



Universidad
Nacional
de Córdoba



FCA
Facultad de Ciencias
Agropecuarias

Metodos cuantitativos para la investigación agropecuaria

Predicción del rendimiento a través de imágenes hiperespectrales del cultivo de maíz

Integrantes:

Ferreyra, Pamela; Gasser, Axel; Moyano, Marcia; Ramos, Cecilia; Romero, Cristian.

Tutora:

Balzarini, Mónica

Asesores:

Aguate, Fernando

Giannini Kurina, Franca



Esta obra está bajo una Licencia Creative Commons
Atribución – No Comercial – Sin Obra Derivada 4.0 Internacional

Contenido

Contenido.....	3
RESUMEN	4
INTRODUCCIÓN	5
OBJETIVOS	7
MATERIALES Y MÉTODOS.....	8
Datos	8
Análisis estadístico	10
RESULTADOS Y DISCUSIÓN.....	14
CONCLUSION	16
ANEXO	17
BIBLIOGRAFIA.....	19

RESUMEN

En el proceso de mejoramiento genético vegetal, la cosecha es una actividad que implica un costo importante, es por esto que se empezó a implementar métodos no destructivos para evaluar los rendimientos de los distintos genotipos como ser el uso de cámaras hiperespectrales, las cuales permiten predecir los rendimientos a través del procesamiento de datos de imágenes del cultivo. En este trabajo se planteó el uso de cuatro modelos estadísticos para predecir el rendimiento a partir del espectro de bandas visibles de una cámara hiperespectral. Los resultados mostraron que el modelo que comprende el espectro rojo que incluye a las bandas 32 a 48, fue el que mejor capacidad predictiva presentó con un error de predicción relativo del 19,4%. Dentro del rango espectral correspondiente al rojo se seleccionaron bandas 32, 33, 34, 35, 36, 37, 39, 40, 42, 43, 44, 46, 47 ya que presentaron mejor capacidad predictiva del rendimiento.

INTRODUCCIÓN

El maíz (*Zea mays* L.) es una gramínea anual, originaria de América, pertenece a la familia de las Poáceas (Gramíneas); es de gran importancia económica a nivel mundial, ya sea como alimento humano, como alimento para el ganado o como fuente de un gran número de productos industriales. Fue el primer cereal en ser sometido a rápidas e importantes transformaciones tecnológicas en su forma de cultivo y actualmente es el cereal con mayor volumen de producción a nivel mundial. El éxito de la tecnología basada en la ciencia para el cultivo del maíz ha estimulado una revolución agrícola generalizada en muchas partes del mundo (FAO, 2003).

El maíz es el segundo cultivo del mundo, después del trigo, por su producción y el primero en rendimiento de grano por hectárea; este se ve afectado por una gran cantidad de factores genéticos y ambientales (Lee y Tollenaar, 2007). Entre ellos (y excluyendo las enfermedades), el estrés por calor y sequía se consideran los más importantes (Wang et al., 2003). Estos factores afectan muchos aspectos de la fisiología vegetal, incluyendo el contenido de clorofila, la biomasa aérea, el contenido de agua de las plantas y por último el rendimiento (Sinsawat et al., 2004, Yordanov et al., 2000).

Muchas de las características fisiológicas y agronómicas de un cultivo que influyen en el rendimiento de los granos, también conducen a diferencias en la reflectancia de la radiación electromagnética a diferentes longitudes de onda. Estas diferencias pueden medirse utilizando cámaras hiperspectrales las cuales pueden medir reflectancia en diferentes longitudes de onda (también denominadas bandas) basándose en un gran número de bandas mediante un método no destructivo es decir para ir visualizando, tener una idea previo a cosecha sin perjudicar el material. Los datos de reflectancia son utilizados para derivar índices de vegetación (IV) que son predictivos de rasgos como el área foliar total, el contenido de clorofila, el contenido de agua, biomasa o rendimiento (Thorp et al., 2015); estos se basan en unas pocas bandas del espectro registrado, por ejemplo, la diferencia normalizada VI (NDVI) se basa en la relación de la diferencia entre la reflectancia en el infrarrojo cercano(NIR), de 700 a 1100 nm, y parte del espectro de color rojo a 670 nm con relación a la suma de ambos(Tucker, 1979). Otros índices comúnmente utilizados son, GVI (Green Vegetation Index) es un Índice de vegetación verde o como también se le conoce GRVI (Green Ratio Vegetation Index), (Sripada et, al. 2006), es el cociente entre la reflectividad en el infrarrojo cercano y la reflectividad en la banda del verde; GNDVI, es una variante del NDVI que utiliza la banda del verde en lugar de la del rojo (Kemerer, 2007); RG, Con este pretendemos calcular un índice que excluya la banda del infrarrojo cercano y ver la relación

entre las bandas rojo y verde, con el índice de vegetación normalizado NDVI; RVI (Ratio Vegetation Index), el mismo representa el cociente entre la reflectividad en el infrarrojo cercano y la reflectividad en la banda del rojo, estando este basado en la diferencia espectral en la vegetación en las longitudes de onda del rojo y del infrarrojo cercano; NRVI; PRI; GRE; X7; CWMI; HBC; HBS; y NIR (Díaz Garcia-Cervigon et al., 2015).

Sin embargo, la gran abundancia y disponibilidad de datos espectrales no se traduce directamente en conocimiento que permita estimar rendimientos. Para esto, es necesario procesar y analizar dicha información que permita estimar rendimiento previo a la cosecha, lo cual permite identificar aquellas zonas de mayor productividad y de mayor prioridad para su cosecha en el momento adecuado. Además, conocer el estado futuro de las unidades de producción mediante la estimación de rendimientos constituye una herramienta valiosa para la planificación a nivel de lote (nivel micro) y para la gestión agropecuaria de grandes áreas (nivel macro).

Estimar rendimientos, desde información espectral, no es una tarea fácil y los modelos deben ajustarse a la realidad puntual que se está estudiando. El uso combinado de la teledetección y los sistemas de información geográfica representan una potente herramienta para los productores agrícolas, ingenieros agrónomos, entidades privadas y públicas, basada en el manejo integrado de los recursos naturales y los sistemas de producción agropecuarios racionalizando el uso de los mismos. Asimismo, permiten el estudio objetivo del impacto de las tecnologías sobre el medio ambiente de manera periódica, rápida y económica.

Herramientas estadísticas, como los modelos de regresión (Balzarini, M., Di Renzo, J., Tablada, M., González, L., Bruno, C., Córdoba, M., Robledo, W., Casanoves, F. (2012). *Estadística y Biometría: Ilustraciones del uso de Infostat en problemas de agronomía*. Córdoba. Ed. Brujas.), aplicadas a problemas como la predicción del rendimiento pueden resultar de gran ayuda. En este trabajo ajustamos diferentes modelos de regresión para la predicción del rendimiento a partir del uso de datos provenientes de cámaras hiperespectrales.

OBJETIVOS

1. Estimar la correlación existente entre diferentes bandas espectrales y el rendimiento del cultivo de maíz de diferentes híbridos en ensayos comparativos de rendimiento.
2. Identificar la banda o combinación de bandas espectrales que presente una mejor capacidad predictiva del rendimiento en el cultivo de maíz.
3. Evaluar la capacidad predictiva de un modelo alternativo para predecir el rendimiento en función de datos relevados con cámaras hiperspectrales.

MATERIALES Y MÉTODOS

Datos

Los datos consistieron en 467 híbridos de maíz experimentales y precomerciales probados en ensayos experimentales. Se utilizaron datos pertenecientes a un programa de mejoramiento genético en un cultivo de maíz, en 11 ensayos comparativos de rendimiento, realizados bajo estrés por calor y sequía en la estación experimental del CIMMYT en Ciudad Obregón, Sonora, México, durante el año 2014. Los ensayos fueron sembrados el 20 de junio en parcelas de 2 hileras de 4,5 m de largo, con una densidad de 6,9 plantas m² con 80 cm de espacio entre hileras, recibieron dos fertilizaciones: 100 kg/ha de (NH₄) H₂PO₄ y 500kg/ha (NH₄)₂SO₄ a la siembra y 250 kg/ha de (NH₄)₂SO₄ en el estado fenológico de V5. Se controlaron malezas, insectos y enfermedades. Las plantas fueron cosechadas a mano el 5 de octubre.

Los ensayos que se usaron en los modelos evaluaron un total de 116 genotipos en un diseño en bloques completos al azar con tres repeticiones. Las variables registradas fueron el rendimiento del cultivo, y reflectancia de 62 bandas espectrales (desde 392nm a 850nm).

Los datos de imagen se recogieron utilizando una cámara hiperespectral (VNIR Headwall Photonics Micro-Hyperspec ARS3, Headwall Photonics) montado en un avión monomotor Piper PA-16Clíper la misma captura múltiples bandas de luz en distintos rangos del espectro electromagnético. Es importante destacar que las imágenes proporcionadas por este tipo de cámaras es una imagen que tiene varias bandas espectrales contiguas de información a través de todo el espectro electromagnético. Las técnicas de formación de estas imágenes dividen al espectro en bandas que se extienden más allá de lo visible. Una banda espectral es un intervalo del espectro electromagnético definido por 2 longitudes de onda.

Para la obtención de las imágenes se procedió a realizar los vuelos 55 días después de la siembra (50% de parcelas florecidas) y se repitieron a los 62, 69, 75 y 83 días después de la siembra. Para lograr una resolución de 30 cm pixel⁻¹, los vuelos fueron realizados a una altitud de 300m y a una velocidad de tierra de 34 mts/seg. La cámara hiperespectral tenía una resolución radiométrica de 10 bits. Adquirió imágenes de 392 a 850 nm, subdivididas en 62 bandas uniformemente espaciadas a una resolución espectral de 1,9 nm, cubriendo el espectro visible que corresponde a la región del espectro electromagnético que el ojo humano es capaz de percibir y cuya longitud de onda va desde los 400-750nm y parte del espectro NIR que comprende el segmento de luz de longitudes de onda entre los 750-2600nm; teniendo en cuenta sus longitudes de onda y la intensidad de la luz que reflejan en la superficie terrestre hacia el espacio, permiten

cuantificar las concentraciones de vegetación en una determinada zona (lote, parcela, bosque, pradera, desierto, etc.); ya que un conjunto de longitudes de onda que un pigmento no absorbe, se refleja y lo que se refleja es lo que vemos como color, por ejemplo en las plantas se refleja el color verde y por ello las vemos de color verde.

Análisis estadístico

Con el objetivo de eliminar el genotipo como fuente de variabilidad se ajustó en cada ensayo para el rendimiento y las bandas espectrales, un modelo de ANAVA con efecto fijo de genotipo. Posteriormente a los residuos obtenidos de los modelos se le sumó la media general de la variable (rendimiento o banda espectral) de cada ensayo. De esta forma se obtuvieron datos de rendimiento en los que la fuente de variación dada por el genotipo fue eliminada.

De las 62 bandas espectrales disponibles se estudió su distribución (Figura 1 y Figura 2). Se procedió a evaluar la correlación con el rendimiento calculando coeficientes de correlación lineal de Pearson. Para evaluar la capacidad predictiva del rendimiento de las bandas espectrales, se utilizaron diferentes estrategias (Tabla 1). En todas ellas se ajustaron diferentes modelos de regresión lineal; el mismo tiene por objetivo identificar un modelo funcional que describa como varía la variable dependiente Y , frente a cambios en X . El modelo para Y presenta constantes desconocidas que se llaman parámetros, por lo que otro objetivo del análisis es la estimación de los parámetros a partir de una muestra aleatoria de observaciones en Y y en X . Además se ocupa de la validación del modelo propuesto y de las pruebas de hipótesis sobre los parámetros del modelo; y por último, también tiene como objetivo la predicción, es decir el uso del modelo para dar el valor esperado de Y cuando X toma un valor particular. Las observaciones de la variable dependiente varían según una función $f(.)$ que depende la/s variable/s independiente/s. Dependiendo de la forma de la función $f(.)$ se tiene un modelo de regresión lineal o un modelo de regresión no lineal, dependiendo del número de regresoras se tiene un modelo de regresión simple (una regresora) o un modelo de regresión múltiple (más de una regresora).

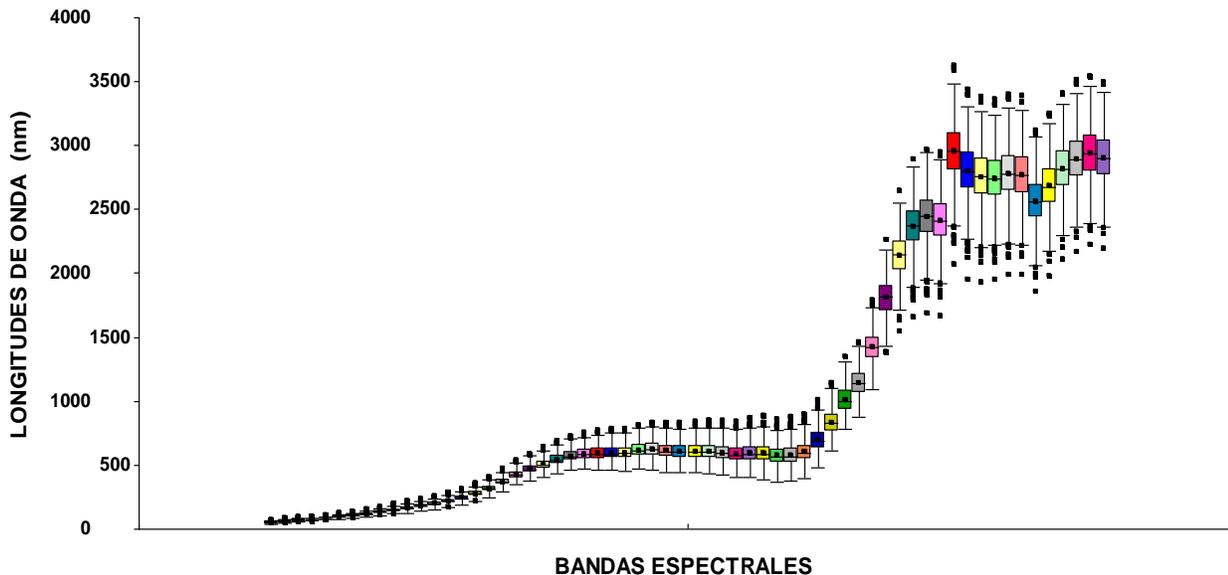


Figura 1: box plot para longitudes de onda (nm) en función de las 62 bandas analizadas en donde se puede observar que la mayor cantidad de bandas están dentro del espectro visible (450-750nm) y tienen menos variabilidad que aquellas bandas más alta que corresponden al infrarrojo.

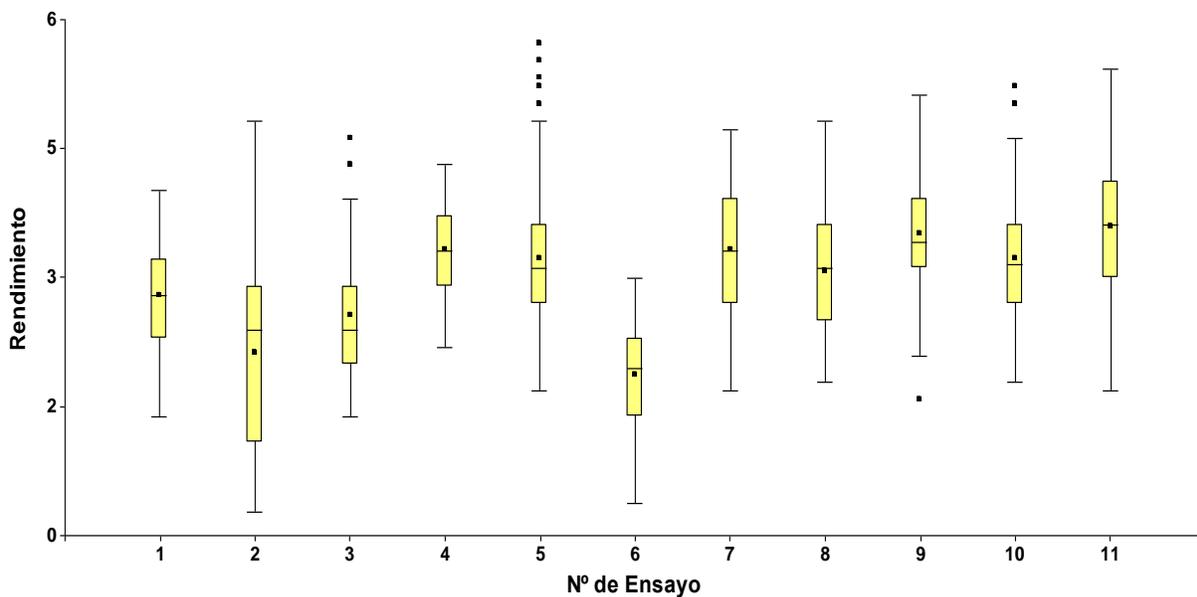


Figura 2: Box-Plot para Rendimiento de maíz en 11 ensayos. En cada box plot se considera 116 híbridos con 3 repeticiones.

En el modelo 1 se utilizó la banda espectral que presentó mayor correlación con el rendimiento a través de todos los ensayos evaluados. En el modelo 2 las variables regresoras fueron las componentes principales (CP1 y CP2) obtenidas a partir de un Análisis de Componentes Principales (PCA, Pearson, 1901) realizados sobre todas las bandas espectrales. El PCA permite examinar todos los datos en un espacio de menor dimensión al espacio original de las variables. En

lugar de considerar cada una de las variables separadamente (análisis univariado), se construye un número (generalmente reducido) de nuevas variables sintéticas de tal manera que estas nuevas variables contengan una alta proporción de la información contenida en el conjunto de variables originales. Además permite decidir cuantas nuevas variables podrían ser necesarias para representar bien la información original.

En el modelo 3 la variable regresora fue el rango de las bandas utilizadas en el modelo 1. En el modelo 4 las variables regresoras fueron las bandas correspondientes al color verde, rojo e infrarrojo cercano en el espectro electromagnético (Tabla 1). En cada estrategia el modelo de regresión ajustado fue realizado bajo el supuesto de independencia, es decir sin ajustar por correlación espacial.

Tabla 1. Bandas espectrales y longitudes de onda en el Espectro Electromagnético.

Banda	Longitud de Onda (nm)	Color en el Espectro
B1-B8	380-450	Violeta
B9-B14	450-495	Azul
B15-B24	495-570	Verde
B25-B27	570-590	Amarillo
B28-B31	590-620	Naranja
B32-B48	620-750	Rojo
B49-B62	750-2600	NIR

Tabla 2. Diferentes Modelos de Regresión Lineal para evaluar la capacidad predictiva del rendimiento.

Variable	Modelo 1	Modelo 2	Modelo 3	Modelo 4
	Modelo de Regresión Simple	Modelo de Componentes Principales	Modelo de Regresión Múltiple	Modelo de Regresión Múltiple
Covariable (Efecto Fijo)	Banda 51;52;53;54;55	CP1 y CP2	Banda 51-55	Verde (B15-B24); Rojo (B32-B48); NIR (B48-B62).
Criterio de Clasificación (Efecto Aleatorio)	Ensayo	Ensayo	Ensayo	Ensayo

Finalmente, para evaluar la capacidad predictiva de los modelos ajustados se procedió a calcular la MSE y RMSE a partir de las diferencias entre los observados y predichos.

$$ECM = \{(O_i - E_i)^2\}/N$$

$$ECMR = \sqrt{(ECM)}$$

$$ECMR(\%) = ECMR/\text{Rendimiento Promedio}$$

En donde ECM es el error cuadrático medio, N es el número de observaciones, O_i es el valor observado y E_i es el valor estimado; ECMR es el error cuadrático medio relativo; y ECMR (%) o Er es el error relativo.

El mejor modelo es cuando b (pendiente de la regresión lineal) es estadísticamente significativa y el coeficiente de determinación R^2 se aproxima a 1. Además $ECM = ECMR = ECMR(\%)$ deben tender a 0. Se considera bueno el ajuste del modelo cuando, $ECMR(\%) \leq 20\%$, b está cerca de 1 y $R^2 > 0,80$ (Pereira, 2004; Stockle et al. 2004; Cai et al., 2007). Todos los análisis estadísticos fueron realizados utilizando el software estadístico InfoStat (Di Rienzo et al., 2016)

RESULTADOS Y DISCUSIÓN

En base a los resultados se construyó la tabla 3, en la cual se presentan los valores de Er(%) para cada modelo. Se puede observar que el modelo 4 es el que mejor predice el rendimiento comparándolo con los otros modelos; ya que RE(<20% y dentro de estos se eligió el de menor valor, siendo este el basado en la banda del rojo. Se trabajó con aquellas regresoras estadísticamente significativas ($p < 0,05$). Se trabajó dentro de la banda roja con distintos valores mediante un modelo de regresión lineal múltiple. En base a las 62 bandas, se plantearon distintos modelos para predecir el rendimiento.

En el modelo 1 los valores obtenidos de Er% fueron superiores al 20% siendo por esto descartado. En el modelo 2 y 3 los valores de Er% fueron buenos (<20%), pero no tanto comparándolo con el modelo 4 donde se obtuvieron los menores valores. Dentro de este modelo predictor de rendimiento, el espectro rojo es que mejor valor arrojó (19,38%); y sobre el cual se realizó un análisis de p-valor de cada una de las bandas que lo componen, determinando que solo algunas son las mejores predictoras; a diferencia de Elwadie et al. (2005) que concluyeron que los índices que utilizan la banda verde (GVI y GNDVI) son los que producen mejores resultados para estimar el rendimiento. El modelo ajustado con las bandas del espectro fue el siguiente,

$$Y = 1,14 + 0,01 \times B_{32} - 0,0047 \times B_{33} - 0,01 \times B_{34} + 0,01 \times B_{35} - 0,01 \times B_{36} + 0,02 \times B_{37} - 0,0039 \times B_{39} + 0,0016 \times B_{40} + 0,0039 \times B_{42} - 0,01 \times B_{43} + 0,0038 \times B_{44} + 0,0037 \times B_{46} + 0,0086 \times B_{47}$$

Tabla 3: Comparación de los diferentes Modelos de Regresión Lineal.

Modelo	Bandas	Er (%)***
1	B51	20,15
	B52	20,15
	B53	20,18
	B54	20,20
	B55	20,22
2	CP	19,99
3	B51-B55	19,92
4	Verde	19,74
	Rojo	19,38
	NIR	19,59

*** Er(%)= Error relativo a la media

El desarrollo continuo de dispositivos de detección, por ejemplo, cámaras, y tecnología de procesamientos de imágenes sirve para la implementación de plataformas de fenotipado de alto rendimiento. Estas pueden ser utilizadas para escanear un gran número de datos (parcelas, genotipos) utilizando un procedimiento no destructivo (Cabrera-Bosquet et Al., 2012).

CONCLUSION

El modelo que mejor predijo el rendimiento de maíz -utiliza una función de regresión lineal múltiple, que incluye las bandas 32,33,34,35,36,37,39,40,42,43,44,46,47 seleccionadas del espectro rojo (32nm, 48nm). El error de predicción relativo del 19,4%.

ANEXO

Planilla General de Ordenamiento de Contenidos de Ética, Desarrollo Personal, Responsabilidad Social y Profesional

nº	Públicos de Interés relacionados con el TAI	Oportunidad / Afectación Positiva	Riesgo / Afectación Negativa	Indicador de RS&S	Respuesta de Gestión de RS&S	Tipo de Valor Generado para los Públicos de Interés
				nº / Justificación		Ético-Cultural / Social / Ambiental / Económico
De afectación directa						
1	Empresas mejoradoras de semillas	*Se ahorra el costo de cosecha si el rendimiento no es el esperado. *Aumenta el rendimiento	Competencia con otras empresas.	45: la empresa difunde entre los clientes y productores sus políticas y prácticas de relacionamiento ético y conforme la legislación.	La empresa conoce las leyes y normas para comercializar sus productos, como así también capacita y asesora a sus colaboradores para que la comercialización se realice siempre en la ley.	*Ético-Cultural: Cumplimiento de normas de comercialización. *Económico: mayor ingreso y menores costos.
2	Productor	*Aumenta el rendimiento a partir de la semilla mejorada que compra.	Mayor cantidad de camiones en ruta.	41: Al haber más cantidad de camiones en ruta, aumenta la contaminación ambiental, hay mayor deterioro de rutas y una mayor posibilidad de accidentes.	Todos los vehículos que contratan se encuentran en regla, conforme a lo que indican las leyes.	*Ético-Cultural: uso racional de insumos. *social: mayor oferta de alimento. * Ambiental: menos uso de agroquímicos. *Económico: mayor ingreso y menores costos.

3	Entidades encargadas de elaborar estadísticas	*Crear un modelo que permita predecir el rendimiento.	Mala elección del modelo predictor.	2: La empresa debe entregarle al cliente información verídica y coherente.	Capacitación del personal en procesamiento de datos.	*Ético-Cultural: Responsabilidad en los informes entregados.
4	Mano de obra	*Elementales para la realización de las distintas tareas.	Reducción de la misma al momento de la cosecha.	17: En el momento de la cosecha si el rendimiento no es el esperado, no se levanta la cosecha y se reduce la mano de obra.	La empresa para evitar desvinculaciones en masa busca otras alternativas para mantener activo el mismo personal.	*Ético-cultural: Responsabilidad social. *Social: no aumentar el desempleo.
De afectación indirecta						
1	Consumidores	Mayor oferta de alimento	Mala conservación del producto afectando a la salud.	46: la empresa debe cumplir con las normas de inocuidad para no afectar a los consumidores.	La empresa conoce y respeta la legislación vigente sobre condiciones sanitarias que exige la ley y si detecta alguna desconformidad, realiza ajustes para cumplir con la ley.	*Social: aumenta la oferta de alimentos y a su vez el precio disminuye.
2	Sociedad	Menor impacto ambiental para la comunidad por menor uso de agroquímicos.	Mayor cantidad de desempleados.	12: la empresa debería realizar un seguimiento de sus actividades y ver que todas sean sustentables.	Cuenta con un sistema de gestión integral de RS y sustentabilidad para las diversas áreas (producción, calidad, recursos humanos, ventas, entre otras).	*Ético-cultural: compromiso social. * Ambiental: menor contaminación.

BIBLIOGRAFIA

Aguate F, Samuel Trachsel, Lorena González Pérez, Juan Burgueño, José Crossa, Mónica Balzarini, David Gouache, Matthieu Bogard, and Gustavo de los Campos 2017. Use of Hyperspectral Image Data Outperforms Vegetation Indices in Prediction of Maize Yield

Balzarini M.G., González L., Tablada M., Casanoves F., Di Rienzo J.A., Robledo C.W. 2008. Infostat. Manual del Usuario, Editorial Brujas, Córdoba, Argentina

Balzarini M., Di Rienzo J., Tablada M., González L., Bruno C., Córdoba M., Robledo W. y Casanoves F. 2012. Estadística y Biometría. Ilustraciones del uso de InfoStat en problemas de Agronomía. Ed. Brujas. 402 pp.

Cabrera-Bosquet, L., J. Crossa, J. von Zitzewitz, M.D. Serret, and J. Luis Araus. 2012. High-throughput phenotyping and genomic selection: The frontiers of crop breeding converge. *J. Integr. Plant Biol.* 54:312–320. doi:10.1111/j.1744-7909.2012.01116.x

Díaz García-Cervigón JJ. 2015. Estudio de Índices de vegetación a partir de imágenes aéreas tomadas desde UAS/RPAS y aplicaciones de estos a la agricultura de precisión. 78 pp. Argentina.

Di Rienzo J.A., Casanoves F., Balzarini M.G., González L., Tablada M., Robledo C.W. InfoStat versión 2016. Grupo InfoStat, FCA, Universidad Nacional de Córdoba, Argentina. 8 de febrero 2019. URL <http://www.infostat.com.ar>

Elwadie, M.E., F.J. Pierce, and J. Qi, 2005. Remote sensing of canopy dynamics and biophysical variables estimation of corn in Michigan. *Agron. J.* 97:99-105.

Lee, E.A., and M. Tollenaar. 2007. Physiological basis of successful reeding strategies for maize grain yield. *Crop Sci.* 47:S-202–S-215. doi:10.2135/cropsci2007.04.0010IPBS

Pearson K. 1901. On lines and planes of closest fit to systems of points in space. *Philos. Mag.* 2: 559–572.

Pereira A. 2004. The Priestley-Taylor parameter and the decoupling factor for reference evapotranspiration. *Agricultural and Forest Meteorology*, 125:305-313.

Ripusudan.L, Paliwal. Introducción al maíz y su importancia. Organización de las Naciones Unidas para la alimentación y la Agricultura 2003. 8 de febrero 2019. URL. <http://www.fao.org>

Sinsawat, V., J. Leipner, P. Stamp, and Y. Fracheboud. 2004. Effect of heat stress on the photosynthetic apparatus in maize (*Zea mays* L.) grown at control or high temperature. *Environ. Exp. Bot.* 52:123–129. doi:10.1016/j.envexpbot.2004.01.010

Thorp, K., M. Gore, P. Andrade-Sanchez, A. Carmo-Silva, S. Welch, J. White, and A. French. 2015. Proximal hyperspectral sensing and data analysis approaches for field-based Plant phenomics. *Comput. Electron. Agric.* 118:225–236. doi:10.1016/j.compag.2015.09.005

Tucker, C.J. 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* 8:127–150. doi:10.1016/0034-4257(79)90013-0

Wang, W., B. Vinocur, and A. Altman. 2003. Plant responses to drought, salinity and extreme temperatures: Towards genetic engineering for stress tolerance. *Planta* 218:1–14. doi:10.1007/s00425-003-1105-5