concepto de sostenibilidad ambiental y económica del proceso de producción (Chartunil et al., 2007). En este sentido la segmentación de las imágenes digitales es una parte importante para muchas tareas en el análisis y procesamiento digital. Recientemente se han generado una gran cantidad de trabajos que

presentan técnicas, modelos y algoritmos para la segmentación de dichas imágenes. Estas técnicas se dividen en cuatro grandes grupos, el primer grupo lo conforman las técnicas de segmentación basadas en los valores de pixel. El segundo grupo contiene técnicas de segmentación basadas en el área. Las técnicas basadas en orillas pertenecen al tercer grupo y finalmente las técnicas basadas en las matemáticas es el cuarto grupo (Báez et al., 2014).

Por otra parte, la teoría de redes también llamada teoría de grafos se considera que tuvo su inicio con el matemático suizo Leonhard Euler en el año 1070, él planteó el curioso problema de los siete puentes sobre el río Pregel de la ciudad prusiana de Kaliningrado (Perianes et al., 2008). A partir de Euler el modelado mediante grafos fue desarrollando esta metodología hasta convertirse en la actualidad, en una herramienta de trabajo para ciencias tan diferentes como la Física, la Química, la Psicosociología, la Economía, la Lingüística, etc. La teoría de grafos está íntimamente relacionada con varias ramas de la Matemáticas como por ejemplo la Teoría de Conjuntos, el Análisis Numérico, Probabilidad, Topología, etc. y es la base conceptual en el tratamiento de problemas combinatorios (Hillier et al., 2010: 55).

Las redes se encuentran por todas partes, nos rodean, formamos parte de ellas, unas veces como nodos (en nuestras relaciones de parentesco o amistad), en otras ocasiones como enlaces (Perianes et al., 2008). Las redes pueden representar diversos sistemas tal como redes sociales, redes de distribución de energía, redes de información, redes de reacciones químicas, metabólicas, redes neuronales, genéticas, biológicas, etc.

Las redes de color RGB, por ejemplo, pueden ser descritas como un grafo con un conjunto finito de nodos (colores rojo, verde y azul) y un conjunto finito de enlaces que asocian cada uno de esos nodos entre sí. En este sentido, “el uso de este tipo de tecnologías en la agricultura de precisión puede ayudar a mejorar los márgenes, a través de un aumento del valor del rendimiento (cantidad o calidad), de una reducción en cantidad de insumos o de ambos simultáneamente” (García et al., 2008:100).

En la actualidad el mapeo de la vegetación a través de la agricultura de precisión es de suma importancia ya que éste se encuentra directamente relacionado con la identificación de la calidad y el crecimiento del cultivo. El trabajo presenta un análisis de

color de imágenes de alta resolución tomadas con un dron, el uso de teoría de redes y el lenguaje de programación de Python 2.7, para identificar la calidad del cultivo de maíz (*Zea mays* L.) en la región de Atlixco, Puebla.

Método

Las fotografías utilizadas en este trabajo fueron tomadas por un Dron DJI Inspire 1 V2.0 y una cámara de alta resolución a una altura de 10 metros con una resolución de 1 cm por pixel, a una velocidad promedio de 5m/s, a una resolución de 4096 x 2160 píxeles. Se realizó un análisis de color a 31 imágenes de cultivos de maíz (*Zea mays* L.) de la región de Atlixco Puebla, usando teoría de redes. Las imágenes se ajustaron a una resolución de 1000 x 1000 píxeles para que pudieran ser analizadas como una red.



Figura 1. Cultivos de maíz (*Zea mays* L.) tomada a 10 metros de altura con un Dron DJI Inspire 1

Metodología Computacional

Se importan las siguientes librerías para realizar el análisis:

In [2]:

```
from PIL import Image #Lee imágenes y las convierte a código RGB
import numpy as np #Facilita el uso de matrices
import networkx as nx #Se usa para analizar la red creada de cada imagen
import matplotlib.pyplot as plt #Permite hacer gráficas
from scipy import stats #Librería para hacer diagramas estadísticos junto con matplotlib
```

Las listas de imágenes y matriz se usan para guardar las imágenes y las matrices con los valores RGB de las respectivas imágenes. Cada imagen tiene un tamaño de 1000 x 1000 píxeles.

In [2]:

```
Images=[]
Imatrix=[]
#Aquí se guardan Las imágenes en Images
for i in range(46,62,1):
    image=Image.open('DJI_00'+str(i+1)+'.jpg')
    Images.append(image)
for i in range(70,85,1):
    image=Image.open('DJI_00'+str(i+1)+'.jpg')
    Images.append(image)
#Aquí se crean y guardan Las matrices con Los valores RGB en Imatrix
for i in Images:
    foto=np.array(i)
    Imatrix.append(foto)
```

Se crea una matriz para todos los valores de R, G y B de las 31 imágenes. En total tenemos 31 millones de números en cada lista.

In [3]:

```
R=[]
G=[]
B=[]
#Con este bucle, escogemos Los valores de R,G y B y Los almacenamos en La lista correspondiente
for i in Imatrix:
    for j in i:
        for k in j:
            R.append(k[0])
            G.append(k[1])
            B.append(k[2])
```

Los 31 millones de números se encuentran como un gran vector. Es por ello que se organizarán en matrices de 1000 x 1000 es decir, se obtendrán 31 matrices de las listas R, G y B. Éstas matrices se guardarán en las listas MR, MG y MB respectivamente.

In []:

```
MR=[]
MG=[]
MB=[]
#Gracias al método reshape(), podemos formar las matrices cuadradas de 1000 y después a
#Lmacenarlas en otra lista
for i in range(31):
    r=np.array(R[i*1000000:(1+i)*1000000]).reshape(1000,1000)
    MR.append(r)
for i in range(31):
    g=np.array(G[i*1000000:(1+i)*1000000]).reshape(1000,1000)
    MG.append(g)
for i in range(31):
    b=np.array(B[i*1000000:(1+i)*1000000]).reshape(1000,1000)
    MB.append(b)
```

De cada matriz se sacará una matriz de adyacencia usando la librería networkx de Python.

In []:

```
AdjacenciaR=[]
AdjacenciaG=[]
AdjacenciaB=[]
#Aqui se convierten las matrices de los valores de R, G y B en matrices de adyacencia y
#esas matrices se guardan
# en las listas AdjacenciaR, AdjacenciaG y AdjacenciaB para R, G y B respectivamente.
for i in MR:
    a=nx.from_numpy_array(i)
    AdjacenciaR.append(a)
for i in MG:
    a=nx.from_numpy_array(i)
    AdjacenciaG.append(a)
for i in MB:
    a=nx.from_numpy_array(i)
    AdjacenciaB.append(a)
```

Se obtiene el grado con peso de cada matriz y se almacena en las listas DegreeR, DegreeG y DegreeB según corresponda.

In []:

```
DegreeR=[]
DegreeG=[]
DegreeB=[]
#Aquí se calculan y se guardan los grados con peso de cada matriz de adjacencia
for i in range(31):
    a=nx.degree(AdjacenciaR[i],weight='weight')
    a=dict(a)
    b=a.values()
    b=list(b)
    c=sum(b)/1000
    DegreeR.append(c)
for i in range(31):
    a=nx.degree(AdjacenciaG[i],weight='weight')
    a=dict(a)
    b=a.values()
    b=list(b)
    c=sum(b)/1000
    DegreeG.append(c)
for i in range(31):
    a=nx.degree(AdjacenciaB[i],weight='weight')
    a=dict(a)
    b=a.values()
    b=list(b)
    c=sum(b)/1000
    DegreeB.append(c)
```

Se puede observar cómo se distribuyen los grados con peso para R, G y B usando un histograma. Para esto se importa el módulo stats de scipy.

In []:

```
from scipy import stats
#Histograma para R
plt.hist(DegreeR)
plt.title('Histograma de grados con peso R')
plt.xlabel('Grado con peso')
plt.ylabel('Frecuencia')
#Histograma para G
plt.hist(DegreeG)
plt.title('Histograma de grados con peso G')
plt.xlabel('Grado con peso')
plt.ylabel('Frecuencia')
#Histograma para B
plt.hist(DegreeB)
plt.title('Histograma de grados con peso B')
plt.xlabel('Grado con peso')
plt.ylabel('Frecuencia')
```

Posteriormente se realiza una gráfica de caja para los grados con peso de los valores obtenidos de R, G y B, es decir, de las listas DegreeR, DegreeG y DegreeB.

In []:

```
A=[DegreeR,DegreeG,DegreeB]  
plt.boxplot(DegreeR,labels='R''G''B')  
plt.title('Diagrama de caja de grados con peso de valores RGB de imágenes ')  
plt.ylabel('Frecuencia')
```

Resultados

La figura 2 muestra la distribución de los grados con peso de cada color en las 31 imágenes analizadas y se puede observar que los grados con peso del color verde tienen una media más grande que los colores azul y rojo y que su distribución es más compacta y hacia arriba, lo que indica grados con peso mayores. Esto puede ser causado a que la mayor parte de las imágenes la ocupa el color verde del cultivo fotografiado y a que el modelo de color RGB asigna a cada pixel tres valores que indican la intensidad del color rojo, verde y azul. Ya que el color verde predomina en la imagen, el valor G de cada pixel tiene más probabilidades de no ser 0 y de presentar valores más altos que los valores R y B.

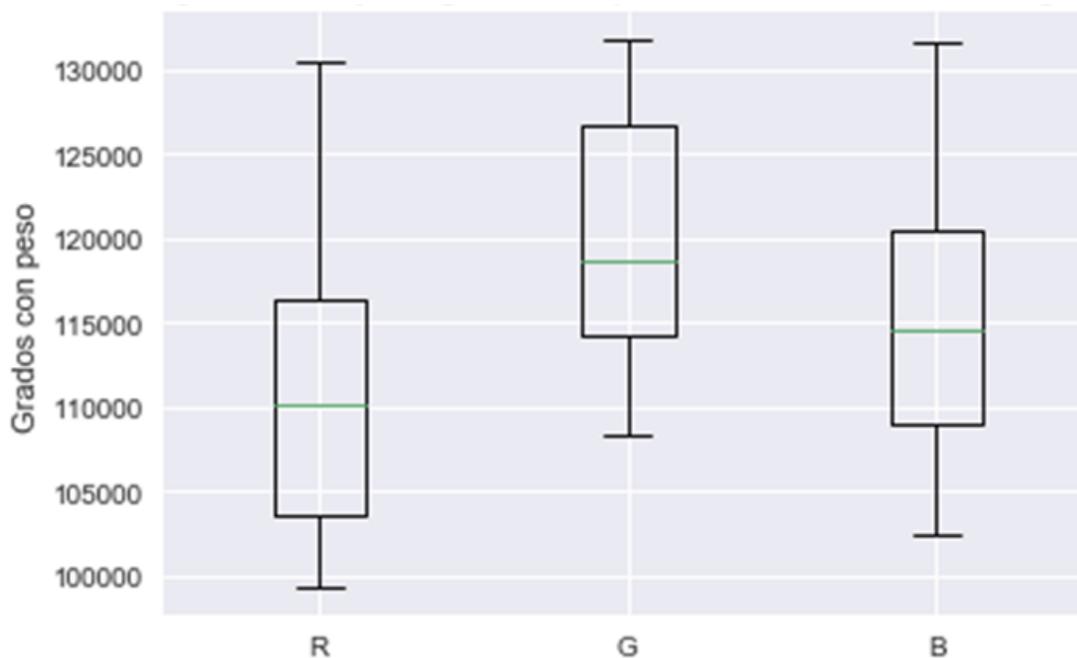


Figura 2. Diagrama de caja de grados con peso de valores RGB de imágenes

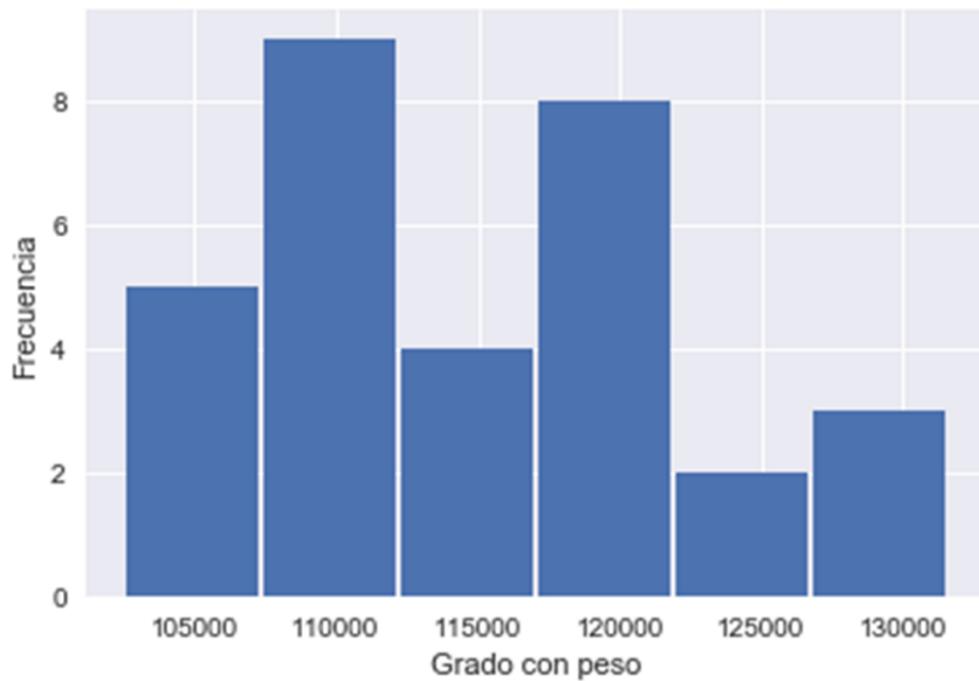


Figura 3. Histograma de grados con peso B

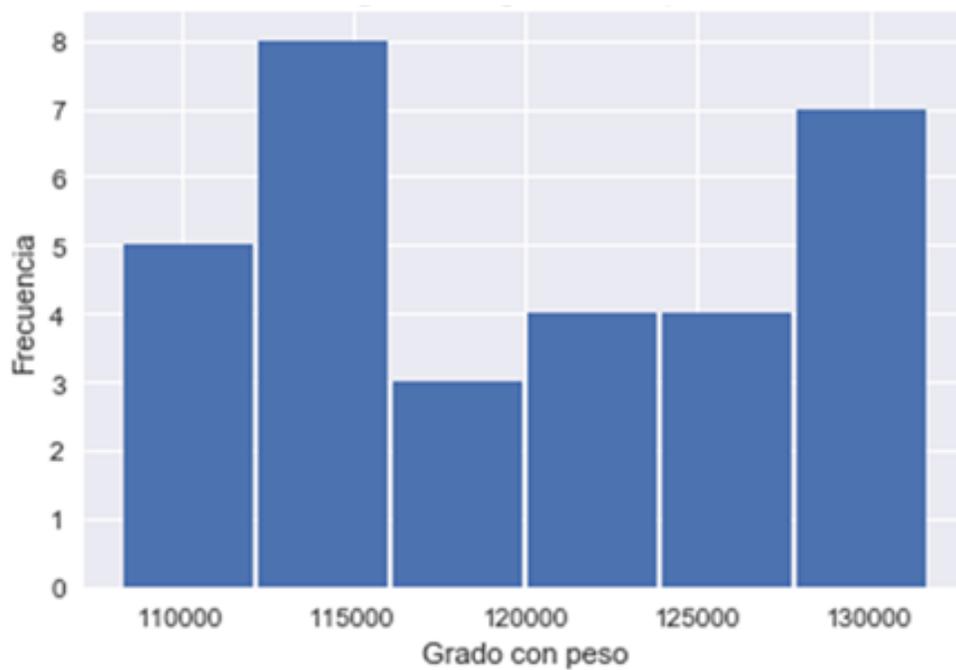


Figura 4. Histograma de grados con peso G

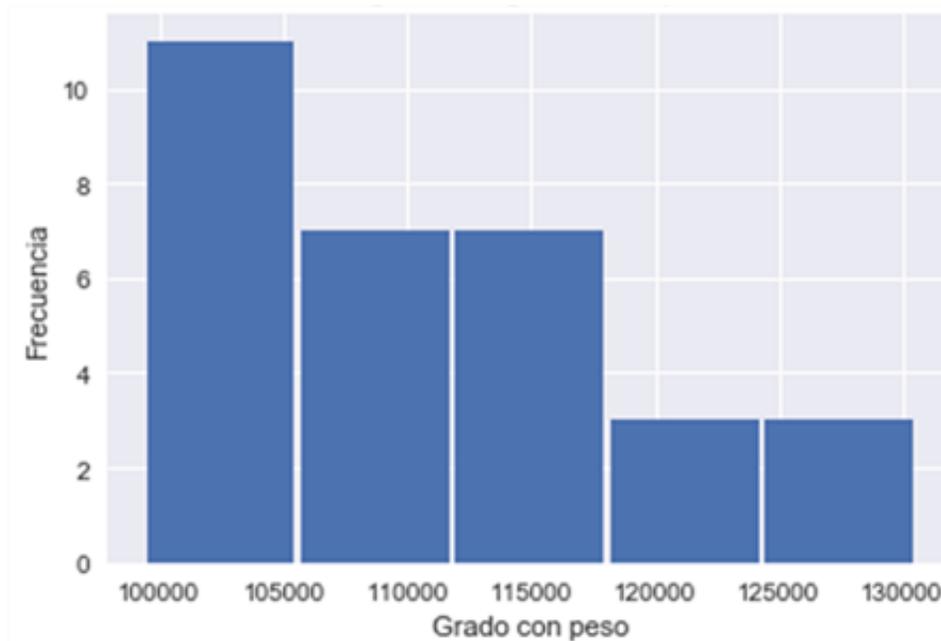


Figura 5. Histograma de grados con peso R de imágenes

De las figuras 3, 4 y 5 podemos ver que grados con peso altos son más frecuentes en los valores G y menos frecuentes en los valores B y R. Esto significa que, para construir la imagen del cultivo fotografiado, se necesitan intensidades más altas de color verde que de color rojo y azul. La presencia e intensidad dominante del color verde en un cultivo que indican los diagramas son muestras de que un cultivo se está desarrollando de una manera saludable y puede servir para caracterizarlo.

Estos valores pueden cambiar si el cultivo no está sano y si es de otro producto alimenticio, ya que es posible que para un cultivo enfermo presente grados con peso más altos para rojo o azul, grados con peso similares para los tres colores o alguna otra anomalía, por lo que valdría la pena analizar cultivos de diferentes tipos.

Conclusiones

Los resultados obtenidos muestran que es posible determinar por medio de un análisis de color y utilizando teoría de redes, la calidad del cultivo y si éste se encuentra sano. Este tipo de análisis puede ser utilizado para caracterizar de manera similar otro tipo

de cultivos o sistemas biológicos en donde, el cambio de color sea un parámetro importante para determinar la calidad, enfermedad y/o estrés hídrico que pudiera presentar el cultivo.

Los sistemas tradicionales de producción tratan las propiedades agrícolas de forma homogénea. Con base en el análisis de imágenes de cultivos se pueden implementar acciones correctivas focalizadas, para obtener sistemas de producción más competitivos y aumentar la eficiencia agronómica del sector. Con este tipo de técnicas de análisis se pueden incrementar y/o mantener la productividad del cultivo y al mismo tiempo reducir los costos de producción.

Referencias

- Báez Rojas, J. J., Guerrero, M. L., Conde Acevedo, J., Padilla Vivanco, A., & Urcid Serrano, G. (2014). Segmentación de imágenes de color. *Revista mexicana de física*, 50(6), 579-587.
- Chartunil, E., Carvalho, F., Marçal, D., & RUz, E. (2007). Nuevas herramientas para mejorar la gestión tecnológica en la empresa agropecuaria. Consultado 13 agosto 2018.
- García, E., & Flego, F. (2008). Agricultura de precisión. *Revista Ciencia y Tecnología*. Recuperado de http://www.palermo.edu/ingenieria/Ciencia_y_tecnologia/ciencia_y_tecno_8.html.
- Gil M A, P A López, A Muñoz O, H López S. (2004) Variedades criollas de maíz (*Zea mays* L.) en el Estado de Puebla, México: diversidad y utilización. In: Manejo de la Diversidad de los Cultivos en los Agroecosistemas Tradicionales. J L Chávez–Servia, J Tuxill y D I Jarvis (eds). Instituto Internacional de Recursos Fitogenéticos. Cali, Colombia. pp:18–25.
- Herrera C B E, F Castillo G, J J Sánchez G, J M Hernández C, R A Ortega P, M M Goodman. (2014) Diversidad del maíz Chalqueño. *Agrociencia* 38:191–206.
- Hillier, F. S. L., Gerald, J., & Elmer, J. (2010). Introducción a la investigación de operaciones. Recuperado 4 de noviembre de 2018, de <https://www.fing.edu.uy/inco/cursos/io/>
- Hortelano S R R, A Gil M, A Santacruz V, S Miranda C, L Córdova T. (2008) Diversidad morfológica de maíces nativos en el Valle de Puebla. *Agric. Téc. Méx.* 34:189–200.

- INEGI, Instituto Nacional de Estadística y Geografía (2010) Anuario de Estadística por Entidad Federativa. INEGI–Aguascalientes, Ags. México. 594 p.
- INEGI, Instituto Nacional de Estadística y Geografía (2007) Anuario Estadístico de Puebla. Tomo II. INEGI; Aguascalientes, Ags. 1284 p.
- Kato y T, A, C Mapes S, L M Mera O, J L Serratos H, R A Bye B. (2009) Origen y Diversificación del Maíz: Una Revisión Analítica. Universidad Nacional Autónoma de México, Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. México, D. F. 116 p.
- Muñoz, O, A. (2015) Centli Maíz. Ed. América. 2da ed. México, D. F. 210 p.
- Perianes, Rodriguez A., Olmeda-Gómez C., De Moya. Anegón F. (2008), Introducción al análisis de redes. El profesional de la información, v. 17, no. 6, pp. 664-669. DOI: 10.3145/epi.2008.nov.10
- Serratos, H, J, A. (2009) El Origen y la Diversidad del Maíz en el Continente Americano. Greenpeace. Ciudad de México, México. 33 p.