



INSTITUTO TECNOLÓGICO SUPERIOR DE ÁLAMO TEMAPACHE

TITULACIÓN

TESIS PROFESIONAL

**“SISTEMA DE APOYO A LA DECISIÓN EN
FERTILIZACIÓN DE MAÍZ “**

PARA OBTENER EL TÍTULO PROFESIONAL DE

INGENIERO INDUSTRIAL

PRESENTA

EMMANUEL ZUÑIGA HERNÁNDEZ

DIRECTOR DE TESIS

DR. RAMIRO MEZA PALACIOS

CO- DIRECTOR DE TESIS

M.I.I GERMÁN DOMÍNGUEZ CARRILLO

Xoyotitla, Álamo Temapache, Veracruz. Julio 2025

AGRADECIMIENTOS.

Quiero agradecer principalmente a mis padres, quienes me han apoyado desde un inicio, no solamente económicamente, sino también emocionalmente al brindarme su apoyo incondicional, así mismo como sus consejos y motivaciones para seguir adelante; quiero expresar que sin su apoyo no hubiese logrado lo que hoy está presente. A su vez también quiero agradecer a mis familiares cercanos especialmente a mi hermano, sobrino, novia, abuela y tía, los cuales del mismo modo han estado para mí cuando lo requiero y han sabido apoyarme en cada momento requerido.

Le agradezco a todas esas personas presentes en esta etapa, a mis amigos más cercanos los cuales me brindaron su apoyo especial en malos y buenos momentos, la compañía de ellos hizo más amena la estancia en esta carrera. También quiero expresar mi gratitud a aquellos compañeros de generación por los buenos momentos vividos en estos años.

Un agradecimiento a mis asesores, quienes estuvieron presentes en esta estancia y lograron brindar su conocimiento; me gustaría agradecer al Dr. Ramiro Meza Palacios y al M.I.I Germán Domínguez Carrillo, por toda la paciencia y conocimiento brindado para un mejor entendimiento del tema. Así mismo quiero expresar mi agradecimiento a todos los docentes que se presentaron en cada fase de mi estudio, por ese conocimiento brindado.

Claro está que todo esto es gracias al apoyo de todas esas personas especiales que fueron partícipes de esta aventura, la cual no fuera posible sin la voluntad de dios, el cual no ha dejado a un lado mi existencia y ha estado para mí, brindándome esa fortaleza, voluntad y salud, sobre todo, para poder salir adelante y seguir superándome.

RESUMEN

La fertilización a base de nitrógeno, fosforo y potasio, para la agricultura de maíz, es un medio que permite a los agricultores mejorar su rendimiento por hectárea, lastimosamente muchas veces esta aplicación es realizada de manera incierta, al no considerar todas esas variables presentes en el cultivo. En este estudio se realizaron dos modelos de ANN BP (redes neuronales artificiales backpropagation) mediante el software Matlab, con una estructura similar, con la finalidad de pronosticar las dosis de fertilización NPK (Nitrógeno, fosforo y potasio) y el rendimiento esperado (RE), tomando en cuenta variables físicas, climatológicas, químicas, de plagas y etc; siendo un total de 22 variables tomadas en cuenta para ambos modelos; a su vez también con estos se tuvo como objetivo el determinar las variables de mayor relevancia o impacto, que son aquellas que tienden a alterar o afectar la salidas, al tener una gran influencia a comparación de las demás. En general ambos modelos, fueron funcionales al lograr su cometido, prediciendo de manera cercana las dosis NPK y rendimiento esperado, esto fue comprobado mediante una validación de datos, al comparar los valores predichos de cada modelo con los valores reales; donde el modelo NPK para nitrógeno, fosforo y potasio; presento un coeficiente de determinación entre el 0.90 a 0.94 y el modelo RE obtuvo R^2 del 0.9919, confirmando el ajuste y validez de ambos casos. En general, este estudio brinda una alternativa para lograr una predicción estimada de las dosis NPK, que se pueden utilizar en los cultivos de maíz para la región de Álamo considerando todas las variables influyentes en el terreno y así mismo el rendimiento esperado (RE); todo esto gracias a los modelos de redes neuronales desarrolladas. Siendo así que con estos modelos se puede poner a disposición de los agricultores una alternativa más para tomar esa decisión, de si realmente fertilizar su cultivo acorde a las características físicas y químicas del suelo, al contar con una predicción cercana a lo real gracias a los modelos.

Palabras claves: Red neuronal artificial, nitrógeno, fosforo, potasio, rendimiento esperado, base de datos, variables, plagas, climatológicas y Matlab.

ABSTRAC.

Nitrogen, phosphorus and potassium fertilization for corn agriculture is a means that allows farmers to improve their yield per hectare, unfortunately, many times this application is done in an uncertain way, because it does not consider all these variables present in the crop. In this study, two ANN BP (backpropagation artificial neural networks) models were made using Matlab software, with a similar structure, with the purpose of forecasting the NPK (Nitrogen, phosphorus and potassium) fertilization doses and the expected yield (ER), taking into account physical, climatological, chemical, pest and other variables, with a total of 22 variables taken into account; A total of 22 variables were taken into account for both models; at the same time, the objective of these models was to determine the variables of greatest relevance or impact, which are those that tend to alter or affect the outputs, as they have a great influence compared to the others. In general, both models were functional in achieving their purpose, closely predicting the NKP doses and expected yield, this was verified by data validation, comparing the predicted values of each model with the real values; where the NPK model for nitrogen, phosphorus and potassium; presented a determination coefficient between 0.90 and 0.94 and the RE model obtained R^2 of 0.9919, confirming the adjustment and validity of both cases. In general, this study provides an alternative to achieve an estimated prediction of NPK doses, which can be used in corn crops for the Alamo region considering all the influential variables in the field and also the expected yield (ER); all this thanks to the neural network models developed. Thus, with these models it is possible to provide farmers with another alternative to make the decision of whether to fertilize their crop according to the physical and chemical characteristics of the soil, by having a prediction close to reality thanks to the models.

Key words: Artificial neural network, nitrogen, phosphorus, potassium, expected yield, database, variables, pests, climatological and Matlab.

ÍNDICE TEMÁTICO.

AGRADECIMIENTOS.....	I
RESUMEN.....	II
ABSTRAC.....	III
ÍNDICE DE TABLAS.....	VI
ÍNDICE DE FIGURAS.	VI
ÍNDICE DE ECUACIONES.	VII
CAPITULO I . INTRODUCCIÓN	1
1.1 Antecedentes.....	2
1.2 Planteamiento del problema.....	3
1.3 Justificación.	4
1.4 Hipótesis.....	5
1.5 Objetivos.	5
1.5.1 Objetivo general.....	5
1.5.2 Objetivos específicos.	5
CAPITULO II . MARCO TEORICO	6
2.1 Marco conceptual.....	6
2.1.1 Maíz.	6
2.1.2 Agricultura de precisión.....	8
2.1.3 Fertilización agrícola.	9
2.1.4 Instrumento de recolección de datos.....	10
2.1.5 Matlab.	14
2.1.6 Red neuronal.	15
2.1.7 Normalización de datos.....	18
2.1.8 Análisis de residuales.....	18

CAPITULO II . ESTADO DEL ARTE.....	20
3.1 Trabajos relacionados	20
3.2 Discusión.....	26
CAPITULO IV. DESARROLLO	31
4.1 Metodología.	31
4.2 Delimitación del problema.....	32
4.3 Recolección y análisis de la información.....	33
4.3.1 Entrevista y prueba piloto.	38
4.3.2 Análisis de la información y creación de la base de datos.....	41
4.3.3 Contenido final de la base de datos.....	46
4.4 Creación y configuración de la red neuronal.	46
4.4.1 Red neuronal en Matlab.	47
4.4.2 Simulación de la red para la predicción, Matlab.....	56
4.4.3 Contribución relativa (RC).	57
CAPITULO V . ANÁLISIS DE RESULTADOS.....	58
5.1 Entrenamientos de red favorable.....	58
5.2 Validación y uso de la red.....	61
5.2.1 NPK.....	61
5.2.2 Rendimiento esperado (RE).....	66
CAPITULO VI. CONCLUSIONES.....	70
REFERENCIAS BIBLIOGRÁFICAS.	72
ANEXOS.....	76

ÍNDICE DE TABLAS.

TABLA III-1.DISCUSIÓN.....	26
TABLA IV-1.VARIABLES DE LA INVESTIGACIÓN.....	33
TABLA IV-2. MEDIO DE OBTENCIÓN DE LA INFORMACIÓN.....	37
TABLA IV-3. EXTRACCIÓN DE INFORMACIÓN A LA BASE.	41
TABLA IV-4. NUTRIENTES QUE APORTA CADA FERTILIZANTE.....	43
TABLA IV-5. CANTIDAD DE FERTILIZANTE LÍQUIDO APLICADO EN EL CULTIVO.....	44
TABLA IV-6. CANTIDAD DE FERTILIZANTE SOLIDO GRANULADO SOLUBLE EN AGUA.	44
TABLA IV-7. CANTIDAD DE FERTILIZANTE SOLIDO APLICADA EN EL CULTIVO.....	44
TABLA IV-8. KG / HA APLICADO.....	46
TABLA IV-9.EJEMPLO DE UNA FRACCIÓN DE LA BASE A UTILIZAR.	46
TABLA IV-10.DESIGNACIÓN DE VALORES NUMÉRICOS.	47
TABLA IV-11.PROPIEDADES DE LA RED.	53
TABLA IV-12.NÚMERO DE VARIABLES DE ENTRADA Y SALIDA UTILIZADAS.	54
TABLA V-1. RESUMEN DE LOS ENTRENAMIENTOS RED NPK Y RENDIMIENTO ESPERADO.	58
TABLA V-2.MEJOR ENTRENAMIENTO.....	59
TABLA V-3. PREDICCIONES Y VALORES REALES, DEL MODELO NPK.....	61
TABLA V-4.DIFERENCIA MAX Y MIN DE RESIDUO, NPK.....	62
TABLA V-5.PREDICCIONES Y VALORES REALES, DEL MODELO RENDIMIENTO ESPERADO. ..	66
TABLA V-6.VALORES MAX Y MIN, RENDIMIENTO ESPERADO.....	67
TABLA V-7. TABLA RESUMEN DE RESULTADOS.	69

ÍNDICE DE FIGURAS.

FIGURA II-1. MAÍZ CRIOLLO	6
FIGURA II-2.GUSANO COGOLLERO.....	7
FIGURA II-3.PAPALOTILLA.....	7
FIGURA II-4.GUSANO FALSO MEDIDOR.....	8
FIGURA II-5.HORMIGA ARRIERA.	8
FIGURA II-6.FERTILIZACIÓN AGRÍCOLA.	9
FIGURA II-7.ELEMENTOS BÁSICOS DE UNA RED NEURONAL.	16
FIGURA II-8. TIPOS DE CORRELACIONES.	19
FIGURA IV-1.METODOLOGÍA A IMPLEMENTAR.	31
FIGURA IV-2.LIMITACIONES EN EL CULTIVO DE MAÍZ.....	32
FIGURA IV-3.COMUNIDADES ENTREVISTADAS.	41
FIGURA IV-4. ALTITUD Y PENDIENTE.....	42

FIGURA IV-5.CREACIÓN DE LA RED NEURONAL, MATLAB.....	48
FIGURA IV-6. INTRODUCCIÓN DE LOS DATOS, MATLAB 2014.	49
FIGURA IV-7. VENTANA NNTOOL, MATLAB 2014.....	49
FIGURA IV-8. IMPORTACIÓN DE VARIABLES, MATLAB 2014.	50
FIGURA IV-9. CONFIGURACIÓN DE LA RED NEURONAL, MATLAB 2014.	51
FIGURA IV-10. RED NPK Y RENDIMIENTO ESPERADO, MATLAB.	53
FIGURA IV-11. SELECCIÓN DE ENTRADAS Y SALIDAS PARA TRAIN.	54
FIGURA IV-12. NEURAL NETWORK TRAINING.....	55
FIGURA IV-13.SIMULACIÓN MATLAB.	56
FIGURA V-1. COEFICIENTES DE CORRELACIÓN DE RED NPK.	60
FIGURA V-2. COEFICIENTES DE CORRELACIÓN DE RED RENDIMIENTO ESPERADO.....	60
FIGURA V-3.DISPERSIÓN NITRÓGENO (N).....	63
FIGURA V-4.VARIABLES DE IMPACTO RELATIVO PARA NITRÓGENO (N).....	63
FIGURA V-5.DISPERSIÓN FOSFORO (P).....	64
FIGURA V-6.VARIABLES DE IMPACTO RELATIVO PARA FOSFORO (P).....	64
FIGURA V-7.DISPERSIÓN POTASIO (K).	65
FIGURA V-8.VARIABLES DE IMPACTO RELATIVO PARA POTASIO (K).	65
FIGURA V-9.DISPERSIÓN RENDIMIENTO ESPERADO.	67
FIGURA V-10.VARIABLES DE MAYOR IMPACTO PARA RENDIMIENTO.	68

ÍNDICE DE ECUACIONES.

ECUACIÓN IV-1.FERTILIZANTE FINAL APLICADO AL CULTIVO.....	45
ECUACIÓN IV-2. DEFINICIÓN DEL NOMBRE DE LA BASE.	48
ECUACIÓN IV-3.DEFINICIÓN DE ENTRADAS Y SALIDAS.	48
ECUACIÓN IV-4.NORMALIZACIÓN DE ENTRADAS Y SALIDAS.....	49
ECUACIÓN IV-5. ALGORITMO DE GARSON.....	57

CAPITULO I . INTRODUCCIÓN

La producción de maíz ha ido generando un mayor interés a nivel mundial, al ser uno de los granos más importantes para el consumo humano. En la ciudad de Álamo Temapache, se produce mayormente los cítricos, por lo cual deja al descuido un poco otros cultivos como, el maíz el cual se le debería considerar un poco más al momento de cultivarlo. En el cultivo de maíz existen factores físicos, químicos, climatológicos y de plagas, los cuales impactan al cultivo, como lo son: el tipo de suelo, los nutrientes necesarios para el maíz (nitrógeno, fosforo y potasio), las condiciones climáticas, el uso de plaguicidas y de fertilizantes.

El buen manejo estos factores, sobrelleva a poder obtener mejores resultados en el plantío, mediante a que algunos componentes, se pueden moderar de manera que beneficie al cultivo; especialmente el uso de fertilizantes que ayuda a la planta a adquirir esos nutrientes faltantes que no se encuentran en el suelo. Se puede incursionar más haya en la agricultura de maíz mediante el manejo de la tecnología, para ayudar a fijar qué elementos son los más importantes considerar, al momento de impartir en el cultivo de maíz, lo cual representa una de tantas soluciones para conocer las deficiencias que existen.

Actualmente el uso de la tecnología en el sector agrícola ha ido en aumento, logrando acrecentar el rendimiento del trabajo y la tierra. Mediante este medio se logra el desarrollo de sistemas inteligentes que ayudan a determinar esos factores que más afectan, a los cultivos de maíz, del mismo modo para conocer aquellas cantidades que son requeridas para cada tipo de suelo tomando en cuenta todos los elementos físicos y químicos presentes. Softwares como Matlab, tienen la función, para la creación de sistemas inteligentes, que dejan analizar y predecir valores estimados de las dosis de fertilización requeridas para cada tipo de terreno, con lo cual se puede reducir el uso excesivo de los recursos, los cuales a su vez conllevan gastos elevados. De ese modo se pueden mejorar resultados de productividad y la obtención de un mejor rendimiento de maíz, a través del mejor uso de los recursos, al considerar correctamente todos los factores físico y químico de los que lleguen a influir en el cultivo.

1.1 Antecedentes.

Los temas acerca de la aplicación de fertilizantes, para los agricultores al paso del tiempo han resultado un tema de gran interés, muchas veces este tema suele tener cierto desconocimiento no en su finalidad, sino en la manera correcta en que se deben llegar aplicar ciertas dosis o cuales son realmente las necesarias para el cultivo de modo que se logre atender realmente las necesidades de la planta y no se genere un desperdicio.

Aunque claramente los agricultores son los expertos en el tema, no llegan a considerar factores y variables más allá del suelo o terreno, lo que impide que realmente se aprovechen estas dosis de fertilizante aplicado, por ello se han realizado varios estudios alrededor del mundo sobre este tema, donde la principal finalidad es poder pronosticar las tasas aproximadas de fertilización para el cultivo del maíz, que son ideales de acuerdo al tipo de suelo que se presente, tomando en cuenta todas aquellos factores y variables influyentes, para poder apoyar en esa decisión de si realmente es recomendable invertir en la fertilización de este grano tan importante en el mundo.

Existen estudios muy representativos del tema, los cuales aplican el uso de las nuevas tecnologías, al introducir modelos que manejan redes neuronales, para lograr una predicción estimada de estos nutrientes y cuáles son las variables que más alteran esta estimación. En el año 2006 Miao y otros, de emplearon el análisis de redes neuronales artificiales para evaluar la importancia relativa de los factores híbridos seleccionados del suelo, el paisaje y las semillas en el rendimiento y la calidad del grano en dos campos de Illinois, EE. UU, en el cual logro identificar que de 7 a 13 factores importantes que explicaban del 61% al 99% del rendimiento observado. Otro estudio representativo del tema de interés fue en el año 2010 donde Yu y otros, donde se propuso un nuevo método de conjunto de redes neuronales, para calcular la tasa de fertilización con mayor precisión de maíz, al final como resultado se obtuvo que modelo de fertilización construido no solo puede simular con precisión la relación no lineal entre el rendimiento y el nivel de nutrientes del suelo, sino que también puede hacer un uso adecuado de los datos existentes sobre el efecto de los fertilizantes. Una última investigación de interés, elaborada año 2019 por el autor de apellido Toapanta, estudió el rendimiento por hectárea de maíz duro seco mediante regresión lineal múltiple y redes

neuronales perceptrón multicapa (MLP), brindando las variables que tienen una mayor incidencia en el rendimiento de maíz por ha, las cuales son la fertilización y la posición geográfica.

En general se han hecho más estudios similares los cuales buscan determinar esas tasas de fertilización necesarias en los cultivos del maíz, lo cual en gran similitud se lleva mediante la aplicación de las redes neuronales artificiales, con las cuales se llegan a obtener mejores resultados finales.

1.2 Planteamiento del problema.

La agricultura es una actividad del sector primaria que ofrece a las personas alimento, empleo y otros recursos económicos. Especialmente las personas que se dedican a esta práctica apoyan al sustento alimenticio para las zonas donde se lleve a cabo. Actualmente la agricultura del maíz es una de las más importantes a nivel global, pero cada vez existen distintos factores que impiden o estancan la productividad de este grano tan importante para los seres humanos y animales. Dentro de los factores principales, que limitan los cultivos de maíz, encontramos: el tipo de suelo, los nutrientes necesarios para el maíz, las condiciones climatológicas, las plagas y el uso de fertilizantes (nutrientes necesarios). Estos, llegan a representar, un problema, al momento de no conocer con exactitud si el terreno requiere una mayor cantidad de alguno de ellos; de acuerdo con las características físicas y químicas, que estén presentes. Especialmente la aplicación de fertilizantes trae muchas veces consigo el cuestionarse la cantidad necesaria que se debe aplicar en el cultivo de maíz, dicha pregunta está presente, mediante a que es considerado por los agricultores que mientras más fertilizante se aplique al cultivo obtendrán mayores rendimientos, pero lastimosamente no es así. Ya que, al momento de aplicar mayores cantidades de nutrientes, esto puede perjudicar al cultivo, obteniendo con ello una afectación no solo para la cosecha sino, también de manera ambiental y monetaria. Entonces el desconocimiento de las cantidades adecuadas para la fertilización de maíz, los otros factores que influyentes, y las consecuencias que generan el uso excesivo de estos mismos, genera esta gran problemática en la región.

1.3 Justificación.

Los problemas presentes en la deficiencia productiva del maíz se ven influidos por las condiciones climáticas, plagas, propiedades físicas y sobre todo el mal uso de los fertilizantes, asimismo como este último, ha tenido un aumento de precio a través de los años. Los agricultores que lo utilizaban se ven afectados, al no poder comprar las mismas cantidades requeridas para sus terrenos, derivado del costo elevado. Siendo así que la inversión que aportaban para una mejor productividad se vea mermada, esto afecta principalmente a aquellos agricultores con recurso limitado, aunque también a aquellos con el recurso necesario. Aunque esta limitante va más allá de poder adquirir el producto, sino también un punto medular que influye mucho es el saber aplicar las cantidades necesarias acorde a las condiciones presentes del terreno, porque muchas veces se aplican cantidades exageradas sin saber que esto puede perjudicar al cultivo, al ambiente y sobre todo a la economía del agricultor, por eso es necesario determinar esas dosis estimadas para fertilización especialmente en nutrientes fundamentales para el crecimiento y desarrollo de la planta, como lo son el nitrógeno, fósforo y potasio. La ciudad de Álamo Temapache tiene una superficie continental de 1,279.0 Km², del cual 730.4 Km² es utilizada para la agricultura, en el año 2021 esta región logró una producción aproximada de 22,783.70 toneladas de maíz (INEGI, 2021)., a pesar de que la zona no es muy productora de maíz, ya que se enfoca más en los cítricos; pero pudiera incursionar más en este cultivo. Es ahí donde el buscar soluciones óptimas para el aumento de producción del maíz, conlleva el manejo de distintos factores físicos y químicos, los cuales se pueden regular y estimar, con el uso de la tecnología, ya que como sabemos la aplicación de la tecnología utilizada en cualquier sector brinda un gran apoyo, a través del uso e implementación de sistemas inteligentes. Como es el caso para el sector agrícola, el manejo de esta contribuye, a la reducción del consumo de químicos y agroquímicos, generando una mayor eficiencia en sentido de rendimiento productivo, a su vez la reducción de costos y la obtención de un mejor producto, estos métodos anteriormente han sido aplicados y brindado resultados positivos, como lo menciona la revista de ciencia y tecnología publicada en el 2008, donde establece que “el uso de las tecnologías de 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 la cantidad de insumos, o de ambos simultáneamente” (García & Flego, 2008). Por lo tanto, desarrollar un sistema inteligente,

que calcule las tasas de fertilización adecuadas para el maíz y el rendimiento esperado, beneficiaría tanto agricultores con o sin recurso económico, de manera que solo inviertan en la cantidad de fertilizante ideal, para lograr obtener rendimientos favorables; evitando de esa manera que se genere un uso excesivo de los mismo, también se espera que se ponga a consideración si invertir en fertilización a base de nitrógeno, fósforo y potasio, mejorara los resultados por hectárea para evitar gastos excesivos al adquirir fertilizantes, dejando como decisión final al agricultor al presentarle predicciones cercanas a lo real acorde a su suelo.

1.4 Hipótesis.

H1: La elaboración de modelos, a base de redes neuronales para la predicción de los valores NPK y rendimiento esperado del maíz, funcionan correctamente y logran estimar datos cercanos a la realidad.

H0: La elaboración de modelos, a base de redes neuronales para la predicción de los valores NPK y rendimiento esperado del maíz, no funcionan correctamente y no logran estimar datos cercanos a la realidad.

1.5 Objetivos.

1.5.1 Objetivo general.

Desarrollar un modelo inteligente capaz de estimar las dosis correctas de fertilización, en la agricultura del maíz para los campos de la región de Álamo Temapache.

1.5.2 Objetivos específicos.

- Pronosticar las tasas de nitrógeno (N), fosforo (P) y potasio (K) para la agricultura de maíz, mediante un sistema basado en redes neuronales.
- Pronosticar el rendimiento esperado del maíz, usando un sistema basado en redes neuronales.
- Determinar las variables de impacto relativo del modelo NPK.
- Determinar las variables de impacto relativo del modelo rendimiento esperado.

CAPITULO II. MARCO TEORICO

2.1 Marco conceptual.

2.1.1 Maíz.

Coll y Godínez (2003) consideran al maíz como un elemento estratégico para la soberanía y seguridad alimentaria en sus distintas formas de usos y valores socioculturales de los mexicanos, principalmente para el medio rural. Es uno de los granos alimenticios más antiguos que se conocen, es una planta domesticada y altamente productiva que no crece en forma salvaje por lo que es completamente dependiente de los cuidados del hombre.

Maíz criollo.

El maíz que más se consume en México es el blanco e híbrido por su bajo precio y amplia distribución. Pues, el criollo está enfocado en el autoconsumo, es decir, en producciones pequeñas hechas por familias, principalmente en el sur y sureste del país. El Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP) asegura que el maíz criollo requiere menos insumos como pesticidas y fertilizantes.

El **maíz criollo**, ver Figura II-1. Es capaz de enfrentar enfermedades, sequías y plagas con mayor frecuencia, así como facilidad, debido a su gran diversidad genética (Jiménez Pedroza , 2022). La gran diferencia existente entre el maíz híbrido y el criollo, es que el maíz híbrido es más productivo, pero menos resistente a comparación del criollo.



Figura II-1. Maíz criollo

Fuente: (SEPI, 2017)

Plagas.

Según Saunders et al. (1998), las plagas de los cultivos son aquellos organismos (insectos, ácaros, babosas, nematodos, roedores, pájaros y en algunas definiciones, las malezas y enfermedades) que compiten con el hombre por los alimentos que produce.

- **Gusano cogollero:** El cogollero es una de las plagas más importantes del maíz, ver Figura II-2. Se presenta durante todo el año, pero la intensidad de sus poblaciones y daños varían de acuerdo con la época del año y zona del país donde se presenta. Si no se combate, campos de maíz pueden ser totalmente destruidos por este insecto (Jiménez Martínez, Sandino Díaz, & Valle Gómez, 2016).



Figura II-2. Gusano cogollero.

Fuente: (Gruposacsa, 2019)

- **Papalotilla:** Plaga presente en diferentes cultivos de maíz, para la zona a estudiar, el mal cuidado de la misma puede afectar al cultivo. Ver Figura II-3.



Figura II-3. Papalotilla.

Fuente: (DÍAZ ROMERO , 2018)

- **Gusano medidor:** Plaga, que se alimenta de las vainas del cultivo, ocasionando daños irregulares a las paredes de la misma, las hojas quedan perforadas y se ve afectado el cultivo por esto, ver Figura II-4.



Figura II-4. Gusano falso medidor.

Fuente: (Reyes C. , 2015)

- **Las hormigas arrieras o cortadoras de hojas:** Representan una plaga importante que limita la producción en gran cantidad y variedad de cultivos en países debido a su dispersión, adaptabilidad y éxito evolutivo. Ver Figura II-5.



Figura II-5. Hormiga arriera.

Fuente: (MacAllen , 2020)

2.1.2 Agricultura de precisión.

La Agricultura de Precisión (AP) es un sistema empleado para analizar y controlar la variación de los cultivos por medio de tecnologías satelitales, monitoreo y maquinaria automatizada. Dicha variabilidad comprende las diferencias en la fertilidad de distintas secciones del terreno y las que se dan durante el crecimiento de las plantas cultivadas, además de las diferencias observadas en la producción de un mismo terreno entre una temporada y otra. Esta moderna agricultura permite reducir hasta 90% el uso de insumos agrícolas que son liberados al medio ambiente (como los pesticidas). Con este tipo de manejo se consigue

una mayor sostenibilidad, ya que minimiza los recursos invertidos, el impacto ambiental, los riesgos agroalimentarios y maximiza la producción (Santillán & Rentería, 2018).

La AP requiere tres etapas:

1. Recolección de datos, realizada con satélites o sensores remotos.
2. Análisis de datos, a cargo de un experto que emite sugerencias para manejar adecuadamente los cultivos.
3. Implementación, el productor cultiva el terreno según las recomendaciones.

Algunas acciones que ayudarían a fomentar la adopción de la AP serían la colaboración entre academia, industria, gobierno y productores; la actualización de la Ley de Desarrollo Rural Sustentable y del Reglamento de la SAGARPA; la investigación y desarrollo agrícola en México; la formación de recursos especializados; la promoción de programas piloto para cultivos estratégicos y su divulgación.

2.1.3 Fertilización agrícola.

La fertilización agrícola, adquiere un papel importante para los cultivos, cuando existe una fertilización al suelo y planta, probablemente el cultivo crecerá mejor y producirá mayores rendimientos. Pero si no existe una fertilización y el suelo carece de nutrientes esenciales, el rendimiento se verá reducido. Ver Figura II-6



Figura II-6. Fertilización agrícola.

Fuente: (Radio Sur, 2022)

La buena fertilización agrícola, es resultado de proveer a los cultivos los nutrientes faltantes, para probablemente mejorar los rendimientos (IFA, 2022). El fertilizante a utilizar en esta

práctica deberá contener cualquier material natural o industrializado, que contenga al menos cinco por ciento de uno o más de los tres nutrientes primarios (N, P2 O5, K2 O).

Tipos de fertilizantes.

Existen gran variedad de fertilizantes que son utilizado por los agricultores, dentro de esta variedad se encuentran los sólidos, gaseosos y líquidos; pero los que más son consumidos llegan a ser solo los sólidos y líquidos.

- **Fertilizante solido o granulado:** Estos se presentan en polvo, granulados, macro granulados, pastillas y etc. Pueden ser aplicados de forma directa o diluidos en agua. La aplicación de estos ofrece una dosificación más precisa liberando los nutrientes que contemplan de forma gradual. Para el cultivo de maíz, en la región de álamo utilizan la urea, bayfolanforte granulado, grofol, super fosfato de calcio triple y sulfato de potasio.
- **Fertilizantes líquidos:** Presentación liquida para aplicación directa o disuelto en agua, son absorbidos con mayor rapidez, su aplicación puede ser antes o después de la siembra. El origen de estos es basado en materiales químicos u orgánicos. Los más utilizados para el maíz en la región de álamo son el bayfolanforte.

2.1.4 Instrumento de recolección de datos.

Entrevista.

“La entrevista es una técnica de recogida de información que además de ser una de las estrategias utilizadas en procesos de investigación, tiene ya un valor en sí misma” (Folgueiras Bertomeu, 2016). De acuerdo con el documento citado con anterioridad la entrevista tiene como principal objetivo obtener información de forma oral y personalizada sobre acontecimientos, experiencias, opiniones de personas. Siempre, participan como mínimo dos personas. Una de ellas adopta el rol de entrevistadora y la otra el de entrevistada, generándose entre ambas una interacción en torno a una temática de estudio.

Tipos de entrevistas.

Entrevista estructurada.

- El investigador planifica previamente las preguntas que se quieren formular. Se prepara las preguntas las cuales irán coordinadas por un guion de forma secuenciada y dirigida.
- El entrevistador no deberá interrumpir la entrevista o hacer algún tipo de comentario. Las preguntas serán de tipo cerrado, solo se podrán afirmar, negar o responder concreta y exactamente sobre lo preguntado.

Entrevista no estructurada o abierta.

- No es necesario establecer un guion previo a la entrevista. La información que se genere de la entrevista será el resultado de la construcción simultánea entre el entrevistador y entrevistados, a partir de las respuestas obtenidas.
- Ahora bien, si es necesaria una gran documentación y preparación por parte del entrevistador. Debe preparar las estrategias que le permitan reconducir la entrevista cuando el entrevistado se desvía del tema propuesto.

Entrevista semiestructurada.

- Se decide la información que se obtendrá, y del mismo modo se establece un guion de preguntas. Pero se puede cuestionar de forma más abierta, permitiendo recoger información más rica y con más matrices que la entrevista estructurada.
- En el transcurso de la entrevista se relacionarán temas y se construirá un conocimiento generalista y compresivo de la realidad del entrevistado.
- El investigador debe prestar total atención en las respuestas del entrevistado para poder relacionarla con los temas y extender dichas conexiones. En caso contrario se perderían los matrices que aporta este tipo de entrevista y frenar los avances de la investigación.

Planificación de la entrevista.

Bisquera, R. (2002) presenta un modelo que secuencia la planificación de la entrevista en tres momentos bien definidos.

1.-Momento de preparación.

- Definir los objetivos de la entrevista: El investigador debe documentar los aspectos a tratar y ser capaz de describirlos en función de los referentes teóricos que considere oportuno para la investigación.
- Identificar las personas que van a ser entrevistadas: Se debe concretar el perfil personal, que ocupara el sujeto dentro del contexto a estudiar y la información que se requiere.
- Formular las preguntas y secuenciarlas: Se debe poner especial atención en la terminología y en el vocabulario que se utilice, que debe resultar significativo y familiar para el interlocutor.
- Localizar y preparar el lugar para entrevistar: Se debe establecer el espacio determinado para llevar a cabo la entrevista, haciendo sentir lo más cómodo a los entrevistados.

2.-Momento de desarrollo.

En este aspecto es determinante no olvidar el objetivo de la entrevista, el cual lógicamente consta que el entrevistado proporcione la información, situaciones y experiencias que él ha pasado o conoce.

- Crear un clima de familiaridad y confianza: El entorno en que se realice la entrevista debe ser cómodo y confortable para el entrevistado.
- Mantener una actitud abierta y positiva que favorezca y facilite la comunicación: La actitud y lenguaje a utilizar, debe ser el adecuado de modo que genere la confianza y apoyo a que la entrevista fluya de manera adecuada.
- Facilitar la comunicación, adoptando una serie de formalismos: Presentarse adecuadamente, iniciar el objetivo y motivo de la entrevista, establecer condiciones de confiabilidad y difusión de la información, puntualizar la duración y numero de encuentros necesarios.

- Llevar a cabo las preguntas de manera estructurada: Una buena estructuración de las preguntas generará un guion adecuado que ayude al entrevistador tanto en la toma de información como en el tratamiento estadístico de la misma.
- Registrar la información de la entrevista: Existen gran variedad para el registro de la información, puede llevarse a cabo mediante medios electrónicos o impresos, de audio o video, El medio a utilizar, será a consideración propia del entrevistador, es ideal que esta elección sea la más conveniente y permita plasmar la información correctamente.

3.-Momento de valoración.

Se centra en el proceso de planificación de la entrevista. Se analiza si ha sido correcta la decisión tomada en torno a la planificación de la entrevista y evaluar el desarrollo de esta. Es importante describir y valorar si la cantidad y calidad de la información es la necesaria. El entrevistador se debe auto preguntar sobre las decisiones que ha tomado, por ejemplo:

- La pertinencia de los objetivos.
- La calidad de las preguntas.
- La calidad de la secuencia de las preguntas.
- El entorno utilizado.
- La duración de la entrevista.
- El tipo de registro utilizado.

Base de datos.

Una base de datos es una herramienta para recopilar y organizar información. Las bases de datos pueden almacenar información sobre personas, productos, pedidos u otras cosas. Muchas bases de datos comienzan como una lista en una hoja de cálculo o en un programa de procesamiento de texto. A medida que la lista aumenta su tamaño, empiezan a aparecer redundancias e inconsistencias en los datos (Microsoft, 2022).

Cualquier base de datos cumplirá las funciones de:

- Organizar gran cantidad de datos para extraer información de relevancia.
- Obtener información de hábitos: compañías como Amazon.com se sirven de las bases de datos de sus clientes para hacerles sugerencias sobre nuevas compras.

- Facilitar la búsqueda y consulta de información: una base de datos de una biblioteca permite buscar un libro o revista de forma más rápida que haciendo uso de un fichero o buscando manualmente.

La elaboración de una base de datos consta de distintos pasos a seguir, de acuerdo a la página oficial de Microsoft el proceso ideal para el diseño de una base de datos es el siguiente:

1. Determinar el propósito de la base de datos.
2. Buscar y organizar la información necesaria.
3. Dividir la información en tablas.
4. Convertir los elementos de información en columnas.
5. Especificar las claves principales.
6. Establecer las relaciones de tablas.
7. Perfeccionar el diseño.

2.1.5 Matlab.

Matlab es un poderosísimo software que combina un entorno de escritorio perfeccionado para el análisis iterativo y los procesos de diseño con un lenguaje de programación que expresa las matemáticas de matrices y arrays directamente. La app permite ver cómo funcionan diferentes algoritmos con los datos importados y realiza iteraciones hasta obtener los resultados deseados y, después, genera automáticamente un programa de MATLAB para reproducir o automatizar su trabajo (The MathWorks, Inc., 1994-2022). Esta herramienta tiene un sinnúmero de funciones, pero principalmente es utilizado:

- Aprendizaje automático.
- Procesamiento de señales
- Procesamiento de imágenes.
- Visión artificial.
- Comunicaciones y finanzas computacionales.
- Diseño de control, robótica y muchos otros campos

Este programa cuenta con una interfaz GUI (también conocidas como interfaces gráficas de usuario o interfaces de usuario) permiten un control sencillo (con uso de ratón) de las

aplicaciones de software, lo cual elimina la necesidad de aprender un lenguaje y escribir comandos a fin de ejecutar una aplicación. El GUI (Graphics User Interface) e MATLAB es el conjunto de herramientas y comandos de bajo nivel que permiten crear y manipular objetos gráficos con el fin de desarrollar aplicaciones “amigables” para el usuario (MATLAB, 2022).

2.1.6 Red neuronal.

Una red neuronal es un método de la inteligencia artificial que enseña a las computadoras a procesar datos de una manera que está inspirada por el cerebro humano, imitando la forma en que las neuronas biológicas se señalan entre sí. A esta red, también se le conocen como redes neuronales artificiales (ANN o RNA) o redes neuronales simuladas (SNN). Las redes neuronales dependen de los datos de entrenamiento para aprender y mejorar su precisión con el tiempo. Sin embargo, una vez que estos algoritmos de aprendizaje se ajustan a la precisión, son potentes herramientas en la ciencia de computación e inteligencia artificial, lo que nos permite clasificar y agrupar los datos a una alta velocidad.

Ventajas de las redes neuronales

Un estudio realizado en el año 2000¹ por Carlos R. y Marta B, referente a las redes neuronales, menciona que las redes neuronales artificiales presentan un gran número de características semejantes a las del cerebro. Esto hace que ofrezcan numerosas ventajas y que este tipo de tecnología se esté aplicando en múltiples áreas. Entre las ventajas se incluyen:

- **Aprendizaje Adaptativo:** Capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.
- **Auto-organización:** Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.
- **Tolerancia a fallos.** La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo un gran daño.
- **Operación en tiempo real:** Los cómputos neuronales pueden ser realizados en paralelo; para esto se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.

- Fácil inserción dentro de la tecnología existente: Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilitará la integración modular en los sistemas existentes.

Composición básica de una red neuronal.

Las redes neuronales constan de tres elementos básicos para su composición, a continuación, en la Figura II-7, se observa el esquema de la red neuronal.




Figura II-7. Elementos básicos de una red neuronal.

Fuente: (Diana, 2014)

La misma está constituida por neuronas interconectadas y arregladas en tres capas (esto último puede variar). Los datos ingresan por medio de la “capa de entrada”, pasan a través de la “capa oculta” y salen por la “capa de salida”. Cabe mencionar que la capa oculta puede estar constituida por varias capas. La distribución de neuronas dentro de la red se realiza formando niveles o capas, con un número determinado de dichas neuronas en cada una de ellas. A partir de su situación dentro de la red, se pueden distinguir tres tipos de capas:

- De entrada: es la capa que recibe directamente la información proveniente de las fuentes externas de la red.
- Ocultas: son internas a la red y no tienen contacto directo con el entorno exterior. El número de niveles ocultos puede estar entre cero y un número elevado. Las neuronas de las capas ocultas pueden estar interconectadas de distintas maneras, lo que determina, junto con su número, las distintas topologías de redes neuronales.
- De salidas: transfieren información de la red hacia el exterior.

Arquitectura de una red neuronal.

Las RNA o ANN, están organizadas en función de:

- Numero de niveles o capas.
- Numero de neuronas por nivel.
- Patrones de conexión.
- Flujo de información.

La distribución de neuronas dentro de la red se realiza formando niveles o capas de un número determinado de neuronas cada una (Reyes & Cisneros, 2014). Cada neurona de la red es una unidad de procesamiento de información., es decir, recibe información a través de las conexiones con las neuronas de la capa anterior, procesa la información y emite el resultado a través de sus conexiones con las neuronas de la capa siguiente, y cuando dicho resultado supere un valor “umbral”. En una red neuronal ya entrenada, las conexiones entre neuronas tienen un determinado peso (peso, sinóptico). En una red neuronal artificial los nodos se conectan por medio de sinapsis, estando el comportamiento de la red determinado por la estructura de conexión sináptica. Estas conexiones sinápticas son direccionales, es decir, la información solamente puede propagarse en un único sentido (desde la neurona presináptica a la post-sináptica). En general las neuronas se suelen agrupar en unidades estructurales que se denominan caps. El conjunto de una o más capas constituye a la red neuronal (González, 2016).

Red Feed-Forward backpropagation.

Una red neuronal feedforward es un algoritmo de clasificación inspirado biológicamente. Consiste en un número (posiblemente grande) de unidades de procesamiento similares a neuronas simples, organizadas en capas. Cada unidad en una capa está conectada con todas las unidades en la capa anterior. Estas conexiones no son todas iguales: cada conexión puede tener una fuerza o peso diferente. Los pesos de estas conexiones codifican el conocimiento de una red. A menudo, las unidades de una red neuronal también se denominan nodos. Los datos entran por las entradas y pasan por la red, capa por capa, hasta llegar a las salidas. Durante el funcionamiento normal, es decir cuando

actúa como clasificador, no hay retroalimentación entre capas. Por eso se les llama redes neuronales feedforward.

El nombre de backpropagation resulta de la forma en que el error es propagado hacia atrás a través de la red neuronal, en otras palabras, el error se propaga hacia atrás desde la capa de salida. Esto permite que los pesos sobre las conexiones de las neuronas ubicadas en las capas ocultas cambien durante el entrenamiento. El cambio de los pesos en las conexiones de las neuronas además de influir sobre la entrada global influye en la activación y por consiguiente en la salida de una neurona. Por lo tanto, es de gran utilidad considerar las variaciones de la función activación al modificarse el valor de los pesos. Esto se llama sensibilidad de la función activación, de acuerdo al cambio en los pesos (Matich, 2001)

2.1.7 Normalización de datos.

La página oficial de Microsoft define a la normalización como el proceso de organizar los datos de una base de datos. Se incluye la creación de tablas y el establecimiento de relaciones entre ellas según reglas diseñadas tanto para proteger los datos como para hacer que la base de datos sea más flexible al eliminar la redundancia y las dependencias incoherentes. Scielo define que la normalización es esencial para asegurar que los datos sigan padrones, sean consistentes entre los diferentes artículos y revistas de modo de asegurar su funcionalidad e interoperabilidad con los sistemas de información (Scielo, 2017).

2.1.8 Análisis de residuales.

El analizar los residuos, es una parte importante que nos sirve para determinar si realmente se cumple la premisa de linealidad de las relaciones y normalidad de los valores. A través de un análisis y el uso de gráficas, se puede determinar si hay coherencia o incoherencia en nuestros resultados.

Gráfico de dispersión.

Galton describió el proceso de construcción de un diagrama de dispersión en un artículo de 1890. Un gráfico de control es definido de distintas maneras, el documento llamado correlación y regresión lineal, publicado por Clara Laguna menciona que el diagrama de

dispersión o nube de puntos permite obtener información sobre el tipo de relación existente entre X y Y, ayudando a detectar posibles valores atípicos o extremos (Lagunas, 2014). Las técnicas de correlación y las de regresión están estrechamente relacionadas, aunque obedecen a estrategias de análisis un tanto diferentes. El coeficiente de correlación determina el grado de asociación lineal entre X e Y, sin establecer a priori ninguna direccionalidad en la relación entre ambas variables. La finalidad de la correlación es examinar la dirección y la fuerza de la asociación entre dos variables cuantitativas. Así conoceremos la intensidad de la relación entre ellas y si, al aumentar el valor de una variable, aumenta o disminuye el valor de la otra variable.

Tipos de relaciones.

Cuando se realiza el gráfico del diagrama de dispersión pueden presentarse diferentes relaciones, comportamientos o tendencias de los datos. Existen diferente relación que pueden presentar el grafico, ver Figura II-8.

- Relación positiva fuerte: Los datos se agrupan formando una clara tendencia en la que entre a mayor valor de la variable x, mayores serán los valores de la variable independiente y. Es de destacar que la dispersión de los datos es baja.
- Relación negativa fuerte: los datos se agrupan formando una clara tendencia en la que entre a mayor valor de la variable x, menores serán los valores de la variable independiente y. Es de destacar que la dispersión de los datos es baja.
- Ninguna relación: los datos no se agrupan y por ende no forman ningún tipo de tendencia. Es de destacar que la dispersión de los datos es alta.




Figura II-8. Tipos de correlaciones.

Fuente: (Math Net, 2022)

Coeficiente de determinación, R^2 .

Este coeficiente nos indica el grado de ajuste de la recta de regresión a los valores de la muestra, y se define como el porcentaje de la variabilidad total de la variable dependiente Y que es explicada por la recta de regresión. Cuanto menos disperso sean los residuos (recordad que los residuos o errores son la diferencia entre los valores observados y los valores estimados por la recta de regresión), mejor será la bondad del ajuste

Las características de este coeficiente son:

- R^2 es una cantidad adimensional que sólo puede tomar valores en $[0, 1]$
- Cuando un ajuste es bueno, R^2 será cercano a uno (mayor será la fuerza de asociación entre ambas variables)
- Cuando un ajuste es malo, R^2 será cercano a cero (la recta no explica nada, no existe asociación entre X e Y).

CAPITULO III . ESTADO DEL ARTE

3.1 Trabajos relacionados

A continuación, se presenta una revisión del estado del arte relacionado con el uso de redes neuronales para la resolución de problemas en la agricultura.

Yang, (2000), desarrollo modelos de redes neuronales (ANN) usando un algoritmo backpropagation con diferentes números de PEs en sus capas ocultas y de salida, para clasificar imágenes tomadas desde el campo y detectar la presencia de malas hierbas en el maíz. Este modelo concluyó como un sistema de reconocimiento de maleza basado en la red neuronal artificial, con una tasa de éxito del 80 a 100% para identificación del maíz y para la maleza un 60 a 80%.

Arriaga, (2015), presento la introducción de diferentes herramientas y modelos que permitan una gestión más eficiente y sostenible de los recursos hídricos en la zona del estudio, no

saturada del suelo en sus componentes espacial, mediante el uso de redes neuronales artificiales (RNA) como herramienta en ensayos de calibración de sensores, generando como resultado que las RNA, son útil para la calibración de sensores, mejorando la calibración de los sensores 10HS y 5TE, y EC20 con respecto a una calibración basado en ajuste por polinomios cúbicos para el maíz.

Pérez, Figueroa, Godínez y Pérez, (2019), desarrollaron dos redes neuronales (perceptrón multicapa) utilizando el algoritmo de retropropagación de errores, para analizar el impacto del precio nacional de otros productos y del precio internacional del maíz sobre el comportamiento del precio, se obtuvieron resultados muy aproximados a la realidad, así como su capacidad para ponderar el impacto de otras variables de precios tanto de productos relacionados como de precios internacionales, dicha información es considerada importante para la toma de decisiones en el ámbito de políticas públicas encaminadas.

Toapanta, (2019), estudió el rendimiento por hectárea de maíz duro seco mediante regresión lineal múltiple y redes neuronales perceptrón multicapa (MLP) con una sola capa oculta, con n de nodos, usando el algoritmo backpropagation y resilient-propagation, las conclusiones generadas en este estudio describen que el modelo RLM creado, brinda las variables que tienen una mayor incidencia en el rendimiento de maíz por ha, las cuales son la fertilización y la posición geográfica. Mientras que los modelos creados a partir de redes neuronales se ajustan a relaciones lineales obteniendo una mejor opción al momento de modelar el rendimiento del maíz.

Zerecedo, (2017), diseñó dos modelos de redes neuronales artificiales (RNA), usando la red neuronal de tipo estática (perceptrón multicapa), con el principal objetivo de predecir los precios nacionales del maíz usando datos de 1980-2014. Como resultados de este estudio, se pudo corroborar la utilidad de los modelos de redes neuronales artificiales para la predicción de precios reales a futuro, así como la capacidad para ponderar el impacto de otras variables de precio para productos relacionados, siendo de gran importancia para el proceso de toma de decisión dentro del ámbito de las políticas públicas encaminadas al apoyo de los productores agrícolas nacionales.

Gaitan, Hsieh y Canon (2014), llevaron a cabo un estudio para pronosticar el rendimiento de maíz en la provincia china de 1962 a 2004, contando como variables el clima, fertilizantes y el dato de años pasados. Se usó de la regresión lineal múltiple (MLR) y modelos de redes artificiales no lineales (ANN), con un algoritmo de aprendizaje bayesiano de Foresse Hagan. Se obtuvo de resultado que ANN era significativamente superior al MLR, y como los datos no eran estacionarios, se encontró que la validación cruzada era menos confiable que validación retroactiva en la evaluación de habilidad de pronósticos.

Pokraj y Obradovix. (2001), en su estudio con objetivo de proporcionar una herramienta para optimizar ganancias agrícolas, a través de la aplicación de fertilizantes específicos en nutrientes, mediante el uso de técnicas de optimización no lineal basada en redes neuronales. Los resultados experimentales preliminares sugieren que la técnica propuesta tiene un alto potencial para aumentar significativamente la ganancia financiera y reducir sustancialmente las tasas promedio de fertilización en comparación con la fertilización uniforme realizada tradicionalmente y la aplicación de modelos de regresión lineal.

Helong, Dayou, Guifen, (2010), propone una red neuronal, tomando como datos de entrada el nivel de nutrientes del suelo y la tasa de fertilización, el rendimiento se toma como salida del modelo. Se transformó el cálculo de la tasa de fertilización en la resolución de un problema de programación y se puede utilizar para así calcular la tasa de fertilización con el mejor rendimiento y el máximo beneficio, así como para pronosticar el rendimiento. La red está estructurada por 7 neuronas en la capa oculta con el algoritmo Backpropagation.

Yuhong y otros (2019), elaboraron una red neuronal, que resulto tener una mayor predicción de la tendencia de rendimiento de los cultivos como resultado del cambio en la cantidad de fertilizante. Se consideraron, 6 variables que influyen en el rendimiento de cultivos N, P y K en el suelo y entrada de fertilizantes N, P y K. Los pesos se determinaron iterativamente y el valor inicial es aleatorio en la red neuronal BP. En el proceso de realización, las muestras se dividieron automáticamente en tres partes a través de Matlab: capacitación, validación y prueba. Se ha demostrado que la red neuronal wavelet-BP establecida combina el análisis

wavelet multi-resolución con la potente aproximación no lineal de redes neuronales, consiguiendo una resolución adaptativa con una buena tolerancia a fallos y predecir efectivamente la tendencia del rendimiento de los cultivos como resultado del cambio en la cantidad de fertilizante.

Lykhovyd (2018), en su estudio determino si las redes neuronales artificiales son más precisas que la regresión lineal en la predicción del rendimiento del maíz dulce. Utilizaron un conjunto de datos obtenidos de experimentos de campo sobre la mejora tecnológica del cultivo de maíz dulce. Los experimentos de campo se llevaron a cabo durante el período de 2014 a 2016, también se estudió el impacto de las profundidades de arado de la vertedera, las tasas de aplicación de fertilizantes minerales y las densidades de plantas en el rendimiento. La predicción mostro un mejor resultado con las redes neuronales artificiales con un coeficiente de determinación del 0.978 con una predicción del rendimiento de 10.93 t ha⁻¹ bajo un arado de vertedera a una profundidad de 20-22 cm.

Singh (2008), propuso una red neuronal artificial multicapa feedforward utilizando dos algoritmos de aprendizaje el algoritmo de descenso gradiente (GDA) y el algoritmo de descenso de gradiente conjugado (GCDA), para modelado y pronostico del rendimiento de maíz. Como resultado se destacado el potencial de la metodología de redes neuronales artificiales para abordar con éxito la situación realista en la que no se conoce la relación funcional no lineal exacta entre la variable de respuesta y un conjunto de predictores.

Dong y otros (2020), propusieron un método para la fertilización de precisión de maíz basado en la red neuronal wavelet-BP, tomando datos experimentales existentes. Este estudio proporciono una nueva técnica para la investigación de fertilización de precisión, además que generó una guía práctica para el aumento de la producción del maíz, al tiempo que reduce de producción y la contaminación agrícola. Al mismo tiempo, también proporciono una forma de resolver problemas similares en todo el campo de la producción.

Liu J, CE Goering, Tian L. (2001), crearon una ANN de retropropagación, completamente conectada y con alimentación hacia adelante para aproximar la función de rendimiento no

lineal que relaciona el rendimiento del maíz con los factores que influyen en el rendimiento, mediante un muestreo estratificado basado en la lluvia y los factores que afectan el rendimiento de los cultivos. Como resultados se obtuvo que los factores que influyeron incluyeron factores del suelo, factores climáticos y factores de manejo; además la red neuronal de retropropagación y avance predijo los rendimientos de maíz con un 80 % de precisión

Álvarez R., Steinbach H. (2011). Desarrollaron modelos adecuados para predecir la mineralización de N durante las estaciones de crecimiento de trigo y maíz, en condiciones de campo. Se probaron dos técnicas de modelado empírico, regresión lineal y redes neuronales artificiales, utilizando como variables independientes o entradas algunas variables ambientales. Ambas técnicas permitieron el desarrollo de modelos adecuados para la predicción de mineralización de N ($R^2 > 0,68$), pero las redes neuronales dieron resultados ligeramente mejores. La metodología desarrollada para la estimación de la mineralización aparente de N puede ser aplicada a otros cultivos y regiones de producción.

Miao, Y., Mulla, DJ y Robert, PC (2006). Emplearon, el análisis de redes neuronales artificiales (ANN) para evaluar la importancia relativa de los factores híbridos seleccionados del suelo, el paisaje y las semillas en el rendimiento y la calidad del grano en dos campos de Illinois, EE. UU. Se identificaron alrededor de 7 a 13 factores importantes que podrían explicar del 61% al 99% del rendimiento observado o la variabilidad de la calidad en los años-sitio de estudio. Se encontró que el híbrido era el factor general más importante para la calidad en ambos campos y también para el rendimiento en el Campo 1. Se concluyó, que el híbrido fue más importante que los factores del suelo y del paisaje para ser considerados en el manejo de cultivos de precisión, especialmente cuando la calidad del grano era un objetivo de manejo.

Farjam, A., Omid, M., Akram, A. y Fazel Niari, Z. (2014). Desarrollaron y probaron varias ANN de perceptrón multicapa con seis neuronas en la capa de entrada y de una a tres capas ocultas con diferente número de neuronas en cada capa y una neurona (rendimiento de semilla o grano de maíz) en la capa de salida, para estimar los rendimientos de semillas y

granos de maíz en Parsabad Moghan, Irán. El mejor modelo para predecir los rendimientos de semillas y granos de maíz tenía topologías 6-4-8-1 y 6-3-9-1, respectivamente. El valor de salida del modelo asociado con la salida real tenía valores de coeficiente de determinación (R^2) de 0,9998 y 0,9978 para semilla y grano de maíz, respectivamente. El análisis de sensibilidad mostró que, en la producción de maíz de siembra, el gasóleo y la maquinaria, y en el maíz grano, el consumo de gasóleo y semillas tienen el mayor efecto sobre el rendimiento de la producción.

Wang, F.L., Dong, C.G., Wu, C.F., & Fang, K.K. (2017). Propusieron un modelo básico basado en el método de optimización de la red neuronal de BP. Tomando como objeto de investigación los cultivos de maíz, seleccionando como factores experimentales la densidad de siembra, la tasa de aplicación de nitrógeno, la tasa de aplicación de fósforo y la tasa de aplicación de potasio, el rendimiento del maíz. Concluyeron que el método de optimización tiene una precisión de función de ajuste alto, los resultados de optimización son precisos y proporciona un método confiable para resolver problemas de optimización similares en el campo de la producción agrícola.

Yu y otros (2010). Propusieron un nuevo método de conjunto de redes neuronales, para calcular la tasa de fertilización con mayor precisión de maíz, En este modelo, el nivel de nutrientes del suelo y la tasa de fertilización se toman como entradas de la red neuronal y el rendimiento se toma como salida. Para el modelo, se transformó el cálculo de la tasa de fertilización en la resolución de un problema de programación y se utilizó para calcular la tasa de fertilización con el máximo rendimiento y beneficio, así como para pronosticar el rendimiento. El modelo de fertilización construido en este documento no solo puede simular con precisión la relación no lineal entre el rendimiento y el nivel de nutrientes del suelo, sino que también puede hacer un uso adecuado de los datos existentes sobre el efecto de los fertilizantes.

Adisa, OM y otros (2019). En su estudio, utilizaron modelos de redes neuronales artificiales (ANN) para predecir el maíz en las principales provincias productoras de maíz de Sudáfrica. El análisis de predicción y proyección de la producción de maíz se realizó utilizando

variables climáticas y la tierra cultivada. Como resultado se obtuvo que la precipitación, evaporación transpiración, temperatura mínima y máxima; tierra cultivada y húmedas del suelo fueron la mejor combinación para predecir la producción de maíz. Además, que el modelo desarrollado puede ayudar a mejorar el proceso de toma de decisiones de los agricultores y los encargados de formular políticas.

3.2 Discusión.

Se llevo a cabo una ardua investigación, para analizar y conocer que estudios similares se han realizado con anterioridad sobre la fertilización y rendimiento del maíz, a través del uso de redes neuronales. La Tabla III-1, presenta los estudios indagados, donde se puede visualizar los autores, los datos que se tomaron en cuenta en el estudio, el método utilizado, la contribución que apporto y sobre que cultivo fue manejada.

Tabla III-1.Discusión.

Autor	Datos considerados	Métodos utilizados	Contribución	Cultivo
<i>(Yang, 2000)</i>	Imágenes del campo.	ANN-BP.	Maleza.	Maíz.
<i>(Arriaga, 2015)</i>	Calibración.	RNA.	Calibración de sensores.	Maíz.
<i>(Pérez Soto, Figueroa Hernández, Godínez Montoya, & Pérez</i>	Precio interno del maíz	RNA	Precio de nacional del maíz y similares.	Maíz y similares.

<i>Figueroa, 2019)</i>				
<i>(Toapanta, 2019).</i>	Temperatura promedio, precipitación, fertilización, variedad/hibrida, y superficie sembrada.	MLPANN.	Variables de impacto. Rendimiento.	Maíz.
<i>(Zerecero, 2017)</i>	Precios nacionales e internacionales.	MLPANN	Precio.	Maíz.
<i>(Gaitan, Hsieh, & Cannon, 2014).</i>	Condiciones climáticas y fertilización	MLR ANN-B	Rendimiento	Maíz
<i>(Pokrajac & Obradovic, 2001)</i>	Rendimiento y características de los cultivos.	MLPANN RBF OLS	Fertilización. Ganancias.	Agricultura en general.
<i>(Helong, Dayou, & Guifen, 2010)</i>	Nutrientes y fertilización.	RNA-BP	Rendimiento.	Cultivos en general.

<i>(Yuhong, y otros, 2019)</i>	NPK	RNA-BP	Rendimiento	Cultivos en general
<i>(Lykhovyd, 2018).</i>	Profundidades de arado, Tasas de fertilización y densidad.	RNA RL	Rendimiento	Cultivos en general
<i>(Singh, 2008)</i>	Rendimiento, fertilización, pesticidas y trabajo humano.	MLFNANN	Rendimiento.	Maíz.
<i>(Dong, y otros, 2020)</i>	Datos existentes en la zoma.	RNA W-BP	Fertilización de precisión.	Maíz.
<i>(Liu, Goering, & Tian, 2001)</i>	Clima, suelo, temperatura, lluvia, pH y manejo	RNA-BP	Rendimiento. Factores influyentes.	Maíz
<i>(Álvarez & Steinbach, 2011)</i>	Clima, suelo y condiciones de manejo.	RL RNA-BP	Mineralización de Nitrógeno (N)	Maíz y trigo.
<i>(Miao, Mulla, &</i>	Variables generadas en 2 campos diferentes.	MLPANN- BP	Calidad. Factores influyentes. Rendimiento.	Maíz.

<i>Robert, 2006)</i>				
<i>(Farjam, Omid, Akram, & Fazel Niari, 2014)</i>	Mano de obra, maquinaria, combustible diésel, fertilizantes, productos químicos y semilla.	MLPANN- LM	Rendimiento.	Maíz.
<i>(Wang , Dong , Wu, & Fang, 2017)</i>	Factores genéticos y ambientales.	RNA-BP	Fertilizantes. Densidad.	Maíz.
<i>(Yu, y otros, 2010)</i>	Nutrientes del suelo, rendimiento objetivo, tasas de fertilización.	RNA-BP	Fertilización. Rendimiento.	Maíz.
<i>(Adisa, y otros, 2019)</i>	Variables climáticas y tierra cultivada.	MLPANN- BP	Producción.	Maíz.
<i>Propuesta actual.</i>	Variables, físicas, químicas, plagas, climatológicas y rendimiento.	RNA BP	NPK Rendimiento esperado.	Maíz

Abreviaturas de la tabla 2: ANN y RNA, red neuronal artificial, BP, backpropagation, B, bayesiano, RP, resilient-propagation, LM, Levenberg-Marquardt, GAN, generativa antagónica, RBF, red de función de base radial, RG, regresión generalizada, CNN, red neuronal convolucional. MLPANN, red neuronal artificial perceptrón multicapa, MLR, regresión lineal múltiple. RL, regresión lineal, OLS, mínimos cuadrados ordinarios, MLFNANN, red neuronal artificial multicapa feedforward, RNA W-BP, red neuronal wavelet-backpropagation.

Fuente: Elaboración propia.

Los estudios mencionados en el estado del arte refieren maneras en que se puede abordar el problema de interés. Dentro de los estudios redactados, los más destacables por su aporte y similitud al presente por la elaboración de modelos a base de RNA BP (Red neuronal backpropagation), MLPANN (Red neuronal artificial perceptrón multicapa), MLR (Regresión lineal múltiple) para la predicción de valores cercanos de fertilización NPK y el rendimiento esperado para el maíz. El estudio presente, se ha limitado al uso de redes neuronales backpropagation (RNA BP), con la finalidad de establecer dos modelos capaces de lograr predecir las dosis de fertilización NPK y rendimiento esperado, para la toma de decisión en el cultivo de maíz. En la mayoría de los estudios redactados, manejan el uso de las redes neuronales y la regresión lineal múltiples; y las variables que se llegan a considerar en trabajos como el de Mia y otros (2008); Toapanta (2019) ; Yu y otros (2010) ; son referentes a las condiciones climáticas, fertilizantes, rendimiento y la disponibilidad de macronutrientes NPK en el suelo del terreno tomado como muestra, pero esta información es basada en datos recolectados, años anteriores por lo que realizar estimaciones en tiempo presente se ve mermado por la información. A diferencia de lo anterior, el presente documento conlleva consigo el uso de más variables no solo climatológicas, de fertilizantes y rendimiento; si no también se anexaron plagas y condiciones físicas del terreno, todo ello para el buen entrenamiento de la red neuronal; además los datos presentados se extrajeron en año actual, a modo de que la predicción se aproximara lo más real posible. Los autores Gaitan y otros, manejaron un algoritmo de aprendizaje de la red bayesiano de foresse y hagan, a su vez los datos utilizados también eran de años anteriores. A comparación del modelo creado para este trabajo, se optó por un algoritmo de aprendizaje levenberg-marquardt, esta decisión fue tomado debido a que la cantidad de datos totales extraídos fue de menor escala, más sin embargo se logró manejar un mayor número de variables al contar con un total de 23

variables, que fueron intercaladas para tomar como salida NPK y rendimiento esperado. En general esta investigación es una propuesta que ayuda a estimar las dosis de fertilizante NPK (Nitrógeno, Fosforo y Potasio) y el rendimiento esperado, tomando en cuenta aquellos factores más influyentes en el terreno del agricultor, para poder tomar una decisión si es conveniente fertilizar el terreno, a modo de adquirir un beneficio; dejando esta última decisión al agricultor encargado, dejándole ver los posibles escenarios que llegase a tener con las predicciones generadas a través de las redes neuronales elaboradas .

CAPITULO IV . DESARROLLO

4.1 Metodología.

La metodología planteada en este estudio consta de 7 fases principales. Cada una lleva al objetivo de la investigación siempre y cuando su desarrollo sea el correcto. Ver Figura IV-1




Figura IV-1. Metodología a implementar.

Fuente: Elaboración propia.

Cada fase de la metodología consta de ciertos pasos realizados. Primero, se comenzó con el estado del arte para obtener información de estudios relacionados o con alguna similitud al

presente, prosiguiendo con la delimitación del problema en donde se estableció un límite referente a la problemática establecida. La recolección y análisis de información, es un punto participe donde se recogió la información necesaria para posteriormente proceder a la creación y configuración de dos redes neuronales, las cuales se entrenaron con los datos analizados con anterioridad, de tal manera que se generen diferentes resultados y validarlos, verificando el buen funcionamiento de estas, para así llegar a la última fase discusión y conclusión. El siguiente apartado se desglosará más a detalle, los procesos realizados en cada fase propuesta para esta metodología.

4.2 Delimitación del problema.

La región de Álamo Temapache cuenta con una superficie continental de 1,279 km² de la cual, aproximadamente 730.4 km² son ocupados para la agricultura, de acuerdo con los cuadernillos municipales de la región. La región se enfoca más en el cultivo de los cítricos, sin embargo, por el extenso territorio para la práctica, podría dar un poco más de enfoque al maíz, al considerar la importancia que va tomando este grano en el mundo. Los agricultores de la zona dedicados al maíz muchas veces no conocen las deficiencias y variables, existentes en los cultivos como lo son factores físicos, químicos, climatológicos y de plagas; que se presentan en los cultivos e influyen en el rendimiento. La Figura IV-2, muestra las características más influyentes para la agricultura del maíz.




Figura IV-2.Limitaciones en el cultivo de maíz.

Fuente: Elaboración propia.

Dentro de la investigación surge la incógnita, sobre conocer las dosis de fertilizante basada en nitrógeno(N), fosforo (P) y potasio (K) que son suministradas por los agricultores al cultivo, como punto de apoyo para genera un mejor rendimiento del grano. Esa duda va más allá de solo conocer las cantidades aplicadas, sino también de saber objetivamente que dosis de NPK, son correctas utilizar para que, junto con los demás factores, se obtenga un rendimiento favorable. Por ello la determinación clara de las cantidades requeridas para cada suelo, atrae el conocimiento previo para decidir si aplicar o no, fertilizantes basados en nutrientes indispensables, y a su vez el rendimiento que se espera puede evaluarse mediante todas las variables existentes.

4.3 Recolección y análisis de la información.

Mediante el análisis de las diferentes herramientas para la obtención de información, se estableció que, en la investigación, se utilizara una entrevista semi estructurada. Esta herramienta elegida, es un medio amplio que permite obtener y elaborar datos de modo rápido y eficaz (Casas, Repullo, & Donado, 2003), además se utilizaron otras fuentes confiables para recabar información faltante que la entrevista no recolectara.

Objetivo de la entrevista y definición de las variables.

El objetivo principal de la entrevista es, determinar aquellos factores físicos, químicos, climatológicos y las plagas; que influyen en el cultivo de maíz. Las variables para el estudio se presentan en la Tabla IV-1 , cada variable se adquirió mediante la entrevista y la investigación, para su posterior análisis.

Tabla IV-1. Variables de la investigación.

Variable.	Medición.	Concepto.	Tipo de variable.	Intervalo – clasificación.
Zona.	Ubicación geográfica	Superficie acotada, que se distingue de lo que la rodea.	Cualitativa.	1.Ojite, 2. Dr Montes de Oca, 3. Temapache, 4. Km 33 Paso Real, 5. Potrero del llano, 6. San Miguel. 7. Xuchitl.

Plagas.	Plagas comunes.	Bicho, insecto u organismo no deseado, que pueda perjudicar un cultivo.	Cualitativa y binaria.	1.Papalotilla,2. Hormiga arriera, 3. Gusano cogollero, 4. Gusano medidor.
Temperatura anual.	C°	Promedio de las temperaturas de todo el año en un lugar determinado.	Cuantitativa.	0 a 28.083
Precipitación total al año.	mm	Valor determinado por el promedio de las lluvias registradas en los 12 meses del año.	Cuantitativa.	0 a 1374.4
Radiación solar.	Hrs/años	Energía emitida por el Sol a través de ondas electromagnéticas.	Cuantitativa.	0 a 157.4
Índice de severidad de sequía.	Clasificación.	Consideración del aumento de las sequias en años recientes de acuerdo a los encuestados.	Cualitativa.	1. Muy fuerte 2.Moderado 3. Leve
Pendiente.	%	Grado de inclinación del terreno.	Cuantitativo	0 a 13.16
Altitud.	msnm	Distancia vertical de un punto de la tierra respecto al nivel del mar.	Cuantitativo	0 a 268

Drenaje interno.	Clasificación.	Propiedad del subsuelo para evacuar correctamente, el agua absorbida generada por la saturación de líquido.	Cualitativa.	1.Bueno, 2.Moderado, 3. Malo.
Drenaje externo.	Clasificación.	Propiedad del suelo externo para drenar agua adquirida por medio de lluvia u otro medio.	Cualitativa.	1.Bueno, 2.Moderado, 3. Malo.
Profundidad.	cm.	Espacio en el que las raíces de las plantas pueden penetrar sin mayores obstáculos, con vistas a conseguir el agua y los nutrimentos indispensables.	Cuantitativa.	0 a 20
Textura del suelo.	Clasificación.	Definición del tipo de suelo contenido en la mayor parte del terreno.	Cualitativa.	1.Franco arcillosa, 2.Arcillosa, 3.Franco arenosa

Ph.	Clasificación.	Propiedad química que indica que tan ácida o alcalina es la solución del suelo, que es de donde las raíces y los microorganismos del suelo toman sus nutrientes (Osorio, 2012).	Cuantitativa.	0 al 7.9
Nitrógeno (N).	(Kg/ha)	Macronutriente esencial que ayuda al crecimiento y desarrollo de las plantas. (Cárdenas Navarro, Sánchez Yáñez, Farías Rodríguez, & PeñaCabriales)	Cuantitativa.	0 a 32.46584
Fosforo (P).	(Kg/ha)	Macronutriente esencial para la fotosíntesis y transferencias de energía.	Cuantitativa.	0 a 18.676
Potasio (K).	(Kg/ha)	Macronutriente vital en el crecimiento de las plantas (Larriva, 2003)	Cuantitativa.	0 a 20.42
Azufre (S).	(Kg/ha)	Elemento que evita que las plantas se deshidraten por calor o sequías.	Cuantitativa.	0 a 4.60256

Calcio (Ca).	(Kg/ha)	Elemento responsable de crear y mantener la estructura de los suelos agrícolas (Revista agroprecuaria, 2017).	Cuantitativa.	0 a 1.0054
Rendimiento esperado	(Ton/ha)	Se define como la cantidad de producto, que se espera producir en una hectárea de cultivo.	Cuantitativa.	0 a 4

Fuente: Elaboración propia.

Se tomaron a consideración un total de 22 variables y cada pregunta estructurada, tuvo la finalidad de obtener la información para determine los factores más influyentes presentes en cada terreno. Como criterio de elección para las preguntas se evaluó que medio, es el más viable para adquirir la información (internet, entrevista o alguna aplicación), ya que algunos factores se pueden conocer mediante fuentes de información confiable, ver Tabla IV-2.

Tabla IV-2. Medio de obtención de la información.

Factores.	Tipo.	Medio de obtención.
Zona.	Físico.	Entrevista y Google Eart Pro.
Plagas.	Plagas.	Entrevista.
Temperatura anual (°C).	Climatológico.	Weather Spark.com
Precipitación total al año (mm).	Climatológico.	Weather Spark.com
Radiación solar (hrs/año).	Climatológico.	Weather Spark.com
Índice de severidad de sequía.	Climatológico.	Entrevista.
Pendiente (%).	Físico.	Entrevista y Google Earth Pro.
Altitud (msm).	Físico.	Google Earth Pro.

Drenaje externo.	Físico.	Entrevista.
Drenaje interno.	Físico.	Entrevista.
Profundidad (cm).	Físico.	Entrevista.
Textura.	Físico.	Entrevista.
Ph.	Químico.	Ciencias agroindustriales y Entrevista.
Fertilizantes usados en el cultivo.	Químico.	Entrevista y Fichas técnicas.
Rendimiento esperado.	Rendimiento.	Entrevista

Fuente: Elaboración propia.

4.3.1 Entrevista y prueba piloto.

Mediante el medio para obtener la información, se delimito el tipo de preguntas a usar en la entrevista y finalmente crearla. La entrevista formulada a través de los criterios establecidos anteriormente, consto de un total de 24 preguntas, algunas cerradas y otras abiertas. Cada pregunta se planteó a modo, que los agricultores entendieran el concepto y finalidad; quedando de la siguiente manera:

Instituto Tecnológico Superior de Álamo Temapache – Campo agrícola

“Inventarió de datos del cultivo de maíz”

“PROPIEDADES FÍSICAS Y CLIMATOLÓGICAS.”

1) De acuerdo a las temporadas de lluvia, riego del terreno y etc. ¿Cómo considera que es el drenaje externo del suelo?

a) Bueno

b) Moderado

c) Malo

2) Y ¿el drenaje interno del suelo?

Bueno

b) Moderado

c) Malo

3) ¿Cómo considere el índice de sequía del terreno en estos últimos años?

a) Leve

b) Moderada

c) Muy fuerte

4) ¿Que profundidad llega a tener la raíz del maíz, con base a su experiencia?

5) ¿Cómo definiría la textura que tiene el suelo de su terreno?

a) Franco arcilloso

b) Arcilloso

c) Franco arenoso.

6) ¿Qué niveles de pH presentan sus suelos?

7) ¿Aproximadamente con cuantas hectáreas cuenta para la siembra de maíz?

“PROPIEDADES QUÍMICAS Y PLAGAS.”

1) Utiliza algún tipo de fertilizante en el terreno; para un mayor desarrollo de los cultivos agrícolas. *Si su respuesta es sí*, explique qué tipo de fertilizante utiliza:

2) ¿Aproximadamente cuál es el precio del fertilizante que utiliza?

3) ¿Cada cuánto tiempo y en qué cantidad (Costal / hectárea, kilos /hectárea o etc.); aplica fertilizante en el terreno?

4) ¿El fertilizante es aplicado manualmente, con alguna maquina o herramienta? ¿Si se aplica con máquina, cuantos litros por hectárea consume de combustible la maquina?

5) ¿Cuenta con sistema de riego? *Si su respuesta es sí*. ¿Cuántos litros ocupa para ese sistema de riego y cada cuanto es aplicable?

6) ¿Actualmente tiene un control de nutrientes de los cultivos?

7) Aplica algún control contra plagas. *Si la respuesta es sí*. ¿Qué plaguicidas o pesticidas usa, en qué cantidad y cada cuánto tiempo?

8) Además de los plaguicidas. ¿Utiliza algún otro agroquímico (por ejemplo: rodenticidas, ¿herbicidas o etc.)?

9) ¿Qué tipo de plagas son comunes en su cultivo?

10) ¿Utiliza algún método natural para controlar la plaga o hierba?

“RENDIMIENTO”

- 1) ¿Cada cuánto tiempo siembre maíz?
- 2) ¿Cuánta producción de maíz obtiene al final de la cosecha (toneladas/ hectárea o etc.)?
- 3) ¿Aproximadamente en cuanto vende el producto final y cada cuanto lo hace?
- 4) Para la recolección de la cosecha final ¿Se lleva a cabo manualmente o utiliza alguna maquinaria?
- 5) ¿Cuánto desperdicio se genera al levantar la cosecha del cultivo?
- 6) ¿Tiene alguna utilidad el desperdicio generado?
- 7) ¿En cuánto se reduce el rendimiento si le cae la plaga?

La entrevista, paso por un proceso de “prueba piloto”, aplicada a un grupo de personas dedicadas especialmente a la agricultura de maíz en la comunidad de Ojite Rancho Nuevo, esta aplicación inicial, corresponde a la verificación de información, para validar la veracidad de esta. Esta observación, ayudo a verificar que la entrevista cumpla su objetivo de recabar la información pertinente para determinar aquellos factores que más influyen en el rendimiento de maíz, en caso de no cumplir el objetivo se tenía que modificar, pero como se coincidió que la prueba piloto si lograba el objetivo, se procedió al siguiente paso que fue la aplicación a comunidades aledañas de la ciudad de Álamo Temapache.

Verificada la validez de la información mediante la prueba piloto, se designaron 7 comunidades cercanas a la zona, esto fue a la limitante de recursos y medios, para adquirir la información, se lograron recabar aproximadamente 70 entrevistas en total en la región. Estas entrevistas contaban con un enfoque a agricultores conocedores del tema, para evitar la mal aplicación de esta y recolectar información no certera por el desconocimiento del tema, este aspecto también presento un problema al momento de no encontrar muchas personas

agricultoras, no porque no hubiera en las comunidades, sino porque era muy difícil ubicarlos para entrevistarlos.

4.3.2 Análisis de la información y creación de la base de datos.

La Figura IV-3, muestra las 7 comunidades entrevistada, donde se lograron levantar 70 entrevistas: Ojite, Doctor Montes de Oca, Temapache, Km 33 Paso Real, Potrero del Llano, San Miguel y el Xuchitl.




Figura IV-3. Comunidades entrevistadas.

Fuente: Google Earth. (2022)

Variables cualitativas y cuantitativas recabadas directamente.

Cada respuesta obtenida; se analizada detalladamente y sobre el análisis, la información correcta se distribuyó en una base de datos inicial con 22 variables, tanto cualitativas y cuantitativas. Por ejemplo, la pregunta 9 de la categoría “propiedades químicas y plagas”, se extrajeron las variables de los tipos de plagas presentes en el cultivo; y se colocaron en una hoja de Excel en el lugar correspondiente; el resto de información extraída se colocaba de la misma manera. Ver Tabla IV-3.

Tabla IV-3. Extracción de información a la base.

Zona	Papalotillo	Hormiga arriera	Gusano cogollero	Gusano medidor
Ojite	1	0	1	0
Ojite	1	0	1	0
Ojite	1	0	1	0
Ojite	0	0	1	0

Fuente: Elaboración propia.

Las variables extraídas en esta pregunta eran de tipo cualitativo, para poder manejarlas en la base de datos inicial se filtraron los datos a información binaria (0 y 1), dando a entender que si la plaga está presente se marcaba con el valor 1 y si no existía esa plaga con el valor 0.

Variables cualitativas y cuantitativas recabadas indirectamente.

Las variables que necesitaban otro medio para poder validarlas fueron:

- Altitud (m.s.n.ms).
- Pendiente (%).
- Y los nutrientes nitrógeno, fosforo, potasio, azufre y calcio.

La **altitud y pendiente**, se lograron obtener gracias a Google Earth Pro (Google Earth, 2022) , mediante a las zonas entrevistada y la ubicación aproximada del cultivo de cada agricultor entrevistado, ver Figura IV-4.




Figura IV-4. Altitud y pendiente.

Fuente: Google Earth (2022).

Las preguntas referentes a **fertilizantes** usados por agricultores y las veces que es aplicado por cosecha, fue indispensables para determinar los nutrientes nitrógeno, fosforo, potasio, azufre y calcio, que se adquieren en el cultivo gracias a la fertilización. La información adquirida en las entrevistas trae consigo la necesidad de distinguir con claridad los nutrientes que aporta cada tipo de fertilizante y las veces que es aplicado:

1. Los fertilizantes más utilizados por los entrevistados fueron de tipo sólido y líquido. De ellos se distinguieron el Bayfolan forte foliar, Bayfolan forte granulado, Urea, Grofol, Super fosfato de calcio triple y Sulfato de potasio.
2. Las veces que es aplicada la fertilización al cultivo, reflejo que la mayoría de entrevistado menciona que se tienen dos cosechas por año una corta y una larga; en cada cosecha aplican diferentes dosis (3 a 6 aplicaciones por cosecha).

El criterio 1 y 2, redactado con anterioridad, fue evaluado mediante una tabla, la cual describe las cantidades de nutrientes que aporta cada fertilizante esto de acuerdo con la ficha técnica de cada uno, ver Tabla IV-4.

Tabla IV-4. Nutrientes que aporta cada fertilizante.

NUTRIENTES	Urea	Bayfolan	GROFOL	BAYFOLAN GRANULADO	Super fosfato de calcio triple	Sulfato de potasio
Nitrógeno	46%	11%	20%	24%	18%	0%
Fosforo	0%	8%	30%	17%	46%	0%
Potasio	0%	6%	10%	13%	0%	50%
Azufre	0%	0%	5%	0.20%	0%	17%
Calcio	0%	0%	0%	0.02%	0%	0%

Fuente: Elaboración propia.

Los fertilizantes entablados, constan de 3 tipos, sólidos, líquidos y los sólidos granulados solubles en líquido:

- El color gris presenta un tipo de fertilizante sólido aplicado directamente a las plantas.
- El de color azul, fertilizantes líquidos para aplicación por bomba.
- Y los de color verde representan fertilizantes sólidos granulados solubles en agua para aplicación por bomba.

Cada columna, muestra el contenido de nutrientes que aportan, la unidad de medida es expresada en porcentaje (%). Se contaron 6 tipos diferentes de fertilizantes, con características diferentes en sus porcentajes. La clasificación de fertilizantes y los porcentajes que aportan cada uno; se logró determinar realmente la dosis de fertilización líquida, sólida

y sólida granulada soluble en agua, aplicada al cultivo. Los **fertilizantes líquidos y granulados solubles en agua**, aplicados mediante bomba, conllevan criterios como:

- Los litros totales de agua utilizados por hectárea.
- La cantidad total de fertilizante líquido o sólido que se mezcla con el agua.
- Las veces que es aplicada la fertilización por temporada.

La Tabla IV-5, presentan los criterios considerados, para poder obtener la cantidad total de fertilizante líquido aplicado en el cultivo y en la Tabla IV-6, del mismo modo, pero para los fertilizantes granulados solubles en agua y en la Tabla IV-7, se puede apreciar los fertilizantes sólidos.

Tabla IV-5. Cantidad de fertilizante líquido aplicado en el cultivo.

M A Í Z	APLICACIÓN FOLIAR							Fertilizante
	Bombas X ha	Litros por bomba	Litros totales ocupados.	Fertilizante (ml) aplicado por lt	Cantidad de fertilizante total (ml)	Veces aplicadas por temporada	Fertilizante total (ml/ha)	Bayfolan forte
	3	20	60	10	600	3	1800	

Fuente: Elaboración propia.

Tabla IV-6. Cantidad de fertilizante sólido granulado soluble en agua.

M A Í Z	Aplicación en grano							Fertilizante
	Bombas x ha	Litros por bomba	Litros totales ocupados.	Fertilizante (kg) aplicado por lt	Cantidad de fertilizante total (kg)	Veces aplicadas por temporada	Cantidad final de fertilizante total (Kg/ha)	GROFOL
	1	20	20	0.1	2	2	4	

Fuente. Elaboración propia.

Tabla IV-7. Cantidad de fertilizante sólido aplicada en el cultivo.

MAÍZ	Costales/ha	Kg por costal	Cantidad usada	Fertilizante.
	1	50	50	Urea

Fuente:Elaboración propia.

Las tablas mencionadas, cumplen el objetivo de calcular la cantidad de fertilizante aplicado al cultivo (ml/a, kg/ha y costal/ha) por ejemplo, si un agricultor utiliza 3 bombadas de 20 litros por hectárea, y cada litro le añade 0.1 kilogramos de fertilizante granulado. Y lo realiza 3 veces por temporada. Queda expresado en la Ecuación IV-1:

$$FT \cdot At = FfA$$

Ecuación IV-1. Fertilizante final aplicado al cultivo.

Donde:

Para determinar FT, se debe multiplicar los litros totales de agua ocupados por el fertilizante añadido a cada litro.

- FT = Fertilizante total que se añade a la solución (Acorde a las especificaciones).
- At= Aplicación por temporada.
- FfA = Fertilizante final aplicado al cultivo.

Sustituyendo los valores:

1. FT= 3 bombadas de 20 litros = 60 litros * 0.1 kg de fertilizante añadido = **6 Kg de fertilizante total** y si lo aplica 3 veces por temporada, quedaría expresado:

$$6 Kg \cdot 3 = FfA$$

$$FfA = 18 Kg /ha$$

Entonces como se añaden 6 kilogramos de fertilizante a los litros de agua total usado, ese valor se multiplica por las veces que es aplicado en la temporada, dándonos como resultado la cantidad de fertilizante final aplicado en el cultivo.

El **fertilizante final aplicado al cultivo**, simplemente se multiplicará por el porcentaje de nutriente, que aporta cada fertilizante, referente a la tabla de “nutrientes que aporta cada fertilizante”, donde se enlistaron los porcentajes que contiene cada fertilizante. Para mayor entendimiento, si se toma el ejemplo anterior donde se obtuvo que se aplican **18 kg/ha de fertilizante**, y se establece que es de bayfolan granulado solo queda, multiplicar la cantidad por el porcentaje de nutrientes que contiene y así se genera la cantidad de nutrientes aportados. Ver Tabla IV-8.

Tabla IV-8. Kg / ha aplicado.

NUTRIENTES	BAYFOLAN GRANULADO	Fertilizante final aplicado	Kg / ha
Nitrógeno	24%	18	4.32
Fosforo	17%	18	3.06
Potasio	13%	18	2.34
Azufre	0.20%	18	0.036
Calcio	0.02%	18	0.0036

Fuente: Elaboración propia.

De esa manera se logran obtener las cantidades de nitrógeno (N), fosforo (P), potasio (K), azufre (S) y calcio (Ca). La cuales se basaron en la base de datos

4.3.3 Contenido final de la base de datos.

Se lograron determinar, un total de 22 variables de tipo cualitativo y cuantitativo, en la Tabla IV-9, se observa una fracción de la base de datos final.

Tabla IV-9. Ejemplo de una fracción de la base a utilizar.

Zona	Papalotilla	Hormiga arriera	Gusano cogollero	Gusano medidor	Temperatura anual (°C)	Precipitación total al año (mm)	Radiación solar (hrs/año)	Índice de severidad de sequia	Pendiente (%)	Altitud (msnm)
Ojite	1	0	1	0	28.083	1374.4	157.4	Muy fuerte	4.76	33
Ojite	1	0	1	0	28.083	1374.4	157.4	Moderado	1.05	10.5
Ojite	1	0	1	0	28.083	1374.4	157.4	Muy fuerte	2.56	60
Ojite	0	0	1	0	28.083	1374.4	157.4	Moderado	0.69	10.5
Ojite	1	0	1	0	28.083	1374.4	157.4	Muy fuerte	2	33
Ojite	0	0	1	1	28.083	1374.4	157.4	Moderado	0.79	38
Ojite	1	0	1	0	28.083	1374.4	157.4	Moderado	2.03	37

Fuente: Elaboración propia.

4.4 Creación y configuración de la red neuronal.

La información plasmada en la base de datos es el medio inicial para elaborar un sistema inteligente a base de redes neuronales que permitan pronosticar las dosis NPK y el rendimiento esperado; y también determine el impacto de las variables más influyente en cada predicción.

Las predicciones, se determinan, a través del software Matlab y para determinar las variables de mayor impacto se utilizó el algoritmo de Garson. Es importante mencionar que el software

a utilizar solo puede manejar variables cuantitativas por ello es necesario categorizar aquellas variables de tipo cualitativo a cuantitativo.

4.4.1 Red neuronal en Matlab.

Matlab, maneja variables de tipo cuantitativo, entonces las variables cualitativas, tienen que ser transformada a valores cuantitativos. La base inicial, constaba con 5 variables cualitativas, mismas que tienen que convertirse a datos numéricos, para la conversión de las mismas se les designo un valor numérico, mediante la guía de la Tabla IV-10.

Tabla IV-10.Designación de valores numéricos.

Nº	Zona	Índice de severidad de sequía	Drenaje externo	Drenaje interno	Textura
1	Ojite	Muy fuerte	Bueno	Bueno	Franco arcilloso
2	Dr Montes de oca	Moderado	Moderado	Moderado	Arcilloso
3	Temapache		Malo	Malo	Franco arcilloso
4	KM 33 Paso Real				
5	Potrero del Llano				
6	San Miguel				
7	Xuchitl				

Fuente: Elaboración propia.

El número designado para cada variable sustituye los valores cualitativos, para que la base a utilizar contenga solo valores numéricos. Este software puede obtener diferentes salidas en una red, como es el tema de interés predecir las dosis de NPK para el maíz y el rendimiento esperado, directamente se crearon dos modelos con salidas diferentes, el primer modelo tendría como salida las dosis NPK (nitrógeno, fosforo y potasio), mientras que el segundo modelo su salida fue el rendimiento esperado.

Creación y configuración de la red.

Para crear la red, se sigue una serie de pasos, pero antes de hacer el seguimiento; es importante que la hoja de Excel de la base de datos contenga solo valores numéricos y que las columnas finales coincidan con las variables de salidas que se buscan obtener en el modelo. Entendiendo lo anterior, se establecen la siguiente serie de pasos, ver Figura IV-5.




Figura IV-5. Creación de la red neuronal, Matlab.

Fuente: Elaboración propia.

Introducción de datos y normalización de entradas y salidas.

Para la creación de la red neuronal NPK y rendimiento esperado, es necesario ingresar los datos al programa. El llevar a cabo este proceso, trae consigo 3 partes que se deben cumplir:

1.- Definir un nombre para la base, mediante la siguiente Ecuación IV-2.

$$\text{Nombre} = [\text{Base de datos}]$$

Ecuación IV-2. Definición del nombre de la base.

Donde:

Nombre: Representa el nombre que se le dese dar a la base.

Base de datos: Es la base de datos a manejar.

2.- Definir entradas y salidas, de la base nombrada y al mismo tiempo trasponerlas con el uso de un apostrofe. Este proceso se puede llevar a cabo con la Ecuación IV-3.

$$\text{Entradas o Salida} = \text{Nombre}(:, \text{Inicio} : \text{Final})'$$

Ecuación IV-3. Definición de entradas y salidas.

Donde:

Entradas o salida: Sera de acuerdo con la definición que se quiera establecer.

Nombre: Es el mismo nombre que ha sido definido con anterioridad a la base.

Inicio: Rango inicial de datos para entrada o salida.


Final: Rango final hasta donde llegan las entradas o salidas.

3.- Normalizar los valores de entrada y salida, mediante la Ecuación IV-4.

$$[\text{mun}, \text{max}] = \text{mapminmax}(\text{Entradas o Salidas});$$

Ecuación IV-4. Normalización de entradas y salidas.

Aplicados los comandos, se obtiene como resultado la definición de las variables de entrada y de salida; y también la normalización de los valores. Para observar un poco más a detalle, ver la Figura IV-6, donde se presenta la introducción de los datos y su definición en Matlab.



Name	Value	Min	Max
Entradas	19x70 double	0	1.3744...
fertilizante	70x22 double	0	1.3744...
max	1x1 struct		
min	3x70 double	-1	1
Salidas	3x70 double	0	4.6026

Figura IV-6. Introducción de los datos, Matlab 2014.

Fuente: (Matlab, 2014)

Creación de la red.

Establecido el conjunto de datos, para la creación de la red en la hoja de Matlab, se aplica el comando **nntool**, que abre una ventana para proceder con la creación del modelo NPK o rendimiento esperado, acorde a los datos ingresados. Ver Figura IV-7.




Figura IV-7. Ventana nntool, Matlab 2014.

Fuente: (Matlab, 2014)

En la ventana generada se importan los valores introducidos anteriormente (entradas y salidas). Matlab permite importar parte por parte, cada conjunto de valores:

- Las entradas se importan al destino **Input data**.
- Las salidas al destino **Target Data**.

En ambos casos importados, se debe verificar que aparezca, un cuadro de dialogo donde mencione que la red ha sido importada, ver Figura IV-8.




Figura IV-8. Importación de variables, Matlab 2014.

Fuente: (Matlab, 2014)

Configuración de la red

Creada la red, se puede configurar, en la Figura IV-9, se muestra como Matlab permite configurar cada parte de la red, se puede modificar el tipo de red, la selección de entradas y salidas, la función de entrenamiento, la función de aprendizaje de la adaptación, la función de rendimiento, el número de capas, el número de neuronas y la función de transferencia. La configuración se realiza a criterio, de forma que la elección de cada apartado represente lo óptima para la finalidad de la red y los resultados que se esperan.




Figura IV-9. Configuración de la red neuronal, Matlab 2014.

Fuente: (Matlab, 2014)

Para la configuración utilizada para ambos modelos NPK y rendimiento esperado, se tomaron en cuenta los siguientes puntos:

- **Network Type – Tipo de red:** El software dispone de distintos tipos de redes, los modelos plasmados para el estudio requirieron el uso de una red Feed-Foward backpropagation. Esta red, es capaz de identificar ciertos patrones de datos arbitrarios, de esa manera, busca un patrón similar a las características que haya aprendido durante el entrenamiento, al ser una red de propagación hacia atrás los errores detectados en el proceso se minimizaran ajustando y actualizando los pesos, para la reducción de los errores, y con ello garantizar la valides de los resultados

- **Input data (Entradas) y target data (Salidas):** Se incluyen las entradas y salidas, que con anterioridad se exportaron a la red de cada modelo.
- **Training function – Función de entrenamiento:** Se cuentan con distintas funciones de entrenamiento, la red neuronal de interés se debe manejar una función de entrenamiento TRAINLM, debido a que es la más recomendada como algoritmo supervisado óptimo con un número mínimo de salidas, esta función actualiza los valores de peso y sesgo mediante la optimización de Levenberg-Marquardt.
- **Adaptation learning function -Función de aprendizaje para la función:** La red neuronal se basó en una función de aprendizaje LEARN_GDM, este tipo de aprendizaje es el descenso de gradiente con peso de impulso y función de aprendizaje de sesgo.
- **Performance function- función de rendimiento:** Matlab maneja dos funciones de rendimiento, la MSE fue seleccionada, ya que este tipo de función mide el rendimiento de la red de acuerdo con la media de errores cuadráticos.
- **Number of layer- Numero de capas:** El número de capas es configurado personalmente, si queremos que la red tenga un mayor procesamiento de los datos, se le pueden añadir más capas.
- **Properties for layer. Propiedades para la capa:** Se puede modificar el número de neuronas por capa, siempre y cuando existan más capas en la red, se puede configurar para añadir más número de neuronas por capa.
- **Number of neurons- Numero de neuronas:** El número de neuronas es ajustado de acuerdo al rendimiento de la red si se presenta un rendimiento bajo se puede añadir mayor número de neuronas, hasta notar que la red mejore. Para este caso se analizó

la red con 5 y 10 neuronas, para observar el comportamiento de las mismas y decidir cuál arroja un mejor entrenamiento, para su posterior simulación.

La configuración final de la red para ambos modelos a plasmar queda representada en la Tabla IV-11.

Tabla IV-11. Propiedades de la red.

Element	Network properties
Network type	Feed-forward backpropagation
Training function	Trainlm
Adaptation learning function	Learngdm
Performance function	MSE
Number of layers	2
Number of neurons for layer 1	5 y 10
Transfer function	Tansig

Fuente: Elaboración propia.

El número de neuronas puede ser ajustado a consideración del rendimiento presentado por parte del entrenamiento, como se mencionó anteriormente, en este caso se utilizarán 5 y 10 neuronas, analizando cual se ajusta mejor y genera los mejores resultados, obteniendo que **5 neuronas son las ideales** para los modelos al contar con un base de datos pequeña.

Establecida la configuración de la red, para los modelos NPK y rendimiento esperado, el software permite visualizar la estructura de la red. Ver Figura IV-10.




Figura IV-10. Red NPK y rendimiento esperado, Matlab.

Fuente: (Matlab, 2014)

Para comprender un poco más las imágenes plasmadas, se presenta la Tabla IV-12, donde se describe el número de variables de entradas y salidas de cada modelo.

Tabla IV-12. Número de variables de entrada y salida utilizadas.

Descripción.	NPK	Rendimiento esperado.
Variables de entrada.	19	21
Variable de salidas.	3	1
Neuronas	5	5

Fuente: Elaboración propia.

En el modelo NPK, se introdujeron 19 variables de entrada y 3 de salida que fueron el nitrógeno, fosforo y potasio. Y para rendimiento esperado, se anexaron 21 variables de entrada y de salida solamente una que corresponde al rendimiento que se esperado.

Entrenamiento de la red.

El entrenamiento de la red para ambos modelos NPK y rendimiento esperado, permiten que se configure la red para que aprenda sobre la marcha, un aspecto considerable que se debe tener en cuenta es que la red puede ser entrenada varias veces y esos entrenamientos ayudan a mejorarla y minimizar los errores; asimismo el exceso de entrenamiento puede generar un desajuste, por ello es recomendable analizar cuando mejore la red y tomar ese mejor entrenamiento, evitando así un sobre-entrenamiento. Antes de simular la red, se deben seleccionar las entradas y salidas, que fueron incluidas al programa, ver Figura IV-11.




Figura IV-11. Selección de entradas y salidas para train.

Fuente: (Matlab, 2014)

Incluidas las entradas y salidas para el entrenamiento, se procede a seleccionar el Train Network, donde se entrenará la red. La Figura IV-12 , muestra una ventana del software

donde contiene las características de la red ya seleccionadas, junto con los algoritmos que usara y el progreso que se obtiene mediante los entrenamientos.




Figura IV-12. Neural network training.

Fuente: (Matlab, 2014)

Si es necesario visualizar el performance, training state y regression, se puede seleccionar y observar el comportamiento de cada plot, para verificar que realmente el entrenamiento este fluyendo correctamente. La cantidad de veces a entrenar la red se realiza a criterio, es indispensable que se encuentre el mejor entrenamiento con el menor número posible de errores. En regression se visualiza el comportamiento de los gráficos para trainig, validation, test y all; estos deberán tener un margen no muy alejado para poder establecer que el entrenamiento es correcto y no hay errores significativos en su relación.

4.4.2 Simulación de la red para la predicción, Matlab.

El entrenamiento correcto de la red, es esencial para la simular una nueva entrada de datos, que brinde la predicción de los valores NPK y rendimiento esperado (RE). La Figura IV-13 , presenta la serie de pasos a seguir para poder simular la red ya entrenada.




Figura IV-13.Simulación Matlab.

Fuente: Elaboración propia.

La predicción de los valores mediante la red entrenada, debe seguir los pasos indicados donde:

1. Primeramente, se debe elaborar una nueva base de datos recabando valores nuevos ya se por una estimación o recolección de nueva información.
2. La base creada se tiene que introducir en el software del mismo modo que se realizó en paso anteriores.
3. Introducida la base se seleccionan las entradas y salidas, posteriormente se importan los valores necesarios.
4. Seleccionado e importado los valores introducidos se realiza la simulación de ambos modelos NPK y rendimiento esperado, donde el entrenamiento realizado la función de predecir esos datos.
5. Generadas las predicciones se analizan los valores respecto con los originales, para observar si se acercan o no y comprobar su validación.

4.4.3 Contribución relativa (RC).

La Ecuación IV-5 , presenta el algoritmo de Garson, que es utilizado para determinar la contribución relativa (RC) de las variables de entrada de la ANN. Calcula el coeficiente de importancia en función del producto de los pesos de conexión entre las neuronas de la capa de entrada, las neuronas de la capa oculta y las neuronas de la capa de salida de la red neuronal. Este es el i-ésimo factor de entrada del k-ésimo coeficiente de sensibilidad de salida definido en la ecuación (Maozhun & Ji, 2017).

Ecuación IV-5. Algoritmo de Garson.

$$RC = \frac{\frac{\sum_{j=1}^n W_{ij} V_{jk}}{\sum_{k=1}^n W_{ij}}}{\sum_{i=1}^l \sum_{j=1}^n \frac{W_{ij} V_{jk}}{\sum_{i=1}^n W_{ij}}}$$

Donde, i, j, k, respectivamente, se refieren a las neuronas de la capa de entrada, la capa oculta y la capa de salida; Wijes los pesos de conexión entre la capa de entrada y la neurona de la capa oculta, Vjk son los pesos de conexión entre la capa oculta y las neuronas de la capa de salida, n es el número total de neuronas de la capa de entrada, m es el número total de neuronas de la capa de salida. Aplicando la fórmula descrita anteriormente podemos ver cuáles son las variables que tienen una mayor contribución relativa a la hora de determinar el riesgo de contraer una IN.

Conociendo la contribución relativa de cada variable, se puede tomar en cuenta que las variables pueden influir en cierta manera al resultado final, con ello es necesario darle la misma importancia merecida a todos los factores y variables.

CAPITULO V . ANÁLISIS DE RESULTADOS

5.1 Entrenamientos de red favorable.

El entrenamiento de las redes con Matlab para las dos salidas, presentan un coeficiente de correlación cercano a la unidad (1). La Tabla V-1 , resume los resultados obtenidos mediante cada entrenamiento realizado.

Tabla V-1. Resumen de los entrenamientos red NPK y rendimiento esperado.

Network	Neurons in the hidden layer	R-Training	R-Validation	R-Test	R-All
NPK	5	0.98722	0.91414	0.93435	0.96501
	5	0.99563	0.92293	0.91412	0.9725
	5	0.9814	0.96768	0.93419	0.9725
	5	0.97163	0.96269	0.98143	0.9725
	5	0.97187	0.98991	0.95722	0.9725
	5	0.97839	0.95474	0.96671	0.9725
	5	0.97391	0.97404	0.97278	0.9725
	10	0.98218	0.92418	0.90692	0.96243
	10	0.99822	0.93452	0.86333	0.96471
	10	0.96141	0.97002	0.9608	0.96243
	10	0.95691	0.96694	0.98317	0.96243
	10	0.96013	0.96717	0.973	0.96243
	10	0.95825	0.9819	0.95938	0.96243
	10	0.95969	0.97569	0.97003	0.96243
RENDIMIENTO ESPERADO	5	0.97689	0.94167	0.87341	0.95495
	5	0.95	0.97461	0.95817	0.95495
	5	0.95112	0.9568	0.97797	0.95495
	5	0.97257	0.9102	0.97124	0.96521
	5	0.98829	0.86882	0.9352	0.975881
	5	0.97919	0.96486	0.96556	0.97581
	5	0.98357	0.95141	0.96589	0.97581
	5	0.9857	0.95141	0.96589	0.97581
	5	0.9985	0.96141	0.96589	0.97681
	5	0.99985	0.97796	0.98122	0.98873
	10	0.93544	0.96127	0.95925	0.93971
	10	0.98978	0.97472	0.88004	0.96733
	10	0.99633	0.96541	0.98421	0.98543
	10	0.98661	0.9843	0.98795	0.98543
	10	0.98746	0.98918	0.98509	0.98543
	10	0.98468	0.9908	0.98288	0.98543
	10	0.98477	0.98617	0.98684	0.98543

Fuente: Elaboración propia.

Las redes NPK y rendimiento esperado (RE), se entrenaron con un numero de 5 y 10 neuronas, para analizar el comportamiento de cada una. Este proceso se realizó con un máximo de 10 entrenamientos y un mínimo de 7, tratando de evitar algún sobre-entrenamiento, hasta llegar a un punto de correlación cercano en training, validation y test; y no existiera una diferencia significativa. Los entrenamientos presentaron un resultado favorable desde un inicio, por lo que simplemente se entrenó las cantidades de veces planteadas, para que las redes aprendieran de los valores introducidos para su posterior simulación

Training, Validation, Test y All.

De ambos casos para NPK y rendimiento esperado (RE), los que presentaron un mejor entrenamiento por una diferencia mínima fue la red con 5 neuronas, al presentar resultados favorables en cada entrenamiento y generar valores apegados en R-Training, R-Validation y R-Test. La Tabla V-2, muestra los mejores entrenamientos para ambos casos con 5 y 10 neuronas.

Tabla V-2.Mejor entrenamiento.

Network	Neurons in the hidden layer	R-Training	R-Validation	R-Test	R-ALL
NPK	5	0.97391	0.97404	0.97278	0.9725
	10	0.96013	0.96717	0.973	0.96243
RENDIMIENTO ESPERADO	5	0.99985	0.97796	0.98122	0.98873
	10	0.98468	0.9908	0.98288	0.98543

Fuente: Elaboración propia.

Los resultados fueron favorables en cada entrenamiento por parte de ambos casos, se optó por tomar las más destacadas para cada entrenamiento en NPK y rendimiento esperado. Los valores R-Training, R-Validation y R-Test, más cercanos son los ideales, aunque la mayoría se aproximaba, por ese motivo se tomó en cuenta el R-All, donde el más cercano a la unidad (1), y que los demás valores presentaran una cercanía, es el entrenamiento ideal, dando como un mejor resultado en ambos casos para NPK y rendimiento esperado, que la red con 5 neuronas cumple las características mencionadas. El comportamiento entre los valores R-Training, R-Validation, R-Test y R-All para el modelo NPK y rendimiento esperado, se ven representados en la Figura V-1 y Figura V-2, donde se observa el grafico del mejor

entrenamiento para la red con 5 neuronas y seleccionada como entrenamiento final, para su posterior simulación.




Figura V-1. Coeficientes de correlación de red NPK.

Fuente: (Matlab, 2014)




Figura V-2. Coeficientes de correlación de red rendimiento esperado.

Fuente: Matlab.

5.2 Validación y uso de la red.

Los entrenamientos de las redes permiten introducir una nueva base de datos con valores diferentes a los ya entrenados, para la predicción de las dosis NPK y el rendimiento esperado; mediante este proceso se puede comprobar y validar el uso de ambos modelos con sus respectivas redes neuronales, siendo un punto de validez el obtener predicciones lo más posible a lo real.

5.2.1 NPK.

Mediante la introducción de una nueva base a ambos modelos, se puede simular la red, para predecir nuevos valores de salida, donde el modelo NPK, podrá pronosticar valores de nitrógeno, fosforo, potasio y el otro modelo el rendimiento. Para este proceso se tomó en cuenta una base con 30 datos nuevos y con las mismas variables mencionadas con anterioridad, a través de la simulación, el software logro la predicción aproximada de las variables de salida para cada modelo, estos valores generados se compararon con los reales para comprobar la confiabilidad del modelo. La Tabla V-3, presenta las predicciones generadas por el modelo NPK a través de la red neuronal creada en Matlab, y los valores reales de la base de datos inicial, así mismo el residuo o diferencia que se genera entre lo real y lo predicho.

Tabla V-3. Predicciones y valores reales, del modelo NPK.

MODELO NPK.								
Nitrógeno (N) Kg/Ha			Fosforo (P) Kg/Ha			Potasio (K) Kg/Ha		
Real	Predicción	Residuo	Real	Predicción	Residuo	Real	Predicción	Residuo
24.3723	25.1529	0.7806	13.84	12.0403	1.7997	6.12	6.8847	0.7647
18.9853	18.0212	0.9641	7.604	5.913	1.691	9.076	8.7499	0.3261
25.01258	23.5314	1.48118	18.56	15.7725	2.7875	20.42	20.0545	0.3655
18.02182	17.9687	0.05312	6.412	4.7717	1.6403	8.572	5.9134	2.6586
15.56584	16.675	1.10916	4.866	3.9289	0.9371	6.77	6.6021	0.1679
28.9082	28.7607	0.1475	17.16	15.8576	1.3024	19.54	20.0092	0.4692
24.1161	24.485	0.3689	12.666	12.2963	0.3697	14.994	15.9722	0.9782
20.8603	21.6136	0.7533	14.896	11.6355	3.2605	11.54	14.6559	3.1159
20.65384	23.5015	2.84766	10.752	9.7944	0.9576	13.54	11.8089	1.7311
20.5162	21.8375	1.3213	10.656	11.8703	1.2143	14.432	13.8858	0.5462
21.5222	22.6147	1.0925	9.958	10.7627	0.8047	14.35	17.108	2.758
15.8664	16.8095	0.9431	2.664	2.5636	0.1004	2.018	4.1133	2.0953
21.38456	20.5821	0.80246	9.862	10.7789	0.9169	15.278	18.4854	3.2074
32.46584	32.2441	0.22174	18.676	18.5535	0.1225	20.272	19.8006	0.4714

26.3441	23.8317	2.5124	15.61	13.6747	1.9353	15.37	15.6623	0.2923
22.3241	21.6962	0.6279	9.2	8.9165	0.2835	13.16	13.0588	0.1012
15.29056	15.6002	0.30964	4.674	2.6921	1.9819	4.77	5.3175	0.5475
24.1262	22.9233	1.2029	10.426	11.556	1.13	16.83	15.9773	0.8527
21.04046	20.5685	0.47196	8.622	9.1484	0.5264	11.098	10.9554	0.1426
24.0121	23.003	1.0091	10.186	10.2554	0.0694	16.56	15.1091	1.4509
18.48756	19.3314	0.84384	5.74	5.0263	0.7137	8.958	9.1029	0.1449
21.68984	20.4743	1.21554	7.564	5.9001	1.6639	11.7124	9.373	2.3394
15.0481	15.6422	0.5941	3.906	2.1944	1.7116	3.926	3.6223	0.3037
18.2811	18.2685	0.0126	5.53	5.7057	0.1757	8.85	8.7917	0.0583
23.6032	24.1574	0.5542	14.91	14.2833	0.6267	11.23	11.3505	0.1205
25.56646	25.5203	0.04616	13.704	14.5358	0.8318	16.188	16.6327	0.4447
18.14346	18.7717	0.62824	6.434	5.3884	1.0456	8.778	8.7839	0.0059
14.91046	15.5531	0.64264	3.81	3.1525	0.6575	3.926	4.0505	0.1245
20.00774	20.2237	0.21596	6.252	6.9954	0.7434	9.288	9.7608	0.4728
18.9693	18.8673	0.102	8.01	11.7374	3.7274	6.621	2.345	4.276

Elaboración: Fuente propia.

Se observa, que el modelo NPK, logra predecir satisfactoriamente las dosis de nitrógeno (N), fosforo (P) y potasio (K), aunque claramente exista una pequeña diferencia entre valores reales y predichos, es un punto de apoyo que logra determinar esas cantidades de fertilización tomando en cuenta ciertas variables que influyen en esto mismo. Los residuos presentados para cada variable de salida tienen una ligera variación, la Tabla V-4, muestra las diferencia máxima y mínima, existente para cada nutriente.

Tabla V-4. Diferencia max y min de residuo, NPK.

Nutriente	Valor máximo (Kg/ha)	Valor mínimo (Kg/ha)
N	2.84766	0.0126
P	3.7274	0.0694
K	4.276	0.0059

Fuente: Elaboración propia.

La discrepancia, entre los valores reales y predichos, presentaron un valor máximo para nitrógeno (N) de 2.84766 Kg/ ha y una mínima de 0.0126 kg/ha. Para fosforo (P), se presentó un valor de diferencia máximo de 3.7274 Kg/ha y mínima de 0.0694 kg/ha. Y para potasio (K), se obtuvo un valor máximo de 4.276 Kg/ha y un mínimo de 0.0059 Kg/ha. Esto quiere decir que el modelo puede presentar una cierta diferencia mínimas al predecir nuevos resultados, al presenta dispersión entre los valores. La Figura V-3 , presentan la dispersión existente entre los valores reales y predichos para **nitrógeno**.




Figura V-3. Dispersión Nitrógeno (N).

Fuente: Elaboración propia.

Es notorio que se presenta una dispersión entre los valores, esto ya mencionado anteriormente que se obtuvieron valores poco dispersos a lo real, El coeficiente de determinación R^2 , indica que precisamente sí hay variabilidad existente, esta dispersión puede ser a la relación que hay entre el nitrógeno y las variables utilizadas para su predicción. De esa manera al existir variables que tienen un mayor impacto y relación en la determinación del nitrógeno, por ello la Figura V-4, presenta esas variables de impacto relativo en el nitrógeno.




Figura V-4. Variables de impacto relativo para Nitrógeno (N).

Fuente: Elaboración propia.

El **fosforo (P)**, también presento una cierta dispersión mediante el valor estimado y el real, la Figura V-5, muestra la dispersión generada entre lo real y predicho.




Figura V-5. Dispersión Fosforo (P).

Fuente: Elaboración propia.

La variabilidad existente presentada, se ve influida por la relación que existe con las otras variables. La Figura V-6, muestra las variables que mayor impacto generan para el fosforo.




Figura V-6. Variables de impacto relativo para Fosforo (P).

Fuente: Elaboración propia.

El **potasio (K)**, cuenta con una diferencia significativa entre valores simulados y reales, ocasionado con ello una dispersión entre los valores. Ver Figura V-7.




Figura V-7. Dispersión Potasio (K).

Fuente: Elaboración propia.

Al igual que los factores anteriores esta variabilidad de valores, se ve influida por variables de impacto relativo hacia el potasio, ver Figura V-8.




Figura V-8. Variables de impacto relativo para Potasio (K).

Fuente: Elaboración propia.

5.2.2 Rendimiento esperado (RE).

La Tabla V-5, presenta las predicciones generadas por el modelo rendimiento esperado; así como el valor real del rendimiento y el residuo existente entre ambos valores.

Tabla V-5. Predicciones y valores reales, del modelo rendimiento esperado.

RENDIMIENTO ESPERADO (Ton/Ha)		
Real	Predicción	Residuo.
2.5	2.4986	0.0014
1	1.1561	0.1561
4	3.9859	0.0141
1	1.0018	0.0018
0.5	0.73859	0.23859
3	2.977	0.023
2.5	2.4431	0.0569
2	1.9958	0.0042
2	1.6555	0.3445
2	1.9882	0.0118
1.5	1.5055	0.0055
0.3	0.34326	0.04326
1.5	1.5059	0.0059
4	3.9861	0.0139
2.5	2.498	0.002
1.5	1.489	0.011
0.5	0.51999	0.01999
2	2.003	0.003
1.5	1.5183	0.0183
2	1.9932	0.0068
1	0.99016	0.00984
1.5	1.5052	0.0052
0.5	0.49937	0.00063
1	0.98611	0.01389
2	1.9936	0.0064
2.5	2.4995	0.0005
1	1.0274	0.0274
0.5	0.48357	0.01643
1.5	1.4192	0.0808
1	0.92629	0.07371

Fuente: Elaboración propia.

Los valores creados por el modelo rendimiento esperado, se aproximan a los valores reales, aunque claramente es notorio que existe una cierta diferencia entre las cantidades simuladas y las reales, se puede mencionar que con esta aproximación existente el modelo puede acercarse a las cantidades de rendimiento que se esperan tener, contemplando las variables influyentes en el terreno. En este caso las diferencias máximas y mínimas entre las cantidades reales y simuladas se representa en la Tabla V-6.

Tabla V-6. Valores max y min, rendimiento esperado.

Factor	Máximo	Mínimo
Rendimiento esperado.	0.3445	0.0005

Fuente: Elaboración propia

El valor máximo más alejado de la realidad fue de 0.3445 Ton/Ha, mientras que el valor mínimo se representó por 0.0005 Ton/Ha, por tal motivo es que se genera una cierta discrepancia entre las cantidades de rendimiento esperado real y simulado. Ver Figura V-9.




Figura V-9. Dispersión rendimiento esperado.

Fuente: Elaboración propia.

La variabilidad entre valores es poca para este caso. Esa mínima variabilidad se presenta a debido a las variables de mayor impacto relativo que influyen en el rendimiento, ocasionando que este se reduzca o aumente. Ver Figura V-10.




Figura V-10. Variables de mayor impacto para rendimiento.

Fuente: Elaboración propia.

Análisis general de los resultados.

En general los datos adquiridos mediante los modelos NPK y rendimiento esperado (RE), se generalizan y resumen, en la siguiente Tabla V-7 :

Tabla V-7. Tabla resumen de resultados.

Tabla resumen modelo “NKP”				
Variables	Discrepancia entre valor real y predicho (ANN 5 neuronas).		R2	Variables de impacto relativo
	Máximo (Kg/Ha)	Mínimo (Kg/Ha)		
Nitrógeno (N)	2.84766	0.0126	0.9399	K, P, S
Fosforo (P)	3.7274	0.0694	0.9036	RE, N, K, S
Potasio (K)	4.276	0.0059	0.9117	P, N, S
Tabla resumen modelo “Rendimiento esperado”				
Variables	Discrepancia entre valor real y predicho (ANN 5 neuronas).		R2	Variables de impacto relativo
	Máximo (Ton/Ha)	Mínimo (Ton/Ha)		
Rendimiento esperado.	0.3445	0.0005	0.9919	N, P, S, A

Fuente: Elaboración propia.

La discrepancia presentada entre los valores reales y predichos, para cada variable de salida en el modelo NPK (Nitrógeno, fosforo y potasio) y rendimiento esperado (RE), muestran que las redes creadas, logran predecir correctamente estos valores; a manera que no se genera mucha diferencia ni se alejan de la realidad, esto tomando en cuenta las características de cada terreno. Así mismo los valores R^2 obtenidos en los modelos, para cada variable de salida, nos indican que la comparativa entre valores predichos y los reales, es bueno al contar con una cercanía a la unidad, dando referencia que cuando el valor R^2 es cercano a 1, indica que mayor resultara el ajuste del modelo y lograra predecir perfectamente los valores de interés. Con los resultados obtenidos, se puede establecer que dichos modelos son capaces de lograr una predicción cercana a lo real para la determinación de nitrógeno (N), fosforo (P), potasio (P) y rendimiento esperado (RE).

CAPITULO VI . CONCLUSIONES

La fertilización es un punto de apoyo medular en cualquier cultivo, gracias a que este factor en parte logra el incremento del rendimiento por hectárea del cultivo, en el caso del maíz para la región de álamo se notó que los agricultores entrevistados, la mayoría aplica muy poco la fertilización dejando a un lado la idea de adquirir un mejor rendimiento, esto es por distintos factores presentes, esta parte se ve reflejada, en los rendimientos de maíz para la región, los cuales la mayoría llegan a ser bajos o solo se ocupan para consumo.

Con la elaboración de este trabajo se tiene un panorama más claro sobre las variables que pueden llegar a generar una alteración en el rendimiento final del maíz, como se destacó desde un inicio de la investigación, el aplicar ciertas cantidades de fertilizantes en el cultivo para la mejorar el rendimiento por hectárea de este grano, no siempre resulta favorable, ya que muchas veces esta aplicación se hace de manera espontánea, sin tomar a consideración factores o variables del terreno, que pudieran generar alguna alteración al aplicar el fertilizante. Es por ello que, en este estudio, se logra la creación de sistemas de apoyo a la decisión en la fertilización de maíz, mediante el uso de redes neuronales, donde para el modelo de nombre “NPK” y el modelo “rendimiento esperado (RE)”, se destacaron como objetivo principal el lograr pronosticar las dosis de fertilización a base de nitrógeno (N), fosforo (P) potasio (K) y el rendimiento esperado (RE), el cumplimiento de estos objetivos se logró llevar a cabo, al obtener resultados favorables en las predicciones generadas por los modelos de redes neuronales, esto gracias a que los valores predichos fueron muy cercanos a la realidad, donde el dato más alejado para nitrógeno fue de 2.8766 kg/Ha, para fosforo de 3.7274 Kg/Ha, potasio 4.276 Kg/Ha; y para rendimiento esperado de 0.3445. Esta discrepancia entre datos reales y predichos, no tuvo mucha variación al contar con coeficientes de determinación entre 0.90-0.99, lo cual nos ayuda a validar lo anterior mencionado sobre la realidad de las predicciones. Se debe tener en cuenta que para que la predicción se acerque lo mejor posible a la realidad, el valor de las variables debe ser lo más certero también, ya que, si se incluyen valores sin determinar o sin validez, puede haber una alteración, por ello es importante conocer muy bien los factores y variables, de cada terreno puesto que no todos los terrenos poseen un suelo con las mismas características.

Del mismo modo se logró determinar aquellas variables de mayor impacto en cada modelo, para el rendimiento esperado se reflejó que el nitrógeno (N), potasio (P) y azufre (S), son los factores que más repercuten en él, por lo que se tiene que tomar mucho en cuenta en el cultivo, ya que estas variables pueden generar alguna alteración en el rendimiento final si no se aportan adecuadamente. En cambio, para el modelo NPK, las variables relativas de mayor impacto fueron potasio (K), fósforo (P), azufre (S), nitrógeno (N) y rendimiento esperado (RE), del mismo modo se le debe dar la importancia que se merecen a estas variables. Para ambos casos las variables de impacto, juegan un papel importante, al ser estas las principales causantes de que se obtenga una alteración en el resultado final.

Concluyendo, se puede hacer mención que ambos modelos NPK y rendimiento esperado, al ser validados mediante las pruebas correspondientes, arrojaron resultados positivos cumpliendo así con sus objetivos principales de lograr predecir las salidas correspondientes para cada modelo y obtener las variables de mayor impacto o relevancia. A base de lo redactado con anterioridad, se puede hacer mención que se acepta la hipótesis de la investigación H1, la cual establece que la elaboración de modelos, a base de redes neuronales para la predicción de los valores NPK y rendimiento esperado del maíz, funcionan correctamente y logran estimar datos cercanos a la realidad; por lo tanto, se rechaza H0 que menciona lo contrario.

Con estas respuestas positivas del estudio, se puede hacer un análisis previo junto con los agricultores interesados para apoyararlos en esa decisión de si realmente aplicar fertilizantes a base de nitrógeno, fósforo y potasio, los cuales son los nutrientes más esenciales para el buen crecimiento y desarrollo del cultivo; dicho apoyo se basaría al presentar un pronóstico predicho mediante los modelos elaborados, a modo que se pueda analizar qué cantidad de fertilizantes es la necesaria, de acuerdo a las características del suelo y otras variables influyentes en el mismo; este apoyo puede generar el interés del agricultor al tener un panorama más amplio sobre posibles resultados, lo cual incitaría un poco más, a pensar que decisión sería la correcta si fertilizar con ciertas dosis o no, con ello a su vez traería el beneficio de solo invertir el capital necesario para adquirir fertilizante, evitando que se genere un desperdicio monetario y de aplicación del fertilizante.

REFERENCIAS BIBLIOGRÁFICAS.

- Adisa, O. M., Botai, J. O., Adeola, A. M., Hassen, A., Botai, C. M., Darkey, D., & Tesfamariam, E. (2019). Aplicación de una red neuronal artificial para predecir la producción de maíz en Sudáfrica. *Sostenibilidad*, 1145.
- Álvarez, R., & Steinbach, H. S. (2011). Modelado de mineralización aparente de nitrógeno en campo. *Revista de agronomía*, 1159-1168.
- Arriaga, J. (abril de 2015). *Modelado, simulación y control del uso del agua en la agricultura*.
- Cárdenas Navarro, R., Sánchez Yáñez, J., Farías Rodríguez, R., & PeñaCabriales, J. (s.f.). Los aportes de nitrógeno en la agricultura. México, Michoacan, México.
- Casas, J., Repullo, J., & Donado, J. (2003). La encuesta como técnica de investigación. Elaboración de cuestionarios y tratamiento estadístico de los datos (I). *Atención primaria*, 527-538.
- Diana. (15 de Abril de 2014). *Redes Neuronales Artificiales*. Obtenido de <https://speakerdeck.com/diana2014/si2>
- DÍAZ ROMERO , E. E. (Abril de 2018). *Compatibilidad del Control Químico y Biológico sobre Larvas de Spodoptera frugiperda (J. E. Smith) Bajo Condiciones de Laboratorio*. Obtenido de <http://repositorio.uaaan.mx:8080/bitstream/handle/123456789/45105/K%2065430%20D%C3%ADaz%20Romero%2C%20Eder%20Eduardo.pdf?sequence=1&isAllowed=y>
- Dong, Y., Fu, Z., Peng, Y., Zheng, Y., Yan, H., & Li, X. (2020). Método de fertilización de precisión de cultivos extensivos basado en la red neuronal Wavelet-BP en China. *Diario de Producción más Limpia*, 246.
- Farjam, A., Omid, M., Akram, A., & Fazel Niari, Z. (2014). Un modelo basado en redes neuronales y un análisis de sensibilidad de las entradas de energía para predecir los rendimientos de semillas y granos de maíz. *Revista de Ciencia y Tecnología Agrícolas*, 767-778.
- Folgueiras Bertomeu. (30 de mayo de 2016). *La entrevista*. Obtenido de <http://diposit.ub.edu/dspace/handle/2445/99003>

- Gaitan, C., Hsieh, W., & Cannon, A. (2014). Pronóstico de rendimiento de maíz por regresión lineal y redes neuronales artificiales en. *Ciencias agrícolas*, 2-17.
- García, E., & Flego, F. (2008). Agricultura de precisión. *García, E., & Flego, F. (2008). Agricultura de precisión. Revista Ciencia y Tecnología*, 8, 99-116., 99-116.
- González, J. (20 de mayo de 2016). Redes neuronales-Feed forward. *Universidad Bicenteneria de Aragua, 1 Edición* , 3-10. Recuperado el diciembre de 2022
- Google Earth. (Noviembre de 2022). Obtenido de <https://www.google.com/intl/es-419/earth/>
- Helong, Y., Dayou, L., & Guifen, C. (2010). A neural network ensemble method for precision fertilization modeling. *ELSEVIER*, 1-8.
- Gruposacsa. (03 de septiembre de 2019). *GUSANO COGOLLERO (Spodoptera frugiperda)*. Obtenido de <https://www.gruposacsa.com.mx/gusano-cogollero-spodoptera-frugiperda/>
- IFA. (2022). En *Los fertilizantes y su uso* (págs. 3-9).
- INEGI. (2021). *Población total Álamo Temapache*. Obtenido de Banco de indicadores: <https://www.inegi.org.mx/app/indicadores/?t=268&ag=30#D268#D1002000001>
- Jiménez Martínez, E., Sandino Díaz, V., & Valle Gómez, N. (2016). En E. Jiménez Martínez, V. Sandino Díaz, & N. Valle Gomez, *Plagas de cultivos* (págs. 7-20). Managua, Nicaragua.
- Jiménez Pedroza , S. C. (13 de octubre de 2022). *¿Híbrido o criollo? Descubre las diferencias entre estos maíces*. Obtenido de [gourmetdemexico.com.mx: https://gourmetdemexico.com.mx/gourmet/cultura/hibrido-o-criollo-descubre-las-diferencias-entre-estos-maices/](https://gourmetdemexico.com.mx/gourmet/cultura/hibrido-o-criollo-descubre-las-diferencias-entre-estos-maices/)
- Lagunas, C. (2014). *Correlación y regresión lineal*.
- Larriva, N. (2003). Síntesis de la importancia del potasio en el suelo y plantas. *La granja*, 23.
- Liu, J., Goering, C., & Tian, L. (2001). *Una red neuronal para establecer objetivos de rendimiento de maíz*. Obtenido de Transacciones de la ASAE .
- Lykhovyd, P. (2018). *CEEOL*. Obtenido de <https://www.ceeol.com/search/article-detail?id=638297>
- MacAllen , M. (06 de Noviembre de 2020). *Hongos, lo mejor para el control de la arriera*. Obtenido de <https://www.univalle.edu.co/lo-que-pasa-en-la-u/hongos-lo-mejor-para-el-control-de-la-arriera>

- Maozhun, S., & Ji, L. (2017). Algoritmo de Garson mejorado basado en el modelo de red neuronal. *Universidad de Ciencia y Tecnología de China Oriental, Shanghai*, 4308.
- Math Net. (2022). *Correlación*. Obtenido de <https://www.math.net/correlation>
- Matich, D. J. (Marzo de 2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. . Obtenido de Universidad Tecnológica Nacional.
- Matlab. (2014).
- MATLAB. (2022). *Creación de apps con interfaces gráficas de usuario en MATLAB*. Obtenido de <https://es.mathworks.com/discovery/matlab-gui.html>
- Miao, Y., Mulla, D. J., & Robert, P. C. (2006). Identificar factores importantes que influyen en el rendimiento del maíz y la variabilidad de la calidad del grano utilizando redes neuronales artificiales. *Agricultura de Precisión*, 117-135.
- Microsoft. (2022). *Conceptos básicos sobre bases de datos*. Obtenido de <https://support.microsoft.com/>: <https://support.microsoft.com>
- Osorio, N. (2012). pH del suelo y disponibilidad de nutrientes. *Manejo Integral del Suelo y Nutrición Vegetal, Vol. 1 No. 4*, 1-4.
- Oxford Languages . (s/a). *Zona*. Obtenido de <https://languages.oup.com/google-dictionary-es/>
- Pérez Soto, F., Figueroa Hernández, E., Godínez Montoya, L., & Pérez Figueroa, R. A. (2019). *Integración económica y rentabilidad en la agricultura*.
- Pokrajac, D., & Obradovic, Z. (2001). Neural Network-Based Software for Fertilizer Optimization in. *Conferencia Internacional Conjunta sobre Redes Neuronales. Procedimientos*, 2110-2115.
- Radio Sur. (02 de Octubre de 2022). *Seremi de Agricultura iniciará la entrega de más de 6 mil sacos de urea a agricultores de la región de Los Ríos*. Obtenido de <https://pautalosrios.cl/seremi-de-agricultura-iniciara-la-entrega-de-mas-de-6-mil-sacos-de-urea-a-agricultores-de-la-region-de-los-rios/>
- Revista agropecuaria. (06 de noviembre de 2017). Ventajas de la fertilización con calcio en cultivos.
- Reyes, C. (20 de Abril de 2015). *Gusano falso medidor - Trichoplusia ni*. Obtenido de <https://panorama-agro.com/?p=1709>

- Reyes, J., & Cisneros, F. (diciembre de 2014). Redes Neuronales Artificiales (RNA) aplicadas en la predicción de caudales para intervalos de tiempo horarios. *Revista Tecnológica ESPOL.* , Vol.27, 37-49. Recuperado el diciembre de 2022
- Santillán, O., & Rentería, M. (2018). Agricultura de precisión. *INCYTU*, 1-5.
- Scielo. (29 de agosto de 2017). *Persistencia y normalización de los datos dominaron la agenda del III Curso de Actualización SciELO-ScholarOne*. Obtenido de scielo.org: <https://blog.scielo.org/es/2017/08/29/persistencia-y-normalizacion-de-los-datos-dominaron-la-agenda-del-iii-curso-de-actualizacion-scielo>
- SEPI. (24 de Abril de 2017). *Sederec fomenta preservación de la semilla originaria de maíz criollo*. Obtenido de <https://www.sepi.cdmx.gob.mx/comunicacion/nota/sederec-fomenta-preservacion-de-la-semilla-originaria-de-maiz-criollo>
- Singh, R. K. (2008). Metodología de redes neuronales artificiales para modelar y pronosticar el rendimiento del cultivo de maíz. *Agricultural Economics*, 5-10.
- The MathWorks, Inc. (1994-2022). *Introducción a Matlab*. Obtenido de es.mathworks.com: <https://es.mathworks.com/products/matlab.html>
- Toapanta, J. (mayo de 2019). *Estimación del rendimiento por hectárea de maíz duro seco en el ecuador mediante redes neuronales*.
- Wang, F., Dong, Z., Wu, Z., & Fang, K. (2017). Optimización de la densidad de siembra de maíz y la aplicación de fertilizantes basada en la red neuronal BP. *Transacciones de la Sociedad China de Ingeniería Agrícola.* , 33.
- Yang. (30 de junio de 2000). *Aplicación de redes neuronales artificiales en reconocimiento*.
- Yu, H., Liu, D., Chen, G., Wan, B., Wang, S., & Yang, B. (2010). Un método de conjunto de redes neuronales para el modelado de fertilización de precisión. *Modelado matemático y por computadora*, 1375-1382.
- Yuhong, D., Zetian, F., Yaoqi, P., Yongjun, Z., Haijun, Y., & Xinxing, L. (2019). Precision fertilization method of field crops based on the Wavelet-BP neural network in China. *Journal of Cleaner Production*.
- Zerecero, O. (Noviembre de 2017). *Análisis del comportamiento del precio del maíz utilizando un modelo de redes neuronales artificiales*.

ANEXOS.

ANEXO 1.

Instituto Tecnológico Superior de Álamo Temapache – Campo agrícola

“Inventarió de datos del cultivo de maíz”

“PROPIEDADES FÍSICAS Y CLIMATOLÓGICAS.”

1) De acuerdo a las temporadas de lluvia, riego del terreno y etc. ¿Cómo considera que es el drenaje externo del suelo?

a) Bueno b) Moderado c) Malo

2) Y ¿el drenaje interno del suelo?

Bueno b) Moderado c) Malo

3) ¿Cómo considere el índice de sequía del terreno en estos últimos años?

a) Leve b) Moderada c) Muy fuerte

4) ¿Que profundidad llega a tener la raíz del maíz, con base a su experiencia?

5) ¿Cómo definiría la textura que tiene el suelo de su terreno?

a) Franco arcilloso b) Arcilloso c) Franco arenoso.

6) ¿Qué niveles de pH presentan sus suelos?

7) ¿Aproximadamente con cuantas hectáreas cuenta para la siembra de maíz?

“PROPIEDADES QUÍMICAS Y PLAGAS.”

1) Utiliza algún tipo de fertilizante en el terreno; para un mayor desarrollo de los cultivos agrícolas. *Si su respuesta es sí*, explique qué tipo de fertilizante utiliza:

2) ¿Aproximadamente cuál es el precio del fertilizante que utiliza?

- 3) ¿Cada cuánto tiempo y en qué cantidad (Costal / hectárea, kilos /hectárea o etc.); aplica fertilizante en el terreno?
- 4) ¿El fertilizante es aplicado manualmente, con alguna maquina o herramienta? ¿Si se aplica con máquina, cuantos litros por hectárea consume de combustible la maquina?
- 5) ¿Cuenta con sistema de riego? *Si su respuesta es sí.* ¿Cuántos litros ocupa para ese sistema de riego y cada cuanto es aplicable?
- 6) ¿Actualmente tiene un control de nutrientes de los cultivos?
- 7) Aplica algún control contra plagas. *Si la respuesta es sí.* ¿Qué plaguicidas o pesticidas usa, en qué cantidad y cada cuánto tiempo?
- 8) Además de los plaguicidas. ¿Utiliza algún otro agroquímico (por ejemplo: rodenticidas, ¿herbicidas o etc.)?
- 9) ¿Qué tipo de plagas son comunes en su cultivo?
- 10) ¿Utiliza algún método natural para controlar la plaga o hierba?

“RENDIMIENTO”

- 1) ¿Cada cuánto tiempo siembre maíz?
- 2) ¿Cuánta producción de maíz obtiene al final de la cosecha (toneladas/ hectárea o etc.)?
- 3) ¿Aproximadamente en cuanto vende el producto final y cada cuanto lo hace?

4) Para la recolección de la cosecha final ¿Se lleva a cabo manualmente o utiliza alguna maquinaria?

5) ¿Cuánto desperdicio se genera al levantar la cosecha del cultivo?

6) ¿Tiene alguna utilidad el desperdicio generado?

7) ¿En cuánto se reduce el rendimiento si le cae la plaga?