

INSTITUTO POLITÉCNICO NACIONAL

**CENTRO INTERDISCIPLINARIO DE INVESTIGACIÓN
PARA EL DESARROLLO INTEGRAL REGIONAL**

**DETERMINACIÓN DE LOS PARÁMETROS RACIONALES
ÓPTIMOS DE DISEÑO DE UNA DESFIBRADORA DE HOJAS DE
AGAVE *ANGUSTIFOLIA* HAW EMPLEANDO REDES
NEURONALES ARTIFICIALES.**

**TESIS
QUE PARA OBTENER EL GRADO DE:
DOCTOR EN CIENCIAS EN LA ESPECIALIDAD DE CONSERVACIÓN Y
APROVECHAMIENTO DE RECURSOS NATURALES**

**PRESENTA:
M. EN C. RAUDEL PÉREZ DEL RÍO**

**DIRECTOR: DR. MAGDALENO CABALLERO CABALLERO
DIRECTOR: DR. LUÍS HÉCTOR HERNÁNDEZ GÓMEZ**

Oaxaca. México Diciembre 2013



INSTITUTO POLITÉCNICO NACIONAL

SECRETARÍA DE INVESTIGACION Y POSGRADO

ACTA DE REVISION DE TESIS

En la Ciudad de Oaxaca de Juárez siendo las 13:00 horas del día 29 del mes de noviembre del 2013 se reunieron los miembros de la Comisión Revisora de Tesis designada por el Colegio de Profesores de Estudios de Posgrado e Investigación del **Centro Interdisciplinario de Investigación para el Desarrollo Integral Regional, Unidad Oaxaca (CIIDIR-OAXACA)** para examinar la tesis de grado titulada: "Determinación de los parámetros racionales óptimos de diseño de una desfibradora de hojas de *Agave angustifolia* Haw empleando redes neuronales artificiales."

Presentada por el alumno:

Pérez

Apellido paterno

Del Río

materno

Raudel

nombre(s)

Con registro:

A	1	0	0	6	6	4
---	---	---	---	---	---	---

aspirante al grado de: **DOCTOR EN CIENCIAS EN CONSERVACIÓN Y APROVECHAMIENTO DE RECURSOS NATURALES**

Después de intercambiar opiniones los miembros de la Comisión manifestaron **SU APROBACIÓN DE LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

LA COMISIÓN REVISORA


Directores de tesis




Dr. Magdalena Caballero
Caballero



Dr. Luis Héctor Hernández Gómez



Dr. Guillermo Manuel Urriolagoitia
Calderón



Dr. Francisco Castellanos León



Dr. Prisciliano Felipe de Jesús Cano
Barrita



PRESIDENTE DEL COLEGIO DE PROFESORES

Dr. Rafael Pérez Pacheco



CENTRO INTERDISCIPLINARIO
DE INVESTIGACION PARA EL
DESARROLLO INTEGRAL REGIONAL
C.I.I.D.I.R.
UNIDAD OAXACA
I.P.N.



INSTITUTO POLITÉCNICO NACIONAL
SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

CARTA CESION DE DERECHOS

En la Ciudad de Oaxaca de Juárez el día 29 del mes noviembre del año 2013, el (la) que suscribe Pérez Del Río Raudel alumno (a) del Programa de **DOCTORADO EN CIENCIAS EN CONSERVACIÓN Y APROVECHAMIENTO DE RECURSOS NATURALES** con número de registro A100664, adscrito al Centro Interdisciplinario de Investigación para el Desarrollo Integral Regional, Unidad Oaxaca, manifiesta que es autor (a) intelectual del presente trabajo de Tesis bajo la dirección de los Dres. Magdaleno Caballero Caballero y Luis Héctor Hernández Gómez y cede los derechos del trabajo titulado: "Determinación de los parámetros racionales óptimos de diseño de una desfibradora de hojas de *Agave angustifolia* Haw empleando redes neuronales artificiales.". Al Instituto Politécnico Nacional para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, gráficas o datos del trabajo sin el permiso expreso del autor y/o director del trabajo. Este puede ser obtenido escribiendo a la siguiente dirección **Calle Hornos 1003, Santa Cruz Xoxocotlán, Oaxaca**, e-mail: posgradoax@ipn.mx ó raudelrio@gmail.com, Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.

Pérez Del Río Raudel



CENTRO INTERDISCIPLINARIO
DE INVESTIGACION PARA EL
DESARROLLO INTEGRAL REGIONAL
C.I.I.D.I.R.
UNIDAD OAXACA
I.P.N.

Dedicatoria.

A mis padres, Idalmis del Río Batista y Raúl Antolín Pérez Mariño, a mi hermano Raúl

Pérez del Río, por el apoyo, y fe en mí.

A mis amigos y amigas...

Agradecimientos

Al Instituto Politécnico Nacional

Centro Interdisciplinario De Investigación Para El Desarrollo Integral Regional

Consejo Nacional de Ciencia y Tecnología

A mis asesores.

Dr. Magdaleno Caballero Caballero

Dr. Luis Héctor Hernández Gómez

Dr. Guillermo MAMEL Urriola Goitia Calderón

Dr. Juan Alejandro Vázquez Feijoo

Dr. Francisco Castellanos León

ÍNDICE GENERAL.

ÍNDICE GENERAL.....	ii
ÍNDICE DE FIGURAS.....	viii
ÍNDICE DE TABLAS.....	xii
SIMBOLOGÍA.....	xiii
OBJETIVOS.....	xv
JUSTIFICACIÓN.....	xvi
Problemática.....	xvii
Hipótesis general.....	xix
Tareas.....	xix
Aporte teórico.....	xx
Aporte práctico.....	xx
Límites de la investigación.....	xx
Acotaciones del trabajo desarrollado.....	xx
RESUMEN.....	xxii
SUMMARY.....	xxiii
INTRODUCCIÓN.....	1
I. ESTADO ACTUAL DEL ARTE Y ANTECEDENTES DE LA INVESTIGACIÓN.....	3
1.1. Generalidades.....	3
1.1.1. Proceso de extracción de fibras del <i>Agave angustifolia</i> Haw en el Estado de Oaxaca. .	3
1.1.2. Particularidades constructivas de las máquinas desfibradoras.....	4

1.1.3.	Características del proceso de desfibrado mecánico.....	10
1.2.	Proceso de diseño de máquinas desfibradoras.....	10
1.2.1.	Especificaciones de desempeño de la desfibradora.....	10
1.2.2.	Generación de conceptos para el diseño de la desfibradora.....	11
1.2.3.	Métodos interactivos para la determinación de los parámetros de diseño.....	11
1.3.	Redes neuronales artificiales y modelado de procesos mecánicos.....	14
1.3.1.	Introducción a las redes neuronales.....	14
1.3.2.	Aplicaciones de las redes neuronales en la ingeniería.....	17
1.3.3.	Ventajas y desventajas de los modelos mediante redes neuronales artificiales.....	19
1.4.	Optimización Multiobjetivo.....	20
1.5.	Algoritmos genéticos.....	21
1.5.1.	Optimización multiobjetivo con algoritmos genéticos.....	23
1.5.2.	Aplicaciones ingenieriles de la optimización multiobjetivo por algoritmo genético...	24
II.	FUNDAMENTOS TEÓRICOS.....	27
2.1.	Proceso de desfibrado de hojas de <i>Agave angustifolia</i> Haw.....	27
2.2.	Teoría del movimiento del órgano desfibrador rotacional de eje horizontal.....	29
2.2.1.	Determinación de la trayectoria de la cuchilla.....	29
2.2.2.	Altura de la contracuchilla:	31
2.2.3.	Potencia requerida en el órgano desfibrador.....	33

2.2.4.	Determinación de esfuerzo de corte parcial durante el desfibrado.	35
2.2.5.	Capacidad de paso del cilindro desfibrador.	36
2.3.	Teoría de cálculo del órgano de alimentación de rodillos lisos rotatorios.	37
2.3.1.	Condición para el agarre de las hojas y determinación de la presión del resorte de los rodillos.	37
III.	MATERIALES Y METODOLOGÍAS DE LAS INVESTIGACIONES EXPERIMENTALES.....	40
	Modelo de Investigación.	40
3.1.	Métodos de experimentales para determinar propiedades de las hojas del <i>Agave angustifolia</i> Haw.	41
3.1.1.	Propiedades físicas de las hojas de <i>Agave angustifolia</i> Haw.	41
3.1.2.	Determinación de la resistencia a la compresión de las hojas de <i>Agave angustifolia</i> Haw y del <i>Agave fourcroydes</i>	42
3.1.3.	Determinación del comportamiento a tracción de las hojas de <i>Agave angustifolia</i> Haw y <i>Agave fourcroydes</i>	44
3.1.4.	Determinación del comportamiento de las hojas de <i>Agave angustifolia</i> Haw al corte por cizallamiento.	46
3.1.5.	Determinación del contenido de humedad de las hojas del Agave.	47
3.2.	Método de diseño para establecer los parámetros de la máquina.	48
3.2.1.	Selección de los mecanismos y componentes.	48

3.2.2.	Estudio morfológico de los elementos.	49
3.2.3.	Selección de sistema de alimentación.	50
3.2.4.	Determinación del consumo de energía durante el proceso de desfibrado.	51
3.2.5.	Determinación de los parámetros cinemáticos del proceso de desfibrado.	51
3.2.6.	Determinación de los parámetros de calidad del desfibrado.	53
3.3.	Método de entrenamiento de la red neuronal para para optimizar el diseño de la desfibradora de hojas de <i>Agave angustifolia</i> Haw.	55
5.4.1.	Selección de los parámetros de la red neuronal.	56
IV.	ANÁLISIS NUMÉRICO.	57
4.1.	Características generales de los perceptrones multicapa.	57
4.1.1.	Funciones de activación.	62
4.1.2.	Entrenamiento de la red neuronal.	65
4.1.3.	Algoritmo de retropropagación.	68
4.1.4.	Otras mejoras en la adaptación de las tasas de aprendizaje	73
4.1.5.	Limitación de la complejidad de la red y determinación del número de capas ocultas. 74	
4.1.6.	Número de neuronas ocultas.	75
4.1.7.	Deterioro de los pesos	75
4.1.8.	Detención temprana.	76

4.2.	Teoría del algoritmo genético.....	76
4.3.1.	Algoritmo genético simple.....	76
4.3.	Formulación matemática de la optimización multiobjetivo.....	81
4.3.1.	Algoritmos de nichos paralelos.....	82
4.3.2.	Algoritmo genético con operador elitista basado en un ordenamiento no-dominado (NSGA-II).....	84
V.	ANÁLISIS Y DISCUSIÓN DE RESULTADOS.....	89
5.1.	Caracterización mecánicas de las hojas del <i>Agave angustifolia</i> Haw y del <i>Agave fourcroydes</i>	89
5.1.1.	Características geométricas de las hojas del <i>Agave angustifolia</i> Haw y el <i>Agave fourcroydes</i>	89
5.1.2.	Características mecánicas de las hojas del <i>Agave angustifolia</i> Haw y el <i>Agave fourcroydes</i>	89
5.2.	Resultados de los cálculos previos para determinar dimensiones iniciales del banco de ensayos.....	94
5.3.	Resultados de la experimentación en el banco de ensayos.....	95
5.3.1.	Resultados de la evaluación energética.....	95
5.3.2.	Resultados de la evaluación de la calidad del desfibrado.....	96
5.3.3.	Relación entre el porcentaje de fibra entera y el porcentaje de limpieza.....	98
5.3.4.	Influencia de las velocidades de entrada y de las hojas en la calidad del desfibrado.....	100

5.3.5.	Influencia de las velocidades de entrada y de las hojas en la seguridad del operario.	101
5.4.	Modelado con la red neuronal.	102
5.4.1.	Entrenamiento de la red neuronal.	102
5.4.2.	Aproximación del modelo a los valores experimentales.	105
5.5.	Optimización mediante algoritmos genéticos.	106
5.6.	Subproductos obtenidos.	109
CONCLUSIONES		110
RECOMENDACIONES		112
BIBLIOGRAFIA		113
ANEXOS		119

ÍNDICE DE FIGURAS.

Figura 1. Limpieza de la hoja.....	3
Figura 2. Máquina desfibadora de <i>Agave lechuguilla</i> Torey marca “Cardoma”.....	4
Figura 3. Desfibadora tradicional.	5
Figura 4. Máquina desfibadora con avance perpendicular de la hoja en dos tiempos.....	7
Figura 5. Máquina desfibadora con doble tambor desfibador.	7
Figura 6. Desfibadora de avance lineal continuo.....	8
Figura 7. Separador de fibras y material de desecho.....	8
Figura 8. Máquina desfibadora de Sisal “Faustino 5”	9
Figura 9. Red neuronal con tres capas.....	15
Figura 10. Métodos de optimización.....	21
Figura 11. Estructura de la máquina desfibadora diseñada.....	27
Figura 12. Partes del órgano desfibador.	28
Figura 13. Esquema del proceso de desfibrado, variables geométricas.	30
Figura 14. Distancia entre dos cicloides consecutivas.	31
Figura 15. Interacción de las cuchillas con la hoja de agave durante el proceso de desfibrado.	32
Figura 16. Esfuerzos de corte aplicados a la hoja de agave.	35
Figura 17. Esquema de compresión de las hojas de agave por los rodillos alimentadores.	37
Figura 18. Esquema de la hoja de <i>Agave angustifolia</i> Haw.....	41

Figura 19. Corte de las probetas.....	43
Figura 20. Máquina para ensayos estáticos Shimadzu modelo Autograph AGS-J.....	44
Figura 21. Mediciones de las probetas.....	44
Figura 22. Máquina para ensayos Instron-3365.....	45
Figura 23. Herramienta para determinar la resistencia al corte por cizallamiento.....	47
Figura 24. Diagrama de funciones para una máquina desfibradora.....	49
Figura 25. Ajuste de la holgura de desfibrado.....	53
Figura 26. Preparación de las hojas de agave. a) Corte del excedente de la punta de la hoja. b) División longitudinal de la hoja.....	54
Figura 27. Variables geométricas y físicas del proceso de desfibrado.....	55
Figura 28. Estructura típica de un perceptrón multicapa.....	59
Figura 29. Procesamiento de la información que realiza la neurona número i en la capa de neuronas número l de un perceptrón multicapas.....	60
Figura 30. Función sigmoidea.....	63
Figura 31. Pesos entre las entradas (inputs) y las capas ocultas (I-H).....	71
Figura 32. Curva de impulso.....	72
Figura 33. Curva de impulso sobre la superficie de error.....	72
Figura 34. Perceptrón multicapas de dos capas (Duda <i>et al.</i> , 2001).....	74
Figura 35. Perceptrón multicapas de dos, tres y cuatro capas (Bishop, 1995).....	75

Figura 36. Distancia de apilamiento para alternativa de solución <i>Xi</i> .	86
Figura 37. Determinación de la nueva Población.	87
Figura 38. Comportamiento a compresión paralela a la fibra.	91
Figura 39. Comportamiento a compresión perpendicular a la fibra.	91
Figura 40. Comportamiento a tracción longitudinal a la fibra.	92
Figura 41. Comportamiento a tracción perpendicular a la fibra.	93
Figura 42. Comportamiento a cizallamiento longitudinal.	93
Figura 43. Comportamiento a cizallamiento Transversal.	94
Figura 44. Relación energía-velocidad del material desfibrado. a) energía de entrada-velocidad de alimentación. b) energía de salida-velocidad de salida.	96
Figura 45. Calidad del desfibrado. a) Comportamiento de la limpieza respecto a la holgura de desfibrado. b) Comportamiento de la cantidad de fibras enteras respecto a la holgura de desfibrado.	97
Figura 46. Fibras con diferente porcentaje de residuos.	98
Figura 47. Calidad del desfibrado.	99
Figura 48. Influencia de la velocidad de entrada y salida de las hojas en la calidad del desfibrado. a) Influencia en el % de fibras enteras. b) Influencias en la limpieza de las fibras.	101
Figura 49. Desempeño de la red neuronal.	103
Figura 50. Fibras rotas.	105
Figura 51. Residuos.	106

Figura 52. Frente de Pareto.....	107
Figura 53. Resíduos no fibrosos.....	109

ÍNDICE DE TABLAS.

Tabla 1. Parámetros de tanteo para el entrenamiento.....	56
Tabla 2. Características de las hojas del <i>Agave angustifolia</i> Haw y <i>Agave fourcroydes</i>	89
Tabla 3. Propiedades mecánicas de las hojas.....	90
Tabla 4. Estimados de calidad del proceso de desfibrado.....	100
Tabla 5. Soluciones de Pareto.....	108

SIMBOLOGÍA.

RNA	Redes neuronales artificiales.
AG	Algoritmo genético.
x	vector formado por las entradas externas o estímulos a la RNA
n	vector formado por las salidas de las neuronas de salida de la RNA
w	vector formado por todos los pesos de la RNA,
PMC	Perceptrón multicapa.
W	Conjunto de todos los pesos en el PMC
pi	Población inicial
w	Grado de adaptación para la probabilidad de cruce
P_c	Probabilidad de cruce
P_m	Probabilidad de mutación
V_a	Velocidad de alimentación.
ω	Velocidad angular del rotor del órgano desfibrador.
R	Radio del extremo de las cuchillas, m ;
Z	Número de cuchillas
$S_{(x)}$	Longitud de acción de la cuchilla.
V_c	Velocidad de corte.

Δh	Disposición de la contracuchilla.
γ	Peso de la hoja por unidad de longitud.
b	Ancho de la hoja que coincide con el ancho de corte.
ε	Energía de corte de la sección transversal de la hoja.
δ	Espesor del filo de la cuchilla.
σ_B	Resistencia del material bajo el filo de la cuchilla.
β	Ángulo del filo de la cuchilla, grados.
ν	Relación de Poisson.
$\mu = \tan\varphi$	Coefficiente de fricción.
\emptyset	Ángulo de fricción entre el material de los rodillos y las hojas de agave.

OBJETIVOS.

Objetivo general.

Desarrollar un modelo mediante el método de redes neuronales artificiales de conjunto con un algoritmo genético que permita búsqueda de los parámetros de diseño óptimos de los órganos de trabajo que se emplean en el proceso de desfibrado de las hojas verdes de *Agave angustifolia* Haw.

Objetivos específicos.

1. Caracterizar física y mecánicamente las hojas de *Agave angustifolia* Haw y las hojas del *Agave fourcroydes*
2. Desarrollar una desfibradora de laboratorio para la investigación de los parámetros que definen la calidad del desfibrado de las hojas verdes de *Agave angustifolia* Haw.
3. Determinar de forma experimental los parámetros que definen la calidad del desfibrado de las hojas verdes de *Agave angustifolia* Haw y los parámetros que caracterizan el funcionamiento de la maqueta experimental.
4. Desarrollar un modelo mediante el empleo de redes neuronales para correlacionar la calidad del proceso de desfibrado de hojas verdes de *Agave angustifolia* Haw con los parámetros de diseño de la máquina desfibradora experimental.
5. Determinar los parámetros de diseño óptimos de los órganos de trabajo de una desfibradora de hojas verdes de *Agave angustifolia* Haw mediante el método de optimización multiobjetivo basados en algoritmos genéticos.

JUSTIFICACIÓN.

En México, de las 273 especies de plantas de la familia de las agaváceas se encuentran 205, de las cuales 151 son endémicas. Los estados con mayores especies son Oaxaca, Chihuahua, Sonora, Coahuila, Durango y Jalisco (Ramírez, 1995). El estado de Oaxaca en el años 2012 contaba con unas 10,288.75 hectáreas dedicadas al cultivo del agave y una producción de 178396.56 toneladas de las piñas cosechadas en 2917.38 hectáreas, dichas piñas son dedicadas a la industria mezcalera y tequilera (SAGARPA, 2012).

En la fabricación del mezcal y tequila solamente se emplean las piñas, que están compuestas por la base de las hojas y por el tallo, mientras las hojas se desechan, así se deja de aprovechar el 45% en peso aproximadamente del agave. Las hojas, que en su conjunto representan el 55% del peso del agave, son abandonadas en el campo a cielo abierto, contaminando el medio ambiente debido a la forma inapropiada a que son expuestas para su degradación (Caballero *et al.*, 2008).

Las fibras de hojas de Agaves son utilizadas en México miles de años antes de la llegada de los españoles, y en la actualidad son un producto que puede ser utilizado en la producción de medios de consumo para la sociedad sobre todo por sus probadas propiedades mecánicas (Silva Santos *et al.*, 2009). Para disponer de dichas fibras se hace necesario efectuar el proceso de desfibrado de hojas de agave una tarea que hasta el momento se ha efectuado de forma artesanal, por el método conocido como enriado (Caballero *et al.*, 2008). Proponer soluciones a los problemas de conservación y aprovechamiento de los recursos naturales y de uso de tecnologías sustentables, que contribuyan al desarrollo integral de la Región Sur-Sureste de México es la misión fundamental del Centro Interdisciplinario de Investigación para el Desarrollo Integral Regional Unidad Oaxaca (CIIDIR-Oaxaca). Por lo que no se trata solamente de provechar el recurso en sí, si no, hacerlo de la forma más sustentable. El desarrollo de máquinas desfibradoras no cuenta con un proceso de diseño que esté fundamentado en la teoría del desfibrado y que tome en cuenta los principales parámetros que influyen en la interacción del órgano de trabajo con la hoja y lleve a establecer los valores óptimos en el diseño de este tipo de máquinas.

La experiencia ha demostrado que para un proceso de desfibrado se necesita una tecnología que garantice rendimiento y eficiencia, por lo que desde principios del siglo pasado se vienen desarrollando máquinas desfibradoras con este objetivo (Trujillo, 1944). No obstante, el proceso de selección de parámetros óptimos de diseño en una máquina desfibradora de hojas de *Agave* es una labor que resulta compleja de solucionar (Rössel Kipping *et al.*, 2003).

Existen experiencias que han posibilitado el desarrollo de máquinas para el desfibrado de agaves productores de fibras de características similares, aunque no iguales, al *Agave angustifolia* Haw. Ya en Mérida aparece el primer prototipo de máquina para el desfibrado de hojas de *Agave fourcroydes* (Pateullo, 1861) y la invención de una máquina que realice todo el proceso (Lambert, 1921).

Pero a pesar de estos desarrollos previos de máquinas desfibradoras para otros tipos de agaves, no se cuenta con un modelo analítico de cálculo, que permita diseñar de forma óptima una desfibradora de *Agave angustifolia* Haw. Tampoco se cuenta con modelos que puedan relacionar de forma matemática los parámetros de diseño con los parámetros que indican la calidad del proceso de desfibrado, sin primeramente, no determinar con exactitud las características mecánicas de las hojas y luego desarrollar un modelo que se aproxime a esta solución.

Por lo que con este proyecto se pretende, fundamentalmente demostrar, lo factible del empleo de las redes neuronales en combinación con los algoritmos genéticos para optimizar problemas complejos multiobjetivos. Poniendo en práctica este método acercaremos más a los investigadores a sistemas de inteligencia artificial y métodos evolutivos en que en el futuro serán empleados con mayor frecuencia en la solución de un número de problemas cada vez mayor.

Problemática.

Se puede plantear que para el diseño de máquinas desfibradoras de hojas de *Agave angustifolia* Haw se requiere primeramente, desarrollar modelos matemáticos que se aproximen a la descripción del problema

físico real del desfibrado de hojas de *Agave angustifolia* Haw, incluyendo todas las especificaciones de diseño y de solución a cada una de las variables que entran en juego.

Por este motivo, se vuelve complejo el proceso de diseño al no conocer el comportamiento de las variables, ni tampoco en ocasiones tener el modelo del proceso a analizar (Pérez de Corcho-Fuentes y Garbati-Pegna, 2008).

El empleo de modelos analíticos para la determinación de parámetros de diseño ha sido una técnica muy utilizada y muy complicada de tratar en algunas ocasiones. Sin embargo, determinar los valores óptimos de los parámetros de diseño puede requerir un tiempo de cálculo y análisis excesivo por dos razones: el número de combinaciones posibles puede ser muy alto; por otra parte, habitualmente, no se puede obtener la función objetivo, en función de los parámetros de entrada (Havel *et al.*, 1998).

Por otra parte las redes neuronales artificiales han demostrado ser capaces de modelar y solucionar problemas complejos con mayor facilidad (Cid Álvarez, 2007). También ya se cuenta con algoritmos evolutivos como los algoritmos genético que puede solucionar más rápido y mejor problemas de optimización multiobjetivo (Poloni *et al.*, 2000). Entonces para diseñar una máquina desfibradora óptima solo sería necesario determinar de forma experimental el comportamiento de los índices de consumo de la máquina, así como sus regulaciones y ajustes, con la calidad del proceso de desfibrado determinado a partir de establecer parámetros cuantitativos luego de ser obtenidas, como pueden ser la cantidad de residuos y el porcentaje de fibras rotas.

La optimización en el diseño es el arte y la ciencia de la asignación de los menores recursos para el mejor efecto posible (Smith *et al.*, 2012). Consecuentemente nuevas técnicas de optimización están llegando a diario, a menudo estimuladas por una visión fascinante de otros campos. Los algoritmos genéticos, por ejemplo, utilizar una analogía a la codificación de los cromosomas y la selección natural para desarrollar una buena solución optimizada. Por otra parte, las redes neuronales artificiales, poseen ciertas características de su arquitectura y la forma en que procesan la información que las hacen superiores a las técnicas convencionales de cierta clase de problemas de optimización. Clasificación de patrones es un dominio, en el

que las redes neuronales han demostrado mejores resultados que los métodos convencionales de programación lineal (Cid Álvarez, 2007). Después del anterior análisis nos damos cuenta que el método de diseño tradicional no soluciona el problema de un diseño óptimo de una máquina desfibadora de hojas de *Agave angustifolia* Haw, o al menos sin dejar de hacer un número elevado de experimentos para poder obtener variables de comportamiento del material, que a su vez implicaría la construcción de un dispositivo de desfibrado similar al que se pretende emplear. Por tanto, se puede plantear que existe la necesidad de optimizar el diseño de una máquina desfibadora de hojas verdes de *Agave angustifolia* Haw para un funcionamiento más eficiente y adecuado a los productores oaxaqueños a partir de la evaluación con una red neuronal del comportamiento calidad del desfibrado y los parámetros de diseño de la máquina desfibadora.

Hipótesis general.

El desarrollo de un modelo mediante el método de redes neuronales artificiales de conjunto con un algoritmo genético permitirá la búsqueda de los parámetros de diseño óptimos de los órganos de trabajo que se emplea en el desfibrado de las hojas verdes de *Agave angustifolia* Haw.

Tareas.

1. Caracterización de las diferentes máquinas desfibadoras que se emplean en extracción de fibras de plantas similares al *Agave angustifolia* Haw para tener en cuenta ventajas y desventajas.
2. Diseño a detalle del prototipo de máquina desfibadora de hojas de *Agave angustifolia* Haw.
3. Diseño de experimentos para determinar las propiedades de las hojas de *Agave angustifolia* Haw.
4. Modelación mediante una red neuronal de los parámetros de diseños de la máquina desfibadora.

5. Optimización multiobjetivo mediante algoritmos genético de los parámetros del proceso de desfibrado de hojas de *Agave angustifolia* Haw modelados mediante una red neuronal artificial.

Aporte teórico.

1. Comportamiento al corte por cizallamiento de las hojas del *Agave angustifolia* Haw.
2. Modelo teórico que describe la trayectoria del filo de las cuchillas del órgano desfibrador.
3. Modelo teórico para determinar la potencia necesaria y la energía consumida durante el proceso de desfibrado.
4. Desarrollo de una red neuronal para la relación de parámetros de diseño y calidad de desfibrado de hojas verdes de *Agave angustifolia* Haw.

Aporte práctico.

Determinación de los parámetros racionales óptimos de diseño de los órganos de trabajo de una desfibradora de hoja de *Agave angustifolia* Haw.

Límites de la investigación.

El trabajo de investigación parte del estudio del proceso de desfibrado de hojas de *Agave angustifolia* Haw y enfocado en las necesidades de los productores del estado de Oaxaca, México. Para analizar la relación entre los parámetros de diseño de una máquina desfibradora y la calidad del proceso de desfibrado determinada a partir de limpieza de las fibras y la ruptura de las mismas.

Acotaciones del trabajo desarrollado

1. Se consideran como clientes potenciales los productores de *Agave angustifolia* Haw del estado de Oaxaca.

2. Datos obtenidos en hojas de *Agave angustifolia* Haw de la región de Tlacolula, de edades entre 5 y 8 años.
3. Se elaboró un modelo redes neuronales artificiales y la relaciones de variable de entradas y de salidas.
4. Optimización multiobjetivo mediante el método de algoritmos genéticos.

RESUMEN

La presente investigación se ha desarrollado dentro de la línea del aprovechamiento y conservación de los recursos naturales con una visión social, enfocada a aumentar la comercialización de los productos que se pueden obtener a partir de las plantas de agave, disminuir la cantidad de hojas que quedan como desechos después de la cosecha de las piñas y que son consideradas una molestia para las labores de preparación de suelo y desarrollar un proceso de desfibrado mecánico que no contamina el entorno de manera importante. El objetivo de la misma es optimizar los parámetros de diseño que definen la calidad del proceso de desfibrado de hojas verdes de *Agave angustifolia* Haw mediante una red neuronal artificial. Para llegar al objetivo deseado primeramente se realizó la caracterización de las diferentes máquinas desfibradoras que se emplean en extracción de fibras de plantas similares al *Agave angustifolia* Haw para tener en cuenta ventajas y desventajas, luego se efectuó un diseño a detalle del prototipo de máquina desfibradora de hojas de *Agave angustifolia* Haw, más adecuado a los productores del estado de Oaxaca, también se realizaron experimentos para determinar las propiedades de las hojas de *Agave angustifolia* Haw, se utilizó una red neuronal para modelar los parámetros de diseños de la máquina desfibradora y por último, mediante la optimización multiobjetivo empleando algoritmos genético se determinaron los parámetros óptimos de diseño del proceso de desfibrado de hojas de *Agave angustifolia* Haw. El método empleado demostró la factibilidad de realizar la optimización de parámetros de diseño empleando la experimentación para la obtención de datos reales, la modelación mediante métodos de inteligencia artificial y por último la optimización empleando métodos evolutivos.

SUMMARY

This research has been developed into the line of the use and conservation of natural resources with a social vision, focus to increase the marketing of products that can be obtain from agave plants, to decrease the amount of leaves that are as waste after harvest of pineapples and are consider as a problem for soil preparation work and develop a mechanical pulping process does not pollute significantly the environment. The objective of this research is to optimize the design parameters which define the quality of the pulping process of green leaves of *Agave angustifolia* Haw using an artificial neural network. To arrive to the desired objective firstly had been performed the characterization of the different shredders machines used in extraction of fibers plant, similar to *Agave angustifolia* Haw to consider advantages and disadvantages, then carried out a detailed design of the shredder machine prototype leaves of *Agave angustifolia* Haw, more suitable to the producers of the state of Oaxaca, also conducted experiments to determinate the properties of the leaves of *Agave angustifolia* Haw, used a neural network to model the parameters shredder machine designs and finally , with the use of multi-objective optimization and development genetic algorithms parameters of optimum pulping process design of *Agave angustifolia* Haw leaves were determined. The method used showed the viability of performing the optimization of design parameters using experimentation to obtain actual data, modeling through artificial intelligence methods and finally the optimization using evolutionary methods .

INTRODUCCIÓN

Durante más de un siglo en México se han venido desarrollado máquinas desfibradoras o descortezadoras de hojas para varios tipos de agaves, debido a la importancia económica de sus fibras, dentro de estos agaves tenemos al *Agave fourcroydes* y al *Agave lechuguilla* Torrey. En Brasil es otro país donde se han desarrollado un considerable número de prototipos de máquinas desfibradoras, usadas fundamentalmente para la extracción de la fibra del *Agave sisalana*. Cabe señalar que la mayoría de estas máquinas han sido desarrolladas de forma empírica, por productores o inventores, quienes disponen de cierta experiencia que les ha permitido lograr que las mismas funciones adecuadamente.

Aunque se ha demostrado que las fibras del *Agave angustifolia* Haw presentan propiedades que les permiten su uso industrial, (Silva Santos *et al.*, 2009), aun no se comercializan de manera importante y sólo son pequeños productores artesanales que de forma manual elaboran ciertos productos y muchas veces no para el comercio sino para uso propio. Este escaso comercio no ha permitido que con anterioridad se desarrollaran máquinas desfibradoras de hojas para este tipo de agave, pese al gran volumen de fibras que pudiera ser aprovechado.

Para desarrollar una máquina desfibradora de hojas para un tipo de agave cuyo proceso de desfibrado esta insuficientemente estudiado, como es el caso del desfibrado de las hojas del *Agave angustifolia* Haw, lo más lógico sería probar los principios de órganos de trabajo empleados en otros agaves de características similares en cuanto a la estructura de la hoja, sin perder de vista las diferencias existentes en sus propiedades mecánicas.

Varios autores como (Rössel Kipping *et al.*, 2003), (Chen *et al.*, 2004) y (Xu, 2010) abordan la teoría del proceso de desfibrado para determinar el consumo de energía y la potencia requerida.

Pero en la literatura especializada en el tema no aparecen referencias de trabajos que aborden teóricamente las relaciones que existentes entre la calidad del desfibrado y los parámetros de diseño de las máquinas desfibradoras. Por lo que el objetivo de este trabajo es determinar los parámetros racionales óptimos de

diseño de una máquina desfibradora de hojas verdes de *Agave angustifolia* Haw para un funcionamiento más eficiente y adecuado a los productores oaxaqueños, mediante un modelo que pueda relacionar los parámetros de diseño de la máquina desfibradora y la calidad del proceso de desfibrado, se pretende obtener a partir, del entrenamiento de una red neuronal artificial, con datos previamente obtenidos de forma experimental y efectuando variaciones en los parámetros de funcionamiento de la máquina.

Este tema no solo pretende solucionar el problema de la optimización del diseño de una desfibradora de hojas de agave sino dejar fundamentada una metodología que permita a los diseñadores disponer de una herramienta eficaz para poder establecer parámetros de diseño óptimos que no solo tengan en cuenta el consumo de energía y la potencia sino también los parámetros que determinan la calidad del proceso.

Esta investigación se desarrolló en unión al proyecto de investigación “Innovación de nuevos productos, compuestos a base de fibras de agave para usos industriales” que se desarrolló en el CIIDIR Oaxaca y el mismo tiene como objetivo desarrollar nuevos materiales a partir de compuestos naturales utilizando las fibras de *Agave angustifolia* Haw.

I. ESTADO ACTUAL DEL ARTE Y ANTECEDENTES DE LA INVESTIGACIÓN.

1.1. Generalidades.

1.1.1. Proceso de extracción de fibras del *Agave angustifolia* Haw en el Estado de Oaxaca.

El proceso de extracción de las fibras de hojas de *Agave angustifolia* Haw en el estado de Oaxaca se realiza de forma manual y es conocido como “enriado”, el mismo ocurre como resultado del esfuerzo aplicado por las manos del hombre con la ayuda de instrumentos rústicos Figura 1.



Figura 1. Limpieza de la hoja.

El tiempo empleado para el proceso es prolongado, pues la hoja requiere ser horneada y luego sumergida en agua antes de ser extraída la fibra (Cruz, 2000). El método de enriado es un proceso donde la parte no fibrosa es separada a partir de arrastre en dirección de la fibra. Las partículas de corteza de la hoja que ya han perdido sus propiedades iniciales mediante la descomposición de las sustancias por la acción de las bacterias, son relativamente fáciles de desprender.

El desfibrado de estas hojas se realiza de forma manual lo cual demanda un gran esfuerzo y limita crecimiento de la producción de fibra del *Agave angustifolia* Haw. Esta problemática impone el desarrollo de máquinas para el desfibrado de las hojas de agave(López Hernández, 2008).

Aún existen aproximadamente unas 2500 familias que dependen de la extracción de fibras de hojas de agave en cuatro de las ocho regiones del estado de Oaxaca, predominando para este uso el *Agave angustifolia* Haw (Cruz, 2011).

1.1.2. Particularidades constructivas de las máquinas desfibradoras.

Se puede decir que en México, la industria del henequén sucumbió ante la entrada al mercado de nuevas fibras y materiales plásticos (Joseph, 1992) y (Sanders, 1977). Varios autores registran trabajos sobre la producción, propiedades y usos de las fibras pero no aparece literatura sobre las propiedades mecánicas de las hojas, así como herramientas matemáticas para el cálculo de la resistencia al desfibrado y la energía necesaria para efectuar el mismo.

En México, no solo se han desarrollado máquinas para la extracción de las fibras del henequén, también se han diseñado máquinas para la producción de fibra de *Agave lechuguilla* Torey y se ha establecido la teoría funcional de la misma, con el trabajo de (Rössel Kipping *et al.*, 2003).



Figura 2. Máquina desfibradora de *Agave lechuguilla* Torey marca “Cardoma”.

En la Figura 2 se muestra una máquina desfibadora de *Agave lechuguilla* Torey marca Cardoma, que utiliza un motor eléctrico de aproximadamente 3 HP de consumo de potencia. La máquina requiere un avance lento de la hoja que es empujada al interior del órgano desfibador por la acción directa de la mano del operario, ofreciendo poca seguridad y al estar accionada por un motor de poca potencia, los accidentes no son tan fatales. Esta máquina entre sus partes fundamentales cuenta con un motor eléctrico monofásico y un tambor desfibador de púas, acoplados a un bastidor de perfil laminado. El proceso de trabajo fue estudiado por (Rössel Kipping *et al.*, 2003) quienes desarrollaron un tambor desfibador con cuchillas limpiadoras y clavos, concluyendo que el tambor con clavos realiza mejor el proceso que el de cuchillas limpiadoras.

Por otra parte, en Brasil, investigadores del EMBRAPA encabezados por el investigador e inventor José Faustino dos Santos, han desarrollado varios modelos de máquinas desfibadoras de hojas de Sisal; hechas a partir de modificaciones efectuadas a la máquina desfibadora tradicional y que se muestra en la Figura 3.

Las máquinas tradicionales con avance recto de la hoja en la misma dirección y en los dos sentidos. Utiliza un motor de combustión interna, y es construida por los productores. Algunos de sus componentes son de madera, la máquina, se puede decir que gracias a la habilidad y extremo esfuerzo del operario, tiene un rendimiento elevado llegando a unas 20 a 30 hojas por minuto, aproximadamente de 1.200 a 1.800 hojas por hora (Ribeiro Ferreira da Silva y Macedo Coutinho, 2006).



Figura 3. Desfibadora tradicional.

Las máquinas tradicionales con avance recto de la hoja en la misma dirección y en los dos sentidos. Utiliza un motor de combustión interna, y es construida por los productores. Algunos de sus componentes son de madera, la máquina se puede decir, que gracias a la habilidad y extremo esfuerzo del operario tiene un rendimiento elevado llegando a unas 20 a 30 hojas por minuto, aproximadamente de 1.200 a 1.800 hojas por hora (Ribeiro Ferreira da Silva y Macedo Coutinho, 2006). El desfibrado con ésta máquina es muy riesgoso con un elevado porcentaje de accidente y operarios mutilados, pues al ser fabricada por los productores, no presenta un mecanismo o elementos que garanticen la seguridad del operario y que eviten accidentes (Suinaga, 2006).

En la máquina desfibradora con avance perpendicular de la hoja respecto a la acción del órgano desfibrador, Figura 4, tanto el desfibrado, como la alimentación del órgano desfibrador, se realizan de forma mecánica. El trabajo del operario consiste en colocar dos veces la hoja de sisal en la entrada del órgano de alimentación. También utiliza un motor de combustión interna. Este presenta un menor rendimiento que la máquina tradicional, pero ofrece mucha garantía de operación. Presenta algunas especificaciones de diseño que contribuyen a que no sea de las más aptas para el uso, debido a que el órgano de alimentación transversal tiene una construcción compleja, es necesario aumentar el diámetro del tambor, lo que provoca que disminuya la eficiencia energética.

El rendimiento de esta máquina también es menor y aunque el operario no está expuesto a interactuar directamente con el órgano desfibrador debe estar todo el tiempo manipulando la hoja, colocándola al inicio del proceso y recibéndola cuando la misma para por el órgano desfibrador (Yasuko Yamashita *et al.*, 2008).



Figura 4. Máquina desfibadora con avance perpendicular de la hoja en dos tiempos.

La desfibadora con doble tambor desfibador, Figura 5, es hasta el momento, la de mayor complejidad diseñada y construida para productores de fibra de sisal en el estado de Bahía en Brasil. En esta máquina, tanto el desfibrado, como la alimentación del órgano desfibador, se realizan de forma mecánica.



Figura 5. Máquina desfibadora con doble tambor desfibador.

El trabajo del operario es más simple, pues solo coloca la hoja de sisal una vez en la entrada del órgano de alimentación. Utiliza un motor de combustión interna de más potencia que las anteriores y presenta el mayor rendimiento de las máquinas que en un solo proceso separan las fibras de las hojas, pues procesan aproximadamente unas 30 hojas por minuto. Presenta un sistema que ofrece al operador una total garantía de

en cuanto a su seguridad. Es una máquina muy costosa, tanto en construcción, como en el mantenimiento de sus partes (Alves y Santiago, 2006).

Por sus características, la máquina desfibadora de avance lineal continuo, con órgano de alimentación de rodillos, que se muestra en la Figura 6, es inadecuada para pequeños productores de fibras; pues la misma necesita de una instalación donde pueda ser colocada y con posibilidades de conexión a la corriente eléctrica.



Figura 6. Desfibadora de avance lineal continuo.



Figura 7. Separador de fibras y material de desecho.

Su consumo energético es elevado con dos motores de 15 HP+. Tiene el inconveniente que las fibras y los restos de las hojas quedan juntos en el lugar de descarga por lo que se hace necesario emplear un órgano separador que se muestra en la Figura 7. Esto aumenta la complejidad y costo de la máquina. Además se tiene que reorganizar las fibras de forma manual para ser colocada en el área de secado. De esta máquina, en lo positivo se puede decir, que tiene una capacidad de trabajo mayor que las anteriores y puede ser empleada de forma industrial en un proceso completamente mecánico de extracción de fibras.

Según la Red de Tecnología e innovación de Rio de Janeiro, la desfibradora de sisal con avance de la hoja en dirección de la orientación de las fibras y con rodillos de seguridad, “Faustino 5” (Figura 8), fue puesta en el mercado Brasileño en septiembre del año 2010.



Figura 8. Máquina desfibradora de Sisal “Faustino 5”

Esta máquina, desarrollada por el investigador José Faustino Dos Santos, está accionada por un motor de combustión de 10.5 HP y de 3500 revoluciones por minuto en el árbol cigüeñal. Tiene un rendimiento de 20 hojas por minuto y presenta un sistema que invierte el sentido de giro de los rodillos del órgano de alimentación en el momento que el operario presiona la compuerta de este, por lo que queda protegido de cualquier tipo de accidente en el órgano desfibrador.

1.1.3. Características del proceso de desfibrado mecánico.

El proceso de desfibrado mecánico de hojas de agave ocurre en varios pasos. El primero es el corte por cizallamiento parcial de la hoja. En este caso, la distancia entre las cuchillas y la contracuchilla debe ser mayor al espesor de las fibras para evitar el corte de estas. Dicha distancia no debe exceder un pequeño rango, para no provocar que queden partículas de material blando sin cortar. El cizallamiento parcial de la hoja significa que los esfuerzos cortantes en las etapas iniciales pueden estar orientados en la misma dirección que los elementos cortantes, pero luego, por el movimiento circular del órgano desfibrador, se ubican tangencialmente, evitando aproximarse lo suficiente para provocar un cizallamiento total.

El segundo fenómeno es el desprendimiento total del material blando provocado por el empuje de las paletas en la parte anterior al filo y la parte posterior de la contracuchilla. Este proceso requiere una velocidad tal que las partículas de material blando se desprendan totalmente de las fibras. De no ser la velocidad mínima necesaria suficiente, las partículas de material blando se desplazarían junto a las fibras al interior de la máquina. El tercer fenómeno es la impulsión del material blando provocado por la inercia de su peso adherido a las cuchillas.

Cabe señalar que durante el segundo y tercer paso se produce fricción del filo las cuchillas sobre las fibras. A velocidades muy bajas, de avance de la hoja, las fibras sufrirían en exceso de corte de las cuchillas, lo cual provoca su deterioro que conlleva además a la ruptura de estas.

1.2. Proceso de diseño de máquinas desfibradoras.

1.2.1. Especificaciones de desempeño de la desfibradora.

Para el diseño de las máquinas desfibradoras de hojas de Agave, se hace necesario combinar diferentes técnicas y métodos para conseguir el resultado deseado, por lo que se convierte en un problema complejo a solucionar.

El proceso de diseño inicia con las especificaciones que debe cumplir el dispositivo que se desea obtener. Para proponer un prototipo de prueba que intenta satisfacer esas especificaciones de desempeño (Richardson *et al.*, 1998).

Durante el diseño mecánico se lleva a cabo un proceso interactivo de optimización que permite ir actualizando los valores de los parámetros de diseño, para llegar a los valores óptimos de la geometría de los órganos de trabajo del prototipo de prueba. Cada vez que se obtiene una nueva combinación de parámetros y elementos de diseño, se hace necesario comprobar si cumple dichas especificaciones de desempeño (Juvinall y Marshek, 2011).

En este caso, la especificación más importante es la separación total de las fibras de la parte blanda de la hoja; además el desempeño está ligado al rendimiento y eficiencia de la máquina, siendo el parámetro más importante, el consumo de energía por unidad de volumen de fibra. En cuanto al rendimiento, el volumen total de fibras obtenidas en una jornada de trabajo se debe maximizar (Shinners *et al.*, 2007). Por lo tanto a partir de las especificaciones de desempeño, el diseñador plantea el problema de la forma que más le convenga, siempre y cuando mantenga constante dichas especificaciones (Husseinzadeh Kashan, 2011).

1.2.2. Generación de conceptos para el diseño de la desfibradora.

Al realizar la selección de los diferentes componentes para una nueva máquina, dígame la generación de conceptos, se limitan, ya considerablemente, muchas de las variantes. Pero no todas las dimensiones y parámetros de un prototipo de máquina a diseñar se pueden establecer durante la generación del concepto, existen otros parámetros sujetos a especificaciones y a posibles regulaciones durante el proceso de trabajo, que no pueden establecerse como parámetros previos. Es de mucha importancia como se puede ver la selección correcta de un concepto de prototipo para el diseño exitoso (Krish, 2011).

1.2.3. Métodos interactivos para la determinación de los parámetros de diseño.

Por el hecho de que se desconocen muchos datos y de metodología de cálculo más precisa para su aplicación con carácter general en el diseño de máquinas desfibradoras, aún sigue siendo la experiencia acumulada por

los investigadores un elemento fundamental. A manera de una simple valoración empírica sobre el consumo de potencia, puede resultar útil para la selección de un dispositivo de prueba inicial en muchas ocasiones. Precisamente, en la fase interactiva de actualización de los parámetros de diseño, es donde se han producido los mayores avances en los últimos años; especialmente, como resultado de las capacidades de cálculo y almacenamiento de datos cada vez mayores de los ordenadores personales (Rao *et al.*, 2011).

Muchos de los datos necesarios para establecer parámetros de diseño se pueden obtener tanto de manera simulada, como mediante la experimentación, durante la evaluación del funcionamiento del comportamiento de los mecanismos y los órganos de trabajo.

A pesar de que mediante la obtención de parámetros de funcionamiento de manera experimental tiene la desventaja que es necesario construir el prototipo, no en todos los casos es posible la simulación del proceso, por cuestiones tales como el costo computacional, la no validación del modelo de simulación y porque puede ser también costoso realizar esta validación de la simulación.

Claro está que para la obtención de parámetros de funcionamiento de manera experimental, se puede utilizar máquinas ya construidas y variar diferentes parámetros de diseño. En otro caso, es construir un prototipo solo con propósito experimental. Se logra de esta manera un ahorro de tiempo y recursos muy importante, que permite afrontar procesos de diseño en los que se necesita realizar numerosas iteraciones.

La obtención de datos numéricos durante la prueba de órganos de trabajo de máquinas agroindustriales, como en todo el proceso experimentación, se ha visto afectada de manera significativa por la automatización y el desarrollo cada vez más avanzado de instrumentos de medición digitales que permiten obtener de un elevado número de valores numéricos por unidad de tiempo.

Estos valores numéricos permiten la generación de bases de datos que facilita la selección de parámetros de diseño de una forma interactiva, usando algoritmos de optimización. Existen algoritmos desarrollados para diseñar eficientemente sólo un tipo particular de máquinas; que no resultan de utilidad práctica cuando se

trabaja con máquinas que operan con diferentes materias primas y difieren en algunos elementos para los que han sido concebidos.

Lo más común es emplear algoritmos matemáticos de optimización de carácter general. Estos se pueden clasificar en dos tipos principales: los algoritmos de optimización local y los algoritmos de optimización global. Los primeros solo necesitan realizar, normalmente, un número de iteraciones muy pequeño, antes de alcanzar un resultado y finalizar.

Mientras, los algoritmos del segundo grupo necesitan siempre realizar un número muy grande de iteraciones. No obstante, usando algoritmos de optimización global es más seguro conseguir mejores diseños, que satisfagan los requerimientos más exigentes. El motivo es que estos realizan una búsqueda exhaustiva del mejor diseño posible, en un intervalo más amplio de los parámetros de diseño, procurando evitar los diseños que solo son muy buenos en un pequeño intervalo. Sin embargo, a pesar de sus beneficios, la utilización de algoritmos de optimización global se encuentra con importantes dificultades, cuando se trata de diseñar una maquinaria que no ha sido probada para la materia prima a procesar en cuestión.

Estas dificultades son el resultado de la combinación de diversos factores:

1. El elevado número de iteraciones que debe realizar el algoritmo de optimización global antes de converger.
2. La necesidad de determinar con precisión el comportamiento del material a desfibrar, en este caso, las hojas de *Agave angustifolia* Haw durante su interacción con el órgano de trabajo y los diferentes tipos de elementos desfibradores que se pretende diseñar.
3. Las diferentes variantes de funcionamiento de la máquina para establecer cada iteración del algoritmo de optimización, para comparar los resultados con el funcionamiento de la máquina que se desea obtener.

Existen otras razones para enfocar la solución en la simulación por red neuronal, pues nos damos cuenta de la dificultad para lograr soluciones analíticas precisas de los parámetros de diseño dado a que se desconoce el comportamiento mecánico de las hojas de *Agave angustifolia* Haw.

Así el método tradicional de diseño, en este caso, presentaría las siguientes desventajas.

1. Desarrollo previo de un método de cálculo con base en mecánica teórica y resistencia de materiales, que solucione, de manera razonable y eficaz, la relación de los parámetros de funcionamiento y dimensiones de los elementos que interactúan en las etapas del proceso de desfibrado.
2. Pruebas y ensayos para determinar las variables que se necesitan como datos de entrada y que deben ser obtenidos en ensayos que están normados para otras condiciones y parámetros como velocidad y desplazamiento.
3. Se llega a un diseño final del primer prototipo, sin tener en cuenta circunstancias reales de operación y calidad del producto que pueden influir en la solución final.

1.3. Redes neuronales artificiales y modelado de procesos mecánicos.

1.3.1. Introducción a las redes neuronales.

Las redes neuronales artificiales (RNAs) son sistemas procesadores de información, que emulan ciertas funciones del comportamiento de las redes neuronales biológicas. Inspiradas por el funcionamiento que presenta el cerebro humano, su principal atractivo se muestra en su capacidad para aprender de la observación, y generalizar después por abstracción. Lo que las convierte en poderosas herramientas de trabajo, usadas en numerosas áreas del campo científico, capaces de aprender relaciones de entrada-salida arbitrarias (Jain, 2010).

Las RNAs han sido ampliamente utilizadas en muchas áreas de aplicación en los últimos años. La mayoría de las aplicaciones han utilizado las RNAs de alimentación hacia adelante (feedforward) y las RNAs de retropropagación (BP- backpropagation) como algoritmo de entrenamiento (Yao y Liu, 1997).

(Al-Bulushi *et al.*, 2010) desarrolla un flujo de trabajo de red neuronal, que proporciona un enfoque sistemático para abordar diversos problemas de ingeniería de petróleo.

Las redes neuronales artificiales pueden utilizarse para modelar procesos de fabricación porque tienen la capacidad de aprender de las asignaciones no lineales arbitrarias entre patrones de entrada y salidas. El aprendizaje de las redes neuronales está diseñado para determinar un conjunto apropiado de interconexión fortalezas (o “pesos”) que faciliten la activación de las neuronas para alcanzar un estado deseado relacionado con un determinado conjunto de patrones muestreados. Una red neuronal se compone de varias capas de neuronas, que están interconectadas de tal manera que la información se almacena en las ponderaciones asignadas a las conexiones. En la Figura 9 se tipifica una red que tiene tres capas; la primera capa es la capa de entrada donde condiciones entrada de datos que representa de proceso se introduce en la red.




Figura 9. Red neuronal con tres capas.

Presenta además una capa oculta y la última capa es la capa de salida, que corresponde a las respuestas de salida del proceso (Davis *et al.*, 2004).

Entre esas áreas, se sitúa la optimización del diseño mecánico de varias máquinas y mecanismos, donde se han realizado numerosas aplicaciones. En este caso la red neuronal se utilizaría para modelar el comportamiento de los diferentes parámetros de diseño y luego poder realizar un diseño adecuado de la máquina desfibradora de hojas de *Agave angustifolia* Haw.

Vista como una máquina adaptativa, una RNA es un procesador fuertemente distribuido y paralelo, formado por unidades procesadoras más sencillas y por las conexiones entre ellas. A las unidades procesadoras más fundamentales se las conoce como neuronas, y a las conexiones entre las neuronas se las denomina vínculos o enlaces. Estos poseen un parámetro libre asociado, llamado peso, que es quien controla el flujo de información entre las neuronas. Cada neurona de la RNA recibe información, que puede provenir de otras neuronas vecinas y/o del exterior. Luego la neurona procesa esa información y produce una salida, que puede ser, a su vez, información de entrada a otras neuronas, o bien salida de la propia red. Una neurona según la función y la posición que ocupa dentro de una RNA se puede clasificar en tres tipos o clases fundamentales: neuronas de entrada, neuronas de salidas y neuronas ocultas o intermedias (Izeboudjen *et al.*, 2011). Las neuronas de entrada son las que reciben la información desde fuera de la RNA. Mientras, las neuronas de salidas son aquellas cuyas salidas solo se usan externamente.

Por último están las neuronas que solamente reciben estímulos de neuronas de la propia RNA es decir de otras neuronas, y cuyas salidas solamente sirven de entrada para otras neuronas, son las que reciben el nombre de neuronas ocultas o intermedias.

A partir de estos datos generales, existen diferentes formas para que una neurona procese la información que recibe, y también diversas formas de conectar o enlazar unas neuronas con otras. En consecuencia, se pueden construir RNAs con propiedades y capacidades muy diversas, en función de las unidades procesadoras que se utilicen, y de la manera en que esas unidades se relacionen entre sí (Zhang *et al.*, 2003).

Las redes neuronales, como es conocido, tienen la habilidad aproximarse a sistemas no lineales, con una pequeña cantidad en general de datos son competentemente capaz de resolver los problemas de control y optimización.

1.3.2. Aplicaciones de las redes neuronales en la ingeniería.

Una gran mayoría de problemas de ingeniería son problemas inversos, mientras que el problema de ingeniería basado en la solución mediante métodos matemáticos y mecánica computacional es principalmente capaz de resolver los problemas hacia adelante. La naturaleza ha evolucionado eficazmente, robusta y tolerante a problemas de imprecisión, logrando solucionar estratégicamente problemas inversos muy difíciles. La biología ha inspirado el desarrollo de software como y métodos computacionales tales como las como redes neuronales, algoritmos genéticos y lógica difusa, que heredan las características básicas de los métodos de problemas de la naturaleza, y como tal, son convenientes para problemas inversos en ingeniería (Ghaboussi, 2010).

Algunos Problemas prácticos que pueden estar asociados con los objetivos de optimización específicas, que no pueden abordarse con el uso de las teorías de la maquinaria agropecuaria ni con la simulación mediante un programa de cómputo diseñado para un caso particulares de optimización. Esto determina la necesidad del desarrollo de técnicas de optimización para el modelado de maquinarias agroindustriales utilizando procedimientos computacionales eficientes vinculados con la simulación mediante redes neuronales artificiales y enfocados a resolver problemas de optimización de diseño, para ir revolucionando el diseño muchas de las máquinas industriales (Cao *et al.*, 2009).

Según el método presentado por (Farley *et al.*, 2008) se puede clasificar una señal A_scan ultrasónica según la cantidad de los defectos presentes y, a continuación, proporcionar una medida exacta del tamaño y la ubicación de los defectos. Las predicciones se correlacionan muy bien con los valores objetivos, incluso con datos ruidosos.

Un modelo basado en una RNA se utiliza para predecir la profundidad de penetración óptima en soldadura de láminas de acero inoxidable con arco bajo gas de tungsteno, es presentado por (Sudhakaran *et al.*, 2011), que desarrolla un código fuente en MATLAB para hacer la optimización de las variables que intervienen el proceso.

Las técnicas son aplicables a una variedad de dispositivos y mecanismos para logran demostrar un buen desempeño en una serie de situaciones prácticas. Sin embargo, el rápido desarrollo de la industria de la construcción de maquinarias fomenta la investigación en este ámbito hacia la solución de muchos problemas en la precisión, confiabilidad, y los recursos de cómputo (Bratina *et al.*, 2009).

Algunas técnicas de optimización pueden funcionar muy bien si se unieron con la teoría de maquinaria para el desfibrado de hojas de agaves.

Mientras tanto, hasta ahora, ejemplos de optimización con la participación de la teoría del desfibrado requiere un esfuerzo de simulación computacional importante y complicada. Todavía no significa que, en caso de una técnica de optimización realmente eficiente de acompañamiento, una solución verdaderamente competente no se puede obtener.

Mientras tanto, parece que con los avances actuales en cuanto a la capacidad de las computadoras, los sistemas de adquisición de datos y además los programas de análisis matemáticos y de desarrollo de inteligencia artificial con capacidades ampliadas y que se caracterizan por una alta precisión, se merece una mirada cuidadosa a ellas como herramientas de análisis de un respaldo eficiente optimización en el diseño de la maquinaria para la industria (Mutluer y Bilgin, 2011).

Un enfoque para el cálculo de parámetros de diseño de los órganos de trabajo de una desfibradora siguiendo la teoría convencional de máquinas agrícolas, donde se despejan las variables de diseño, tiene la desventaja, de ser un proceso que depende de propiedades de las hojas, que varían, tanto en cada hoja, como a lo largo de sus geometrías.

Por otra parte, las RNAs junto con la experimentación y prueba de máquinas en la determinación de valores reales de comportamiento del consumo de potencia y los valores de parámetros cinemáticas puede ser un enfoque razonablemente productivo y servir como una herramienta de optimización adecuada en el diseño de varios tipos de máquinas industriales (Mengistu y Ghaly, 2007).

1.3.3. Ventajas y desventajas de los modelos mediante redes neuronales artificiales.

En un modelo, cuanto mayor sea la aproximación que consigue al comportamiento verdadero, en el intervalo de valores correspondiente, mayor será la precisión que se le asigne, y viceversa (Cid Álvarez, 2007).

Recurriendo a la teoría del desfibrado, es posible implementar en un ordenador, modelos que puedan solucionar en alguna medida y para casos ya estudiados el problema del consumo de potencia durante el desfibrado. En tales casos, una vez implementados los modelos correspondientes, se puede disponer de respuestas que pueden no ser muy precisas dado el desconocimiento en si del comportamiento mecánico de las hojas durante el proceso. También se suma a esto el problema es que existe una cantidad elementos de desfibrado para los que la teoría de la mecánica teórica, presenta tal grado de complejidad, que imposibilita la implementación práctica de cualquier modelo analítico preciso. Aquí, las RNAs constituyen una herramienta de trabajo muy valiosa. Precisamente, el objetivo fundamental que se persigue con el desarrollo de las RNAs, es el de poder disponer de sistemas que, imitando el comportamiento del cerebro humano, puedan no solo aprender el comportamiento de unas pocas muestras, si no, además, ser capaces de extraer el comportamiento más general que da lugar a esas muestras. Las principales características de las RNAs, que las hacen muy atractivas para este tipo de trabajo, son:

1. La evaluación de la respuesta de las RNAs es muy rápida (casi que inmediata).
2. Debido a su naturaleza, las RNAs son capaces de aprender casi cualquier tipo de comportamiento. Siempre a partir de un número de muestras lo suficientemente representativo del comportamiento que se quiere que aprendan.

3. No se necesita un conocimiento “aprioris” sobre el comportamiento que se desea modelar. Toda la información que se necesita para el modelado, se extrae a partir de un conjunto de muestras del comportamiento que se va a modelar.
4. No se necesita definir una expresión funcional diferente, para el modelo funcional que se va a emplear en un caso particular. El modelo que siempre se utiliza es el de la propia RNA.
5. Las RNAs pueden modelar comportamientos fuertemente no lineales, tan bien como los comportamientos lineales o casi lineales.
6. Las RNAs representan, de manera intrínseca, relaciones entre espacios multidimensionales, equivalentes a aquellas que se desea modelar.

1.4. Optimización Multiobjetivo.

Optimizar es un objetivo común en muchas áreas de la ciencia y la tecnología. Los ingenieros ajustan parámetros para lograr el mejor desempeño de un sistema. Los científicos buscan valores que mejor ajusten un modelo a un experimento. Para lograr aplicar las técnicas de optimización primero es necesario identificar los objetivos (Bagirov *et al.*, 2002).

La mayor parte de los problemas de optimización del mundo real son naturalmente problemas multiobjetivos. Esto es, suelen tener dos o más funciones objetivo que deben satisfacerse simultáneamente y que posiblemente están en conflicto entre sí. Sin embargo, a fin de simplificar su solución, muchos de estos problemas tienden a modelarse como mono-objetivo usando solo una de las funciones originales y manejando las adicionales como restricciones (Zhou *et al.*, 2011).

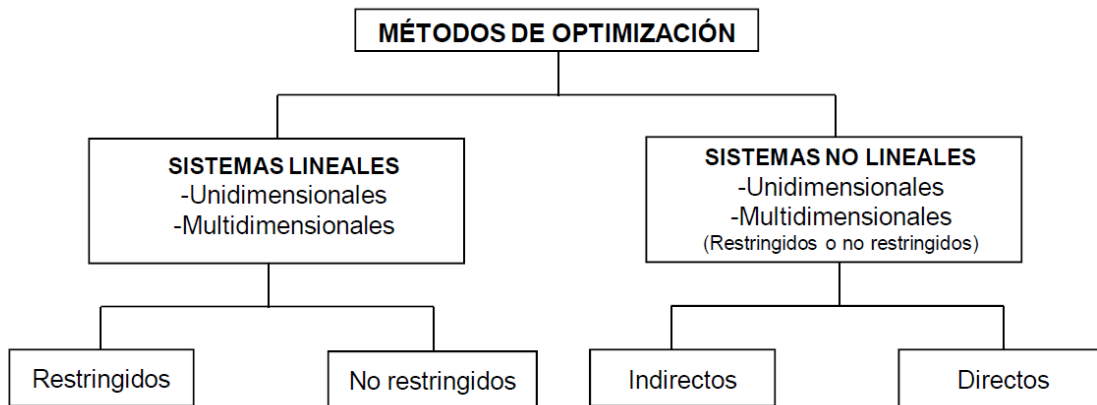


Figura 10. Métodos de optimización.

Los métodos de optimización se pueden clasificar como sistemas lineales o no lineales para sistemas unidimensionales o multidimensionales, estos primeros pueden ser restringidos o no restringidos al igual que los lineales tanto indirectos o directos.

Los métodos clásicos de optimización son utilizados para buscar la solución óptima a funciones continuas y diferenciables. Pero muchos problemas de la práctica presentan una función objetivo que no es continua y/o diferenciables, por lo que los métodos clásicos tienen aplicaciones limitadas en la práctica. En cambio los métodos de optimización basados en técnicas numéricas presentan posibilidades para la determinación de los mínimos y máximos tanto para problemas de una variable o multivariable, ya sea con o sin restricciones (Watrous, 1988).

1.5. Algoritmos genéticos.

Los algoritmos genéticos son formas de algoritmos evolutivos, inspirados en la teoría de la selección natural y la genética para evolucionar una población inicial, hacia mejores regiones del espacio de búsqueda. Durante las últimas décadas ha existido un creciente interés en algoritmos basados en el principio de la evolución (supervivencia del más apto). Entre los algoritmos evolutivos más conocidos se incluyen los algoritmos genéticos (Davis, 1991).

La evolución de la población se realiza mediante la aplicación de operadores genéticos probabilísticos de selección, recombinación y mutación. Los algoritmos genéticos requieren conocer solamente el valor de la función objetivo en la población de puntos y no sus derivadas. Esto último permite abordar una gran variedad de problemas de optimización no tratables mediante métodos basados en gradientes. Los algoritmos evolutivos son métodos robustos de búsqueda, que permiten tratar problemas de optimización donde el objetivo es encontrar un conjunto de parámetros que minimizan o maximizan una función de adaptación (Gen y Cheng, 2000).

Los algoritmos genéticos operan con una población de individuos $P(t) = \{x_1^t, \dots, x_n^t\}$, para la iteración t , donde cada individuo x_i representa un punto de búsqueda en el espacio de las soluciones potenciales a un problema dado. El desempeño de un individuo x_i se evalúa según una función de adaptación $f(x_i)$. Esta función permite ordenar del mejor al peor los individuos de la población en un continuo de grados de adaptación.

La población inicial evoluciona sucesivamente hacia mejores regiones del espacio de búsqueda mediante los procesos probabilísticos que a continuación se enumeran.

1. Selección de los individuos más adaptados en la población.
2. Grado de adaptación para mayor probabilidad de dejar descendencia.
3. Modificación por recombinación y/o mutación de los individuos seleccionados.

Las principales diferencias de los algoritmos evolutivos con los métodos tradicionales de búsqueda son las siguientes:

- codificación del conjunto de parámetros (en general no se evolucionan los parámetros directamente sino que su codificación).
- búsqueda en paralelo con una población de puntos.
- uso de función de adaptación directamente (no se requiere de derivadas).

- reglas de transición probabilísticas entre una iteración y otra.

Para encontrar los óptimos globales, los algoritmos de optimización hacen uso eficiente de dos técnicas

1. Exploración de áreas desconocidas en el espacio de búsqueda.
2. Explotar el conocimiento obtenido de puntos previamente evaluados.

1.5.1. Optimización multiobjetivo con algoritmos genéticos.

Las redes neuronales artificiales (RNA) y algoritmos genéticos (GA) se consideran entre las más modernas herramientas que se utilizan para resolver problemas complejos que no pueden ser resueltos por las soluciones convencionales (Abu Qdais *et al.*, 2010)

En cualquier problema de optimización, la elección de la función objetivo afecta el proceso de optimización, así como los resultados. Así, una identificación cuidadosa y bien estudiada y la formulación de esa función es crucial (Mengistu y Ghaly, 2007).

Estos algoritmos se inspiran en la mecánica de la selección natural y la genética para evolucionar una población inicial de puntos sucesivamente hacia mejores regiones del espacio de búsqueda. La evolución de la población se realiza mediante la aplicación de operadores genéticos probabilísticos de selección, recombinación y mutación. Los algoritmos genéticos requieren conocer solamente el valor de la función objetivo en la población de puntos y no sus derivadas. Esto último permite abordar una gran variedad de problemas de optimización no tratables mediante métodos basados en gradientes.

La formulación discusión y generalización de los algoritmos genéticos para la optimización multiobjetivo fue descrita por (Fonseca y Fleming, 1993). Estos investigadores fueron los primeros en definir un método de asignación de prioridades para algoritmos genéticos multiobjetivo.

El desarrollo de los algoritmos genéticos multiobjetivo (AGMO) es una expresión de nuestro deseo de llevar a la toma de decisiones en diseño de ingeniería, en generar y controlar el diseño del sistema, en particular.

Los problemas complejos exhiben una gran superficie de respuesta que, para ser solucionados con precisión,

en última instancia podría sobrecargar en la toma de decisiones externa con información prácticamente inútil. Un problema importante que surge ocasionado por la asignación de prioridades de Pareto, es el tamaño global del conjunto solución. Pequeñas regiones de la superficie de salida, sin embargo, todavía se pueden degustar en una moda con base en el frente de Pareto, mientras que la toma de decisiones aprende y perfecciona sus necesidades. Métodos de formación de nicho se transfieren el dominio del valor objetivo para sacar provecho de las propiedades del conjunto de Pareto (Fonseca y Fleming, 1995).

1.5.2. Aplicaciones ingenieriles de la optimización multiobjetivo por algoritmo genético.

Los algoritmos evolutivos han encontrado aplicación en muchas áreas no susceptibles de optimización por otros métodos, poseen muchas características deseables en un optimizador multiobjetivo, notablemente el manejo concertado de múltiples soluciones del candidato. Sin embargo, los algoritmos evolutivos son esencialmente técnicas de búsqueda sin restricciones que requieren la asignación de una medida escalar de calidad o idoneidad, a esas soluciones. En la solución de problemas de optimización multiobjetivo se pueden combinar varios métodos como son las neuronales, algoritmos genéticos y optimización basada en gradiente para obtener soluciones computacionalmente fáciles y de poco coste de tiempo. Hay que tener en cuenta que en muchos problemas de optimización de diseño se enfrentan tareas complejas y con información incompleta. Por lo que se requiere un enfoque “Pragmático” en la búsqueda de las mejores soluciones (Poloni *et al.*, 2000).

La optimización del diseño mediante aproximaciones basadas en redes neuronales de retropropagación es el tema de muchas investigaciones y la eficacia del procedimiento utilizado para entrenar a la red neuronal se reflejará en la eficiencia global de la solución óptima dada (Zhang y Subbarayan, 2002).

Kim *et al.* en el 2004 incorporan un modelo RNA con retropropagación a un AG que fue más eficaz y preciso en la estimación de los costes de construcción que el modelo RNA con retro propagación utilizando prueba y error. El modelo incorpora una RNA con retro propagación a un GA capaz de estimar

adecuadamente el costo de la construcción en la etapa temprana del proyecto, reduciendo el tiempo y esfuerzo en la primera etapa de estimación de coste del proyecto.

(Gholizadeh *et al.*, 2008) en el 2008, muestran un estudio con una combinación de algoritmo genético y redes neuronales para encontrar el peso óptimo de estructuras sometidas a múltiples limitaciones de frecuencias naturales. La optimización se lleva a cabo por un algoritmo evolutivo usando variables de diseño discretos y los resultados numéricos demuestran la robustez y alto rendimiento de los métodos sugeridos para la optimización estructural con restricciones de frecuencia.

Se pueden emplear las RNA y los AG como herramienta de simulación y optimización del proceso de producción de biogás, examinando el efecto de los parámetros de funcionamiento del digester, tales como, la temperatura, los sólidos totales, sólidos volátiles totales y el pH en la producción de biogás. El rendimiento del modelo de RNA demuestra la eficacia para predecir la producción de metano con precisión con coeficiente de correlación de 0,87 (Abu Qdais *et al.*, 2010).

(Ghorbanian *et al.*, 2011), en el 2011 desarrollan una herramienta predictiva, rápida y globalmente convergentes para el diseño de cojinete de carga dinámica, que integra un problema complejo de modelación hidrodinámica de cojinetes de deslizamiento en motores de combustión interna, un proceso de optimización que se caracteriza por un alto número de variables que son modificadas y al mismo tiempo un gran número de limitaciones que deben cumplir.

En el estudio numérico del comportamiento bajo carga axial de tubos de aluminio circulares de pared delgada, utilizados para absorber la energía del impacto, la RNA tiene la capacidad de ilustrar la tendencia de los parámetros de deformación complejos y no lineales. Por tanto la optimización se constituye sobre la base de la simulación RNA y la suma ponderada de método de funciones de costes y determinar los valores óptimos de las relaciones longitud/diámetro y diámetro/espesor usando Algoritmos Genéticos según (Marzbanrad y Ebrahimi, 2011).

Mediante una RNA se establece la relación entre los parámetros de entrada de soldadura por láser, como la energía del haz, la velocidad de desplazamiento y la posición focal y las respuestas en tres diferentes gases protectores (argón, helio y nitrógeno). Los modelos establecidos se utilizan para la optimización de los parámetros del proceso utilizando AGs. Y se obtienen soluciones óptimas para los tres gases diferentes y sus respectivas respuestas (Sathiya *et al.*, 2012).

II. FUNDAMENTOS TEÓRICOS.

2.1. Proceso de desfibrado de hojas de *Agave angustifolia* Haw.

En la Figura 11, se muestra la estructura de la máquina fundamentada. La misma fue concebida según las exigencias de los productores de *Agave angustifolia* Haw en México, es decir una máquina compacta, de pequeño formato y de fácil construcción, capaz desfibrar las hojas verdes del agave. Esta máquina, accionada por un motor eléctrico está compuesta por un órgano de alimentación conformado por dos rodillos giratorios que son accionados por una transmisión por cadenas que toma el movimiento desde el árbol del órgano desfibrador. El órgano de alimentación de rodillos mantiene una velocidad constante lo que garantiza la alimentación continua y mantiene alejadas las manos del operario de la acción directa de los elementos activos del órgano desfibrador, lo cual aumenta las alternativas de mercado de las fibras pues permite obtener certificación como un producto que no ofrece peligro para el productor.

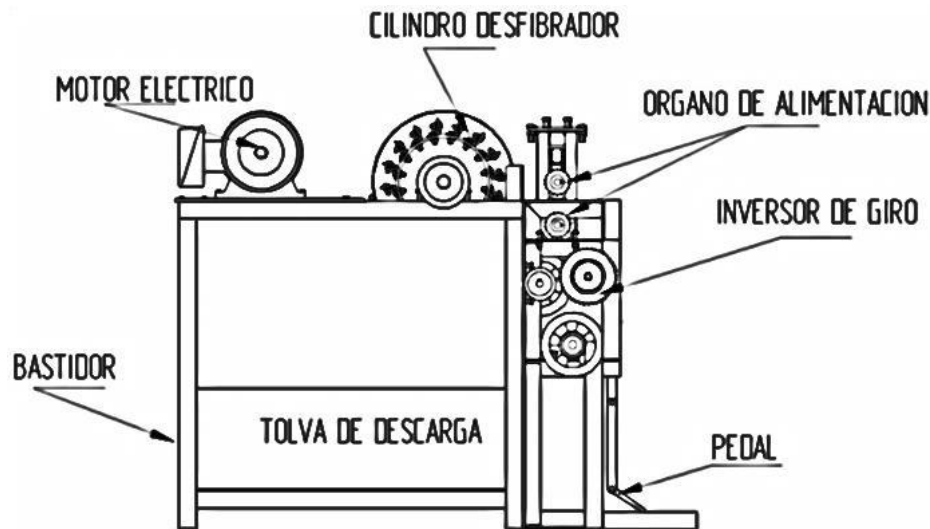


Figura 11. Estructura de la máquina desfibradora diseñada.

Los rodillos de alimentación mantienen la presión sobre las hojas de agave con la ayuda de dos resortes que trabajan a compresión, garantizando el agarre de las hojas mientras son conducidas hasta el órgano desfibrador. El órgano desfibrador está compuesto por un cilindro rotatorio con soportes para la colocación de las cuchillas desfibradoras, que son las encargadas de la eliminación de la corteza de la hoja. La corteza de la hoja cae en la tolva de descarga, mientras las fibras son retiradas del interior de la máquina por el órgano de alimentación, que gira en sentido contrario en el momento de extraer dichas fibras. Este cambio en la dirección del giro de los rodillos de alimentación se produce gracias al mecanismo de cambio sentido del giro, que es accionado por un pedal.

El órgano desfibrador cilíndrico es el elemento más importante de la máquina, es donde se realiza el proceso de separación de la parte blanda y las fibras, así de esta forma, obteniéndose dos nuevos materiales, fibras y parte no fibrosa a partir de las hojas. Las partes que componen el cilindro desfibrador se muestran en la Figura 12.




Figura 12. Partes del órgano desfibrador.

El proceso de desfibrado comienza con la colocación de la hoja entre los rodillos de compresión, en este momento la hoja es comprimida por los rodillos y producto a la fuerza de fricción trasladada con una velocidad de alimentación V_a hacia el órgano desfibrador como se observa en la Figura 27.

Las hojas de agave en el momento que hacen contacto con las cuchillas del órgano desfibrador se encuentran sobre la contracuchilla a una altura a hasta del centro de rotación del cilindro y una holgura de desfibrado H_f , la holgura de desfibrado no es más que la distancia desde la contracuchilla a la recta tangencial al movimiento de las cuchillas que cortan el material con una velocidad V_t .

2.2. Teoría del movimiento del órgano desfibrador rotacional de eje horizontal.

2.2.1. Determinación de la trayectoria de la cuchilla.

La trayectoria de las cuchillas de los órganos desfibradores con eje de rotación horizontal, empleados en las máquinas desfibradoras de hojas de Agaves, corresponde con las ecuaciones paramétricas (1) y (2) que definen la cicloide descrita por el extremo de las cuchillas para órganos de corte de eje horizontal según (Pérez de Corcho Fuentes *et al.*, 2009), donde:

$$x(t) = V_a \times t + R \times \sin(\omega \times t); \text{ m} \quad (1)$$

$$y(t) = R \times (1 - \cos(\omega \times t)); \text{ m} \quad (2)$$

Donde:

V_a : velocidad de alimentación, $\frac{m}{s}$;

ω : velocidad angular del rotor del órgano desfibrador, s^{-1} ;

R : radio del extremo de las cuchillas, m ;

t : tiempo, s .

En el proceso de desfibrado se trata de sustraer de la manera más continua posible la corteza a la hoja para dejar la fibra, por lo tanto el número de cuchillas a colocar en el cilindro será el máximo permisible por la geometría del cilindro desfibrador de radio exterior R_c como se muestra en la Figura 13.

$$Z = \frac{360^\circ}{2 \tan\left(\frac{e}{R_c}\right) + \tan\left(\frac{c}{R_c}\right)} \quad (3)$$




Figura 13. Esquema del proceso de desfibrado, variables geométricas.

Mediante la expresión (8) se puede determinar la distancia máxima $S_{(x)}$ entre dos cicloides de cuchillas consecutivas indicados por los puntos P1 y P2 de la Figura 14, cuando estas han girado un ángulo de 90 grados ($\frac{\pi}{2}$ rad). En ambas posiciones, la cuchilla se encuentra en el plano horizontal, a la altura del eje del órgano desfibrador.

Tiempo de giro hasta el ángulo 90 grados:
$$t_1 = \frac{\pi}{2 \times \omega} \quad (4)$$

Ordenada del punto P_1 :
$$x(t_1) = V \times t_1 + R \times \sin(\omega \times t_1) \quad P_1 = x \times (t_1) \quad (5)$$

Tiempo de giro hasta el ángulo 90 grados para

$$t_2 = t_1 \quad (6)$$

el punto dos:

Ordenada del punto 2: $x(t_2) = V \times t_2 + R \times \sin(\omega \times t_2) + \frac{V}{\omega \times Z}$ $P_2 = x \times (t_2)$ (7)

Distancia entre los puntos 1 y 2: $S_{(x)} = x(t_2) - x(t_1)$ (8)




Figura 14. Distancia entre dos cicloides consecutivas.

Quedando la longitud teórica del tramo de acción de una cuchilla o tramo de desfibrado, analizado como órgano de corte de eje horizontal (Silveira Remus, 1982).

$$l_{teor} = \frac{V_a}{nZ} \quad (9)$$

2.2.2. Altura de la contracuchilla:

El valor óptimo de la holgura de la contracuchilla parte de a condición de que la alimentación debe realizarse en aquel lugar del tambor donde la acción repelente de la cuchilla no exista, es decir,

$V_r = 0$ (Figura 16). La velocidad resultante del filo V_c varía su dirección en relación al movimiento de la hoja y actúa sobre la hoja repeliéndola y dificultando la introducción en el cilindro desfibrador cumpliéndose la ecuación (10).

$$V_r = V_c \cos \varphi \quad (10)$$




Figura 15. Interacción de las cuchillas con la hoja de agave durante el proceso de desfibrado.

Con base en lo anterior y de acuerdo con la ecuación (10) el valor de $V_r = 0$ solo cuando $\varphi = \frac{\pi}{2}$, es decir, cuando la velocidad resultante V_c este dirigida perpendicularmente en la dirección del movimiento de la capa, lo cual tiene lugar en el punto B.

El valor del coseno ángulo ψ para obtener $V_r = 0$ se determina como:

$$\cos \psi = -\frac{V_a}{V_t} \quad (11)$$

Donde:

V_t - Velocidad tangencial de le cuchilla.

Si el espesor de la hoja es h , entonces el levantamiento del eje del tambor, por encima de la contracuchilla, se puede determinar el triángulo boB :

$$\Delta h = a - h = \frac{D}{2} \cos \psi \quad (12)$$

De donde según la ecuación (11)

$$a = h + \frac{D}{2} \cdot \frac{V_a}{V_t} \quad (13)$$

De esta ecuación se infiere que para lograr un corte normal, el eje del tambor debe estar dispuesto por encima del espesor máximo del material la dimensión:

$$\Delta h = \frac{D}{2} \cdot \frac{V_a}{V_t} \quad (14)$$

2.2.3. Potencia requerida en el órgano desfibrador.

Aplicando métodos de la mecánica clásica se establecen las relaciones que permiten determinar los componentes del consumo de potencia en función de los parámetros de diseño y explotación para el órgano de trabajo de una máquina agrícola (Pérez de Corcho-Fuentes y Garbati-Pegna, 2008).

Como en todos los órganos de trabajo, en las máquinas desfibradoras el consumo de potencia puede expresarse como:

$$N = N_{\text{útil}} + N_{\text{vacío}} \quad (15)$$

Donde:

$N_{\text{útil}}$: Potencia invertida en el desarrollo de los procesos tecnológicos que efectúa el órgano expresada en watts.

$N_{vacío}$: Valor de la potencia invertida en pérdidas cuando el órgano trabaja en vacío, o sea cuando funciona con un flujo nulo de material procesado, expresada en watts.

$$N_{útil} = N_{corte_parcial} + N_{impulsión} \quad (16)$$

Donde:

$N_{corte_parcial}$: Potencia invertida en el proceso de corte parcial de la hoja, expresado en watts.

$N_{desprendimiento}$: Potencia invertida para desprender la parte blanda de la fibrosa, expresado en watts.

$N_{impulsión}$: Potencia invertida en la impulsión de las partículas cortadas, expresado en watts.

$N_{rozamiento}$: Pérdida de potencia producto del rozamiento en entre las fibras y al cuchilla, expresado en watts.

$$N_{vacío} = N_{aire} + N_{fricción} \quad (17)$$

Donde:

N_{aire} = Potencia necesaria para vencer la resistencia al aire, watts;

$N_{fricción}$ = Potencia necesaria para vencer la resistencia a la fricción de los rodamientos del órgano desfibrador aire, watts;

Según (Pérez de Corcho Fuentes *et al.*, 2009) unificando las ecuaciones para potencia de corte y potencia de vacío, expuestas en (Fernández y Martínez, 1988) se obtiene:

$$N_{útil} = \gamma \cdot V_a (R \cdot \omega)^2 + \varepsilon \cdot b \cdot R_t \cdot \omega \quad (18)$$

Donde:

γ : peso de la hoja por unidad de longitud, $\frac{kg}{m}$;

ε : energía de corte de la sección transversal de la hoja, $\frac{J}{m^2}$;

b : ancho de la hoja que coincide con el ancho de corte, m;

R_t : radio de trabajo, distancia del centro del eje del rotor al centro de esfuerzos, m.

2.2.4. Determinación de esfuerzo de corte parcial durante el desfibrado.

En la Figura 16 se representan las fuerzas que actúan sobre la hoja de agave en el plano perpendicular al plano de corte. En este, caso para el órgano de cilindro desfibrador se muestra el ángulo entre la dirección de la fuerza desprendimiento del material y la perpendicular a la línea de alimentación.

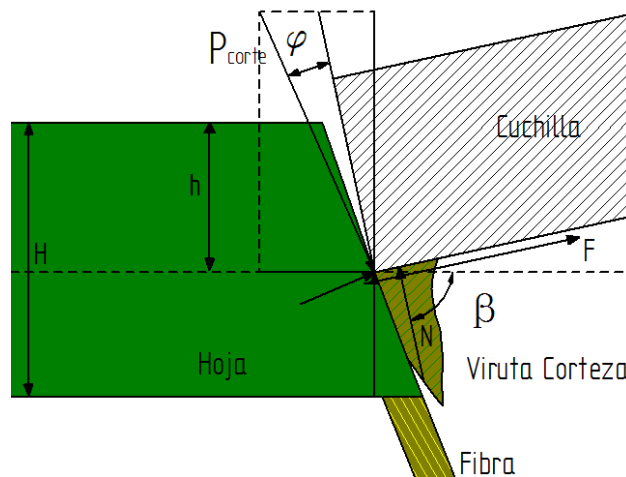


Figura 16. Esfuerzos de corte aplicados a la hoja de agave.

Como puede apreciarse sobre la hoja de agave actúan la fuerza de corte (P_{corte}) y la reacción en el soporte trasladado a la viruta de desprendida, descompuesta en una fuerza normal (N) y una de fricción (F). El trabajo que realiza la fuerza de corte se invierte en dos de las funciones del órgano

de trabajo. El trabajo que ejecuta la componente vertical de esta fuerza se invierte en el proceso de desfibrado propiamente dicho, mientras que el trabajo de su componente horizontal produce una energía cinética a la masa alimentada, disipándose además parte de este trabajo en el rozamiento provocado por la fuerza de fricción producida durante el arrastre de la masa (Srivastava *et al.*, 1993). Este proceso se describe por las siguientes expresiones:

$$P_{corte} = \delta \cdot \sigma_B + \left(\frac{E}{2 \cdot H} \right) \cdot h^2 [\tan\beta + \mu \cdot \text{sen}^2\beta + \nu(\mu + \text{cos}^2\beta)] \quad (19)$$

Donde:

δ : espesor del filo de la cuchilla: *mm*;

σ_B : resistencia del material bajo el filo de la cuchilla, *MPa*;

E : módulo de deformación del material, *MPa*;

H : espesor del materia al cortar, *mm*;

h : profundidad de penetración de la cuchilla en el material, *mm*;

β : ángulo del filo de la cuchilla, grados;

$\mu = \tan\varphi$: coeficiente de fricción;

ν : relación de Poisson.

2.2.5. Capacidad de paso del cilindro desfibrador.

La capacidad de paso se calcula según (Silveira Remus, 1982), como:

$$G = h_{m\acute{a}x} \cdot b \cdot l_{hoj} \cdot \gamma \cdot z \cdot n \quad (20)$$

Donde:

b – ancho de la hoja

γ - peso volumétrico de la hoja de *Agave angustifolia* Haw.

$h_{máx}$ - es el espesor máximo de la hoja que varía desde 5 a 80 mm.

2.3. Teoría de cálculo del órgano de alimentación de rodillos lisos rotatorios.

2.3.1. Condición para el agarre de las hojas y determinación de la presión del resorte de los rodillos.

Según (Miller, 1997), la distancia entre rodillos alimentadores se determina a partir de la condición de agarre de los rodillos, como:

$$s \geq h - D_r [1 - \cos(\phi)] \quad (21)$$




Figura 17. Esquema de compresión de las hojas de agave por los rodillos alimentadores.

Donde:

s - distancia entre rodillos.

D_r - diámetro de los rodillos.

ϕ - el ángulo de fricción entre el material de los rodillos y las hojas de agave.

El diámetro mínimo de los rodillos se determinará, como:

$$D_r > \frac{h - s}{1 - \frac{1}{\sqrt{1 + \tan^2(\phi)}}} \quad (22)$$

Conociendo que la cantidad de material suministrado por los rodillos al tambor desfibrador debe ser 0,5 a 0,7 veces la capacidad de paso del tambor, entonces se puede definir, que:

$$G_{alim} = (0,5 \text{ s } 0,7) \cdot Ga \quad (23)$$

Donde:

G_{alim} - capacidad de alimentación de los rodillos.

La longitud de trabajo de los rodillos se calculará, como:

$$L_r = \frac{G_{alim}}{\gamma \cdot \epsilon \cdot s \cdot V_a} \quad (24)$$

Donde:

ϵ - coeficiente de utilización del ancho de trabajo de los rodillos.

La velocidad de traslación de las hojas a través de los rodillos será menor que la velocidad tangencial de estos.

$$V_a = \eta \cdot u_r \quad (25)$$

Donde:

η - coeficiente que caracteriza el patinaje (0,8 a 0,9);

u_r - velocidad tangencial de los rodillos.

Para determinar la fuerza máxima que deben soportar los resortes que serán instalados en los extremos del rodillo superior para mantener una presión constante sobre el material se puede obtener de la ecuación.

$$\sigma_{m\acute{a}x} = \frac{P_{m\acute{a}x}}{A_{Rc}} \quad (26)$$

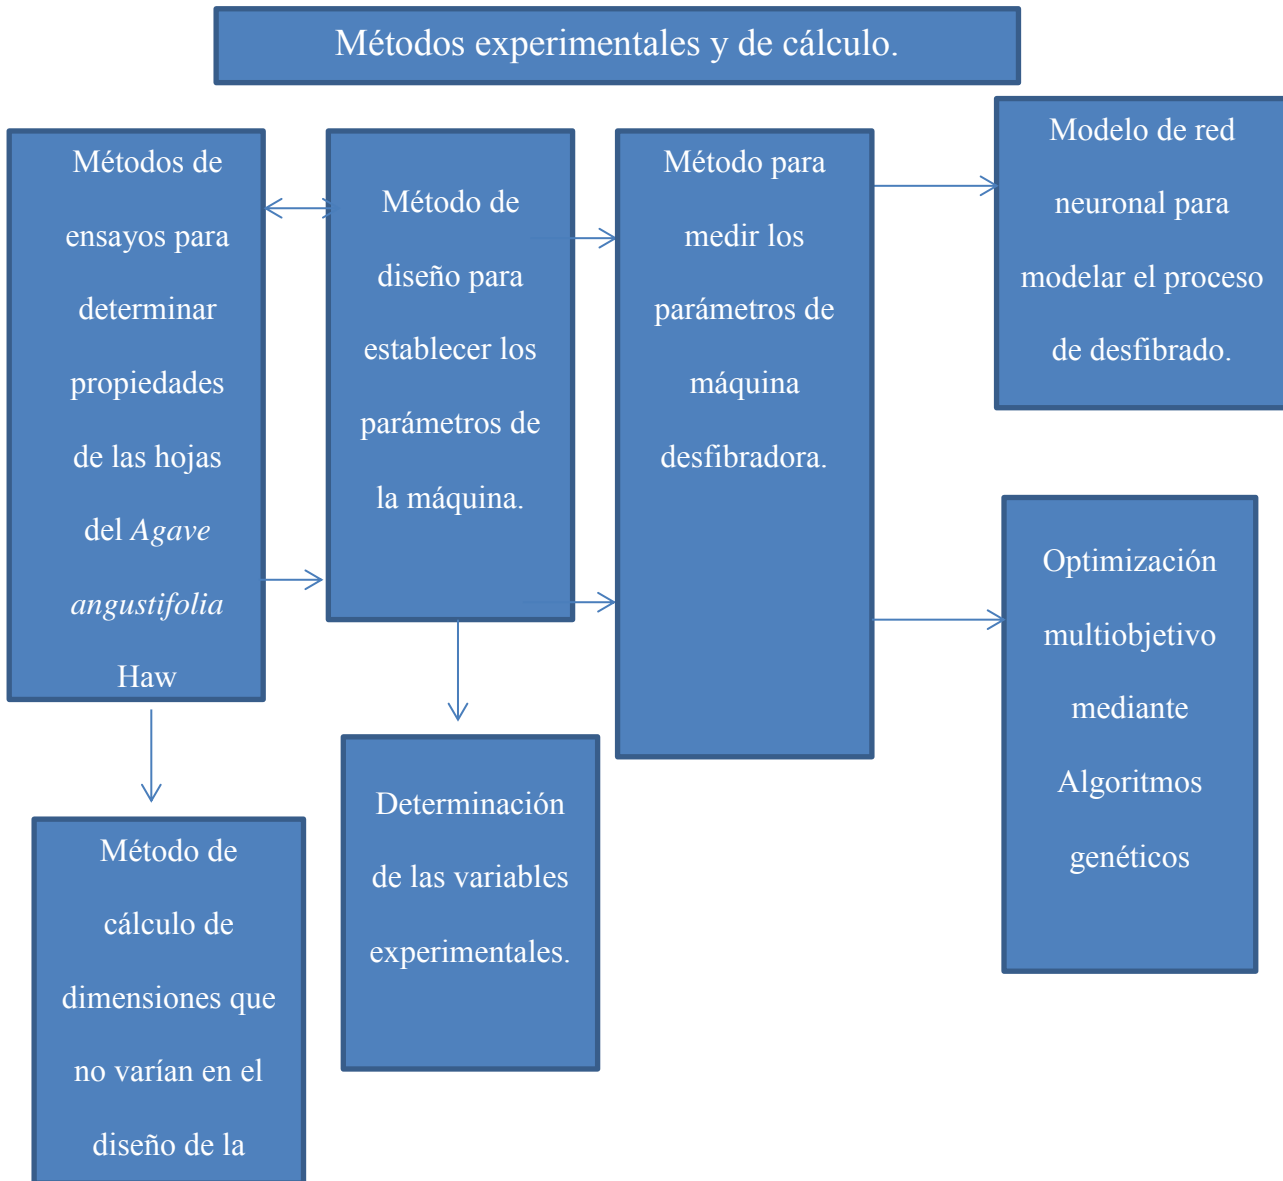
El área de contacto del rodillo A_{Rc} está determinada por el arco descrito por el cilindro mientras está en contacto con la hoja y por el ancho máximo de la hoja.

El cálculo del juego (a) entre los rodillos se realiza a partir del cumplimiento de la condición de “agarre” del componente que se desea pasar a través de los rodillos según la expresión (27) de condición de agarre (Miller, 1997).

$$a \geq dp - D(1 - \cos(\theta \times p)) \quad (27)$$

III. MATERIALES Y METODOLOGÍAS DE LAS INVESTIGACIONES EXPERIMENTALES.

Modelo de Investigación.



3.1. Métodos de experimentales para determinar propiedades de las hojas del *Agave angustifolia* Haw.

3.1.1. Propiedades físicas de las hojas de *Agave angustifolia* Haw.

En la Figura 18 se muestra un esquema de la hoja de *Agave angustifolia* Haw, se observan las variables que caracterizan dimensionalmente a las hojas, las que tienen de 50 cm a 120 cm de largo (L_{hoja}) y aproximadamente, de 4 cm a 8 cm de ancho. Además las hojas son lineales, rígidas, derechas, ascendientes, verdes o verde glucosa, hasta un verde amarillento, con márgenes casi derechos. Las espinas en la punta de la hoja son de 15 mm a 20 mm de largo, de color café oscuro y aplanadas por encima de la base, todo esto según, (NOM-168-SCFI, 2005).

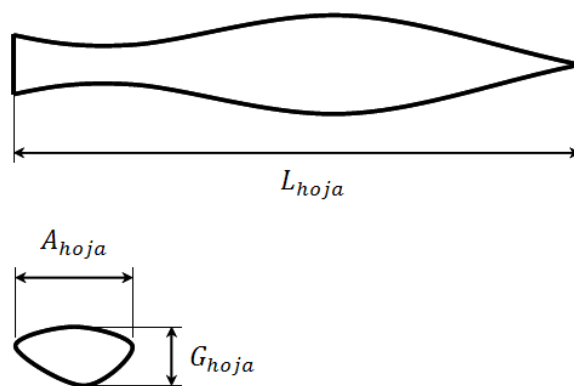


Figura 18. Esquema de la hoja de *Agave angustifolia* Haw.

De igual manera en la misma Figura 18 se muestra el ancho de la hoja A_{hoja} varía haciéndose mayor en el centro de la longitud de la hoja. El espesor o grueso de la hoja G_{hoja} es la distancia desde la superficie inferior o envés hasta la superficie superior, también varía haciéndose menor desde la base de la hoja hasta la espina (García Méndez, 2010).

Para realizar las mediciones de las hojas se utilizaron los instrumentos con los que se cuentan en el laboratorio de metrología del CIIDIR IPN Unidad Oaxaca. Para esta actividad se emplearon los siguientes instrumentos de medición:

Balanza granataria de dos brazos con capacidad máxima: 20 kg., precisión: 1 g.

Calibrador pie de rey digital con rango: 0 – 300 mm y precisión: 0.01 mm.

Flexómetro metálico con un Rango de 0 – 8 m y precisión de 1 mm.

3.1.2. Determinación de la resistencia a la compresión de las hojas de *Agave angustifolia* Haw y del *Agave fourcroydes*.

La selección de las hojas se realizó en plantaciones de *Agave Angustifolia* Haw en la región de los valles Centrales del Estado de Oaxaca, México. Las hojas se seleccionaron mediante la observación detallada y teniendo en cuenta, que no presentaran daños físicos, biológicos y mecánicos. Para la elaboración del experimento se consideró a norma (ASTM D 695, 2010). En dicha norma, se establecen las dimensiones de las probetas para llevar a cabo las pruebas de compresión. Las cuales fueron de 12.7X12.7X25.4 mm en dirección perpendicular y paralelas a las fibras y fueron cortadas con una cierra cinta de 12 pulgadas, marca CRAFTMAN modelo 22400 como se mostramos en la Figura 19, a una velocidad de la cinta de corte de 16 m/s.

Por otro lado las hojas de *Agave fourcroydes* fueron cosechadas en el propio CIIDIR-Oaxaca donde existe una plantación de dicha especie.




Figura 19. Corte de las probetas.

Los ensayos a compresión se realizaron en el laboratorio del Centro de Servicios de Alta Tecnología (CESAT), de la Universidad Popular Autónoma del Estado de Puebla (UPAEP). Todas las muestras fueron acondicionadas en el laboratorio a 20°C y 50% de humedad relativa, durante un periodo de 24 horas. Antes de iniciar los ensayos, todas las probetas fueron medidas por triplicado, en sus dos lados y su altura, como se muestra en la Figura 21.

Las variables en el ensayo a compresión fueron; el esfuerzo máximo (σ) reportado en megapascales (MPa) , la deformación unitaria (ϵ) expresada en porciento (%), el módulo de elasticidad (E) reportado en megapascales (MPa) y la energía de compresión T_C expresada en joules (J). La velocidad de compresión se estableció en 2.54 mm/min.




Figura 20. Máquina para ensayos estáticos Shimadzu modelo Autograph AGS-J



Figura 21. Mediciones de las probetas

3.1.3. Determinación del comportamiento a tracción de las hojas de *Agave angustifolia* Haw y *Agave fourcroydes*.

El método de ensayo empleado está diseñado para producir datos de propiedades de resistencia a la tracción para el control y la especificación de los materiales plásticos en muchos materiales, puede haber una especificación que requiere el uso de este método de ensayo , pero con algunas

modificaciones de procedimiento que tienen prioridad cuando se adhiere a la especificación según (ASTM D-4000, 2012).

La máquina de prueba empleada, Figura 22, de tipo de movimiento constante y comprende de las siguientes partes, un elemento fijo para realizar un pinzamiento y un elemento móvil que lleva una segunda empuñadura. Las mordazas que están unidas rígidamente a los elementos fijos y móviles de la máquina de ensayo. Para el ensayo se tuvo en cuenta asegurar que la muestra de ensayo se inserte y se sujeta de manera que el eje de la muestra de prueba coincide con la dirección de la tracción a través de la línea central del conjunto de agarre. Consiguiendo que el ensayo se llevó a cabo de tal manera que el deslizamiento relativo de las garras fue evitado en la medida de lo posible. En este caso la máquina tiene un mecanismo de accionamiento para impartir al elemento móvil una velocidad uniforme, controlada con respecto al miembro estacionario.



Figura 22. Máquina para ensayos Instron-3365.

Las probetas fueron elaboradas de un espesor de 7 mm, se realizaron pruebas a diez muestras, cinco normal y cinco paralelos con, el eje principal de la anisotropía.

Las probetas fueron revisadas para en caso de encontrar alguna anomalía en su estructura desecharla, las pruebas se realizaron a condiciones ambiente de $23 \pm 2^{\circ}\text{C}$ y $50 \pm 5\%$ de humedad relativa la precisión para el espesor fue de 0,025 mm utilizando los métodos de prueba aplicables en (ASTM D5947, 2011). La velocidad empleada fue de $5 [0.2] \pm 25\%$.

La resistencia a la tracción se determinó dividiendo la carga máxima en newtones por el área de sección transversal original de medio en el segmento de longitud de calibre de la muestra en metros cuadrados, el resultado se obtuvo en pascales y posteriormente se convirtió a megapascales.

El por ciento de alargamiento es el cambio en la longitud con relación a la longitud de referencia original de la muestra, y se obtiene dividiendo el cambio de longitud entre la extensión de la longitud de referencia original y multiplicar por 100. El módulo de elasticidad se determinó usando el área de la sección transversal media original

3.1.4. Determinación del comportamiento de las hojas de *Agave angustifolia* Haw al corte por cizallamiento.

Según (ASTM D 6110, 2010, pág.61) mediante una herramienta de corte cilíndrica se puede determinar la resistencia y el módulo de cizallamiento de un material compuesto con fibras Figura 23.




Figura 23. Herramienta para determinar la resistencia al corte por cizallamiento.

Con ayuda de la prensa Máquina Universal de ensayos estáticos marca Shimadzu modelo Autograph AGSJ, el cual tiene una resolución 0.0098 N y precisión ± 0.025 y cuenta con una celda de carga de 10 kN, así como con el procesador de datos integrado Trapzium Single. En el procesador del equipo se programó la velocidad de ensayo 1.3 mm/min, se acciona una herramienta de corte cilíndrica que provoca el corte por cizallamiento de las mismas. Con este procedimiento se podrá determinar tanto la resistencia como el módulo de cizallamiento de las hojas de agave. En este caso se determinó el módulo de cizallamiento en dirección paralela y perpendicular a la fibra. También se determinó la energía de corte por cizallamiento a partir de la integración de la curva fuerza-desplazamiento. Así como la obtención del gráfico esfuerzo-deformación (ASTM D 732-02, 2010).

3.1.5. Determinación del contenido de humedad de las hojas del Agave.

En base a la norma oficial mexicana NOM-116-SSA1-1994, bienes y servicios, en el laboratorio de suelos del CIIDIR IPN Unidad Oaxaca mediante procedimiento de tratamiento térmico con el método por arena o gasa y es aplicable a alimentos en general, con excepción de aquellos en los que se requiera una metodología específica. En este método se agrega arena o gasa, se incrementa la

superficie de contacto y la circulación del aire en la muestra, favoreciéndose así la evaporación durante el tratamiento térmico. El contenido de humedad en la muestra se calculó con la ecuación (28) y se encuentra expresada en por ciento (%):

$$humedad(\%) = \frac{M_2 - M_3}{M_2 - M_1} 100 \quad (28)$$

Donde:

M1 = Cápsulas de níquel con la gasa, secada durante 2 horas a $100 \pm 2^\circ\text{C}$.

M2 = Cápsula preparada y una cantidad de producto inferior a 10 g.

M3 = Cápsula preparada y el producto secadas durante 4 horas a $100^\circ \pm 2^\circ\text{C}$.

3.2. Método de diseño para establecer los parámetros de la máquina.

3.2.1. Selección de los mecanismos y componentes.

Para una correcta selección de los mecanismos y componentes de la desfibradora, más adecuados para los productores oaxaqueños, tomamos en cuenta primeramente las funciones principales que dicha máquina realiza. Durante el desfibrado ocurre un proceso de separación de la materia prima, en este caso las hojas de agave se separan en dos nuevos materiales, las fibras y la parte no fibrosa de la hoja. Esto da como resultado tres materiales durante el proceso, hojas, fibras y partes blandas. Por lo que en la figura 12 representamos el análisis de las funciones principales del desfibrado y las funciones secundarias.

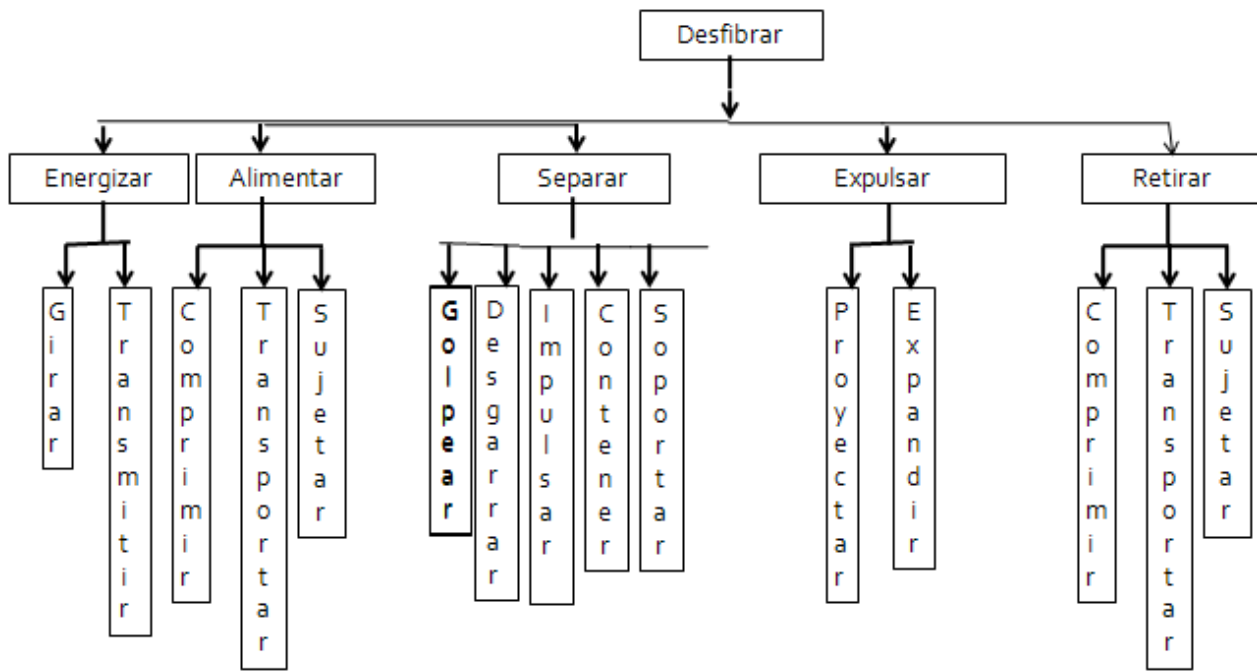


Figura 24. Diagrama de funciones para una máquina desfibradora.

Es importante apreciar que hay elementos que realizan varias funciones lo que contribuye notablemente a la simplificación de la máquina a diseñar, eliminando piezas y con ello el considerable ahorro del consumo de potencia.

3.2.2. Estudio morfológico de los elementos.

Para la selección de los componentes más adecuados durante el diseño de una máquina desfibradora de hojas de agave se realizó la carta morfológica para tener una apreciación primeramente visual de los diferentes elementos que aparece en ANEXO 1. Es importante tener en cuenta que hay elementos que realizan varias funciones lo que contribuye notablemente a la simplificación de la máquina a diseñar, eliminando piezas y con ello el considerable ahorro del consumo de potencia.

Para la selección del medio de potencia, encontramos que los más usados son los motores de combustión interna estacionarios, diésel o de gasolina y también lo motores eléctricos. La selección

de estos depende en gran medida de la organización que se le quiera dar al proceso de extracción de fibras de agave además de las condiciones de los productores. Las hojas de agave para ser transportadas necesitan un medio de carga bastante adecuado a las condiciones del terreno, a pesar de las elevaciones en la geografía de Oaxaca. Los productores han optado por transportar las piñas de agave del campo a la planta de Mezcal en camiones de poco tonelaje, los que se desplazan con facilidad por los caminos sinuosos de estas zonas, sería conveniente para el transporte de las hojas aprovechar también este tipo de transporte, lo que da la posibilidad de sacar las hojas del campo y tenerlas en un lugar adecuado para efectuar todo el proceso de su aprovechamiento además de los otros componente de la parte blanda de la hoja. De no emplear este medio de transporte, se necesitaría de animales de carga que lleven las hojas a una menor distancia, pero sería crear un problema para los productores que no disponen de los mismos ni de experiencia para su explotación. Una vez que las hojas son llevadas a un lugar como las Mezcalera, donde los productores cuentan con corriente eléctrica y disponibilidad de conexiones, lo más factible para una pequeña industria de extracción de fibras sería el uso de motores eléctricos tanto de conexión monofásica o trifásica, pues, en algunos de los casos ya cuentan con este tipo de servicio.

3.2.3. Selección de sistema de alimentación.

Es de gran importancia para la explotación de la máquina desfibadora un sistema de alimentación que no solo cumpla con las funciones mecánicas de proceso, sino que además garantice el cumplimiento de las normas de seguridad y protección del operario. Para garantizar la sujeción, desplazamiento y compresión de la hoja, se elige un sistema de alimentación compuesto por dos rodillos de presión constante y distancia variable que sea capaz mantener una presión constante a pesar de los distintos espesores de la hoja así como sujetar las fibras y extraerlas después de ser limpiadas. Para el momento de invertir la dirección de avance de las fibras es necesario desarrollar

un sistema mecánico de inversión del sentido de giro de los rodillos que sea eficiente preferentemente accionado con el pie para que permita al operario continuar utilizando sus manos en la sujeción de la hoja.

3.2.4. Determinación del consumo de energía durante el proceso de desfibrado.

Se medirá durante todo el proceso de desfibrado, es decir tanto en la entrada como en la salida de la hoja el valor de la intensidad de la corriente eléctrica en cada una de las fases mediante tres multímetros de gancho digitales, marca MITZU modelo MP 9600, para encontrar la energía consumida en el proceso según la ecuación (29) aplicando el método de los tres vatímetros (de Antonio, 2007).

$$E = \frac{v_c(I_1 + I_2 + I_3)\cos(\varphi)}{\sqrt{3}} t \quad (29)$$

Dónde:

$\cos(\varphi)$ - factor de potencia.

v_c - tensión eléctrica.

I_1 - Intensidad en el conductor 1.

I_2 - Intensidad en el conductor 2.

I_3 - Intensidad en el conductor 3.

3.2.5. Determinación de los parámetros cinemáticos del proceso de desfibrado.

La medición de la velocidad de corte de la cuchilla durante el proceso de desfibrado se determinó a partir mediante la velocidad de rotación del tambor desfibrador durante el trabajo en vacío, la cual se midió mediante un tacómetro digital de luz láser marca Atmel.

$$V_{corte} = \frac{\omega \pi R}{30} \quad (30)$$

Donde:

ω – frecuencia de rotación del órgano desfibrador

r_{rod} - radio del trabajo del órgano desfibrador.

Para determinar la velocidad de alimentación de las hojas se midieron los tiempos de entrada y salida de estas utilizando un cronómetro digital de precisión 0,01 s. Finalmente la velocidad de entrada se calculó, como:

$$V_{ent} = \frac{L_{hoj}}{T_{ent}} \quad (31)$$

Donde:

T_{ent} - tiempo de entrada de la hoja al órgano desfibrador.

L_{hoj} - longitud de la hoja desfibrada.

La velocidad de salida de la hoja se determinó, como:

$$V_{sal} = \frac{L_{hoj}}{T_{sal}} \quad (32)$$

Donde:

T_{sal} - tiempo de salida de la hoja al órgano desfibrador.

Método para variar la holgura de desfibrado.

La regulación de la holgura de desfibrado se realizó con un calibre de espesores el cual se colocó entre la cuchilla y la contracuchilla, como se muestra en Figura 25.



Figura 25. Ajuste de la holgura de desfibrado.

La holgura de desfibrado se varió en seis valores diferentes, siendo: $D_f=1,25$; 1,3; 1,5; 1,6 y 2 mm.

La regulación se hizo con ayuda de un calibre de espesores.

3.2.6. Determinación de los parámetros de calidad del desfibrado.

Primeramente se delimitó en la hoja la distancia a desfibrar, que en este caso fue de 1 m a partir del estrechamiento de la sección transversal, al excedente de hoja se le realizó un corte (Figura 26^a). A esta distancia se le adicionó una distancia adicional para el agarre, pues por motivos de seguridad no se efectuó el desfibrado de esta parte. Posteriormente la hoja fue dividida a la mitad en la dirección de las fibras como se muestra en la Figura 26b. Esta división se realizó con el propósito de evitar la forma cóncava de la hoja en su sección transversal, pues dada la rigidez de la hoja de este tipo de agave la hoja no quede asentada en la contracuchilla y dificulta el desfibrado. Finalmente estas porciones de las hojas fueron pesadas antes del desfibrado.



a)

b)

Figura 26. Preparación de las hojas de agave. a) Corte del excedente de la punta de la hoja. b) División longitudinal de la hoja.

Después del desfibrado se realizó el corte de las fibras, y se determinó el peso del agarre de la mitad de la hoja desfibrada, este agarre se corresponde con la parte cercana a la base de la misma que no fue desfibrada y se utilizó para empujar las hojas al interior de la máquina y luego retirarlas. Además se determinó, el peso de las fibras enteras junto al material de residuo que permanece adherido y también se determinó el peso de las fibras rotas. Posteriormente se realizó un secado de las fibras al sol durante 48 h, para determinar el peso de las fibras enteras secas y los residuos, así como, el peso de las fibras secas y limpias mecánicamente.

El porcentaje de material no fibroso de residuo húmedo se determinó de acuerdo con la ecuación (33).

$$\%Res(h) = \frac{(P_{fib} + P_{res}(h) - P_{fib}(s))100}{P_{fib} + P_{res}(h)} \quad (33)$$

El porcentaje de peso de fibras rotas en relación al peso total de fibras obtenidas se determinó, como:

$$\%Fib_r = \frac{P_{fib_r} 100}{P_{fib(s)} + P_{fib_r}} \quad (34)$$

Donde:

$P_{fib} + P_{res}(h)$ = Peso de total de fibras y material no fibroso (húmedos).

$P_{fib} + P_{res}(s)$ = Peso de total de fibras y material no fibroso (secos).

$P_{fibras}(secas)$ = Peso de fibras secas.

3.3. Método de entrenamiento de la red neuronal para para optimizar el diseño de la desfibradora de hojas de *Agave angustifolia* Haw.

Selección de las entradas y objetivos para el entrenamiento de la red neuronal.

Las variables de entrada de la red neuronal constituyeron los parámetros calidad del proceso de desfibrado. Modelo de red neuronal para optimizar el diseño de la desfibradora.




Figura 27. Variables geométricas y físicas del proceso de desfibrado.

Considere el diagrama de una máquina desfibradora como se muestra en la Figura 27, dentro de los parámetros tenemos:

5.4.1. Selección de los parámetros de la red neuronal.

En la Tabla 1, se puede apreciar los diferentes parámetros de selección para entrenar la red neuronal, los mismos se seleccionaron por tanteo y apreciando el error cuadrático medio en la validación del entrenamiento.

Tabla 1. Parámetros de tanteo para el entrenamiento.

Modelo	Capa oculta de entrada	Capa oculta de salida	Función de transferencia Capa entrada	Función de transferencia Capa de salida	Función de entrenamiento	Función de aprendizaje de pesos y tendencias	Función de desempeño	División de datos para el entrenamiento, validación, pruebas	Validación
Variantes	20-35	10-25	tansig, logsig, purelin	tansig, logsig, purelin	trainlm, trainbfg, trainrp	learngd, learnqdm	mse, msereg	70/100, 15/100, 15/100 80/100, 10/100, 10/100	-
Mejor combinación.	25	10	tansig	purelin	trainlm	learnqdm	mse	70/100, 15/100, 15/100	

El número de neuronas tanto de la capa oculta de entrada como de la capa oculta de salida se fueron tanteando de 5 en 5 neuronas.

IV. ANÁLISIS NUMÉRICO.

4.1. Características generales de los perceptrones multicapa.

De todas las posibles clases de RNAs, los perceptrones multicapa (PMC) son el tipo más popular y ampliado su aplicación en los problemas de modelado (Zhang *et al.*, 2003). Su principal atractivo reside en su habilidad para aproximar, con gran precisión, funciones multidimensionales genéricas que son continuas e integrables. Esta es, precisamente, la propiedad de las RNAs que más interesa en el caso presente. Además, los PMC también destacan por su simplicidad, y por la disponibilidad de un algoritmo rápido y robusto que facilita su entrenamiento. Pero por ahora, en esta sección, únicamente se describe la topología y el procesamiento de la información que realizan este tipo de sistemas.

Los PMC pertenecen a un tipo de RNAs más generales, muy comúnmente utilizadas en el modelado del comportamiento de sistemas físicos arbitrarios. Son las llamadas redes neuronales “feedforward”, que quiere decir que son alimentadas siempre hacia adelante. En estos sistemas, las neuronas se organizan en grupos ordenados, que fijan las posibles relaciones existentes entre las neuronas de la RNA. Estas posibles relaciones, se determinan en función de la posición del grupo al que pertenecen las neuronas, dentro de la ordenación. Así, cada grupo solamente puede recibir información de los grupos anteriores y/o del exterior, y enviar información, a su vez, únicamente a los grupos posteriores y/o al exterior.

Desde un punto de vista matemático, su organización interna y la manera de procesar la información, permiten la representación de una red neuronal “feedforward” mediante una función

$$n = n(x, w) \tag{35}$$

donde x es un vector de dimensión D , formado por las entradas externas o estímulos a la RNA, n es un vector de dimensión C , formado por las salidas de las neuronas de salida de la RNA, y w es un vector formado por todos los pesos de la RNA, estando cada peso asociado con un vínculo diferente de la RNA. Es decir, que este tipo de sistemas se pueden ver, como si se tratara de aplicaciones generales entre espacios multidimensionales. La manera de calcular n a partir de los vectores x y w , depende de la estructura concreta de la RNA “feedforward” que se utilice en un caso concreto: del número de neuronas con el que se cuente, del procesamiento de la información que estas realicen, y de las relaciones existentes entre ellas. Luego, una vez fijada la geometría, la relación entre entrada salida, x y n respectivamente, la determina, por completo, el valor de los pesos que forman el vector w , tal como se deduce de la ecuación (35).

En la Figura 28 se representa la estructura típica de un PMC. Las neuronas se representan mediante círculos, y los vínculos entre las neuronas y con el exterior mediante flechas. La dirección de las flechas se utiliza, entonces, para indicar el sentido que sigue flujo de la información que se produce entre las neuronas. Como se puede observar, las neuronas que forman el PMC se agrupan en grupos, que, en este caso, se disponen siguiendo una estructura de capas, una a continuación de la otra. En esta organización, las neuronas de cada capa se relacionan, únicamente, con las neuronas de las capas inmediatamente anterior y posterior. Cada neurona recibe información de las neuronas de la capa inmediatamente anterior, y envían su información procesada a las neuronas de la capa inmediatamente posterior, para que la procesen a su vez. Una excepción son las dos capas de neuronas más exteriores, cuyas neuronas se relacionan solo con las neuronas de la capa más próxima, anterior o posterior, y con el exterior.

A la capa de neuronas del PMC que recibe los estímulos desde fuera de la RNA, se la denomina capa de neuronas de entrada o, simplemente, capa de entrada. De manera análoga, a la capa de neuronas cuyas salidas son las salidas exteriores de la RNA, se la denomina capa de neuronas de salida o, simplemente, capa de salida. A las restantes capas de neuronas se las denomina capas ocultas o intermedias, y se las identifica mediante la posición que ocupan en la organización interna del PMC, siendo la capa de entrada la primera y la de salida la última. A la entrada externa número i del PMC se la representa mediante x_i , n_j representa a la salida externa número j del PMC, y z_i^l es la salida de la neurona número i de la capa de neuronas ocultas número 1 y L es el número total de capas de neuronas del PMC, y N_l es el número de neuronas en la capa número l . D es lo mismo que N_1 , el número de neuronas en la capa de entrada o capa número 1, y C lo mismo que N_L , el número de neuronas en la capa de salida o capa número L .




Figura 28. Estructura típica de un perceptrón multicapa.




Figura 29. Procesamiento de la información que realiza la neurona número i en la capa de neuronas número l de un perceptrón multicapas.

Tanto en la Figura 28 como en la Figura 29, se ilustra la manera en la cual un PMC general procesa la información que recibe. En la primera de estas figuras, se puede apreciar como el vector de entradas $\mathbf{x} = [x_1, x_2, \dots, x_D]^T$, el PMC calcula el vector de salidas correspondiente $\mathbf{n} = [n_1, n_2, \dots, n_C]^T$, a través de un proceso en el que la información fluye siempre en una misma dirección, hacia adelante. Las entradas exteriores alimentan, en un primer momento, las neuronas de entrada o capa número 1 del PMC. Luego, esta capa de neuronas alimenta, con sus salidas, a las neuronas ocultas que forman la capa número 2 del PMC. A continuación, esta capa número 2 produce nuevas salidas, con las que se alimenta la siguiente capa de neuronas del PMC. Y así se procede de manera sucesiva, hasta llegar a las neuronas de la capa de salida, o capa número L del PMC, cuyas salidas son las salidas externas de la RNA.

$$n_i = z_i^L ; i = 1, 2, \dots, C \quad (36)$$

Por otro lado, en la Figura 29, se representa la forma en la que una neurona particular, oculta o de salida, procesa la información que recibe para producir una salida. Se considera para ello el caso

general de la neurona número i , en la capa de neuronas número l del PMC. En primer lugar, esta neurona recibe los estímulos

$$z_1^{l-1}, z_2^{l-1}, \dots, z_{N_{l-1}}^{l-1} \quad (37)$$

que son las salidas de las neuronas en la capa $l - 1$; y el estímulo fijo que se denomina estímulo de “bias”.

$$z_0^{l-1} = 1 \quad (38)$$

Entonces, cada uno de estos estímulos se multiplica por el peso correspondiente. En el caso de un estímulo procedente de una neurona en la capa anterior, se multiplica por el peso asociado al enlace entre la neurona actual, y la neurona anterior que produce el estímulo que se considera. Mientras, para el estímulo de “bias”, se multiplica por un peso propio, asociado al enlace entre el generador del estímulo de “bias” y la neurona actual.

Luego, los productos resultantes se combinan entre sí para producir la suma pesada

$$\gamma_i^l = \sum_{j=0}^{N_{l-1}} \omega_{ij}^l \times z_j^{l-1} \quad (39)$$

Finalmente, se hace pasar el resultado de esta suma a través de una función de activación, γ , para producir el resultado final de la neurona

$$z_i^l = \sigma(\gamma_i^l) \quad (40)$$

Por último, en lo que se refiere a las neuronas de la capa de entrada al PMC, estas se utilizan, únicamente, para retransmitir el estímulo exterior a la primera capa de neuronas oculta del PMC. Es

decir, que el procesamiento de la información que realizan las neuronas de entrada, expresado matemáticamente, es simplemente

$$z_i^1 = x_i; i = 1, 2, \dots, D \quad (41)$$

Por consiguiente, hay textos en donde estas neuronas no se consideran como tales, ni como parte alguna del PMC. Entonces, en esos textos, la primera capa de neuronas ocultas se convierte en la capa de neuronas número 1 del PMC. Aquí se ha preferido guardar las neuronas de entrada como parte del PMC, ya que existen pesos asociados a los enlaces entre las salidas de esas neuronas, y las entradas de las neuronas de la primera capa de neuronas intermedias.

4.1.1. Funciones de activación.

El tipo de funciones de activación que utilizan los PMC, constituyen un rasgo identificativo que los diferencia de otros tipos de RNAs “feedforward”. Las funciones de activación que se utilizan en este caso, son funciones matemáticas que intentan emular el comportamiento que se observa en las neuronas biológicas, en respuesta a los estímulos recibidos. Este comportamiento consiste, en una primera aproximación, simplemente en la activación o no activación de la respuesta de la neurona. Otros tipos de RNAs “feedforward” utilizan, sin embargo, funciones matemáticas más generales, que poco tienen que ver con los comportamientos de los sistemas nerviosos de los seres vivos. Ejemplos de otros tipos son las redes neuronales radiales y las redes neuronales “wavelet”, que utilizan como funciones de activación, de manera respectiva, las funciones a las que se hace referencia en sus nombres.

Normalmente, en las neuronas ocultas de un PMC se utiliza una misma función de activación en todas ellas. También es posible el uso de funciones de activación diferentes, aunque esto no parece proporcionar ningún tipo de ventaja. Al contrario, el manejo del PMC se puede ver dificultado al tener que determinar, para cada neurona diferente, la función de activación que se debe de utilizar. Mientras, en las neuronas de salida, se suele preferir la utilización de un tipo de funciones de activación, diferente del que se utiliza en las neuronas

ocultas. Con ello se busca adaptar el funcionamiento de unas y otras neuronas, a las diferentes tareas que cada grupo desempeña en la RNA.

La función de activación más comúnmente utilizada en las neuronas ocultas, es la función

Sigmoidea.

$$\sigma(\gamma) = \frac{1}{(1 + e^{-\gamma})} \quad (42)$$

Esta es, como se muestra en la Figura 30, una función con forma de S que posee las propiedades asintóticas.3




Figura 30. Función sigmoidea.

$$\sigma(\gamma) \rightarrow \begin{cases} 1 & \text{cuando } \gamma \rightarrow +\infty \\ 0 & \text{cuando } \gamma \rightarrow -\infty \end{cases} \quad (43)$$

Otras posibles funciones de activación, que también se utilizan en las neuronas ocultas, son: la función arco-tangente.

$$\sigma(\gamma) = \left(\frac{2}{\pi}\right) \arctan(\gamma) \quad (44)$$

Función tangente-hiperbólica.

$$\sigma(\gamma) = \frac{(e^\gamma - e^{-\gamma})}{(e^\gamma + e^{-\gamma})} \quad (45)$$

$(e^\gamma + e^{-\gamma})$ y otras funciones con propiedades parecidas. Todas ellas son funciones con forma de S, acotadas, continuas, monótonas e infinitamente diferenciables. En las neuronas de salida se pueden emplear, en principio, el mismo tipo de funciones de activación que se utilizan en las neuronas ocultas. Sin embargo, se prefiere, por lo general, el empleo de la simple función identidad, Figura 31.




Figura 31. Función identidad.

$$\sigma(\gamma) = \gamma \quad (46)$$

De esta manera se evitan dos circunstancias no deseables, derivadas de la utilización de funciones de tipo sigmoideo en las neuronas de salida de una RNA. En primer lugar, al tratarse de funciones que son acotadas, se está restringiendo el intervalo de valores que pueden tomar las salidas de la RNA. Por consiguiente, se puede hacer necesario modificar esos intervalos, para ajustarlos al problema concreto que se esté a tratar. La otra dificultad, proviene del comportamiento asintótico que se observa poseen las funciones de tipo sigmoideo. En este caso, si se necesita que una salida de la RNA tome un valor muy próximo a uno de los límites asintóticos, se hace obligatorio moverse en los límites $\gamma \rightarrow \pm\infty$, donde la función de activación es casi constante.

4.1.2. Entrenamiento de la red neuronal.

El entrenamiento es el proceso a través del cual la RNA, aprende, o modela, el comportamiento de un determinado fenómeno. Existen algunos procesos de entrenamiento, aunque no muy desarrollados, que incluyen el ajuste simultáneo, tanto de la topología como de los parámetros libres o pesos de la RNA (Yao y Liu, 1997). Sin embargo, lo más normal es que se fije primero el tipo y la estructura de la RNA que se va a utilizar, basándose en la experiencia y en la intuición, y que a continuación se ajusten los parámetros libres de la misma. Luego, si no se consigue el resultado deseado, se modifica la topología de la RNA y se reinicia el proceso.

Primeramente, para entrenar la RNA se hace necesario obtener un conjunto muestras representativo del comportamiento que se quiere modelar, que se utilizará como patrón para el ajuste. A este conjunto se le denomina conjunto de datos de entrenamiento, o simplemente conjunto o datos de entrenamiento. Para el caso del proceso de desfibrador, este está formado por un conjunto de pares como en la ecuación (47),

$$\{(x^k, t^k), k \in T\} \quad (47)$$

donde T representa el conjunto de índices de los datos de entrenamiento, siendo t^k un vector que se obtiene a partir de x^k según la ecuación:

$$t^k = f_D(x^k) \quad (48)$$

Donde: f_D es, típicamente, un modelo del desfibrado, para el comportamiento de los parámetros que definen la calidad del desfibrado.

La generación de un conjunto de entrenamiento, conlleva la toma de decisiones referentes al tamaño de ese conjunto, y a la distribución de sus componentes. El conjunto de datos de entrenamiento que se obtenga, debe ser representativo del comportamiento que se desea modelar. Por tal motivo, se necesitan más datos para el modelado de los comportamientos más complejos, que varían más rápido, que los que se necesitan para los casos más sencillos, en los que la variación es más suave. Si el tamaño del grupo resulta excesivamente

pequeño, dada la complejidad del comportamiento a modelar, o si su distribución no sigue un esquema adecuado, no se podrá conseguir que la RNA resultante del entrenamiento muestre una buena generalización. Así, cuando se observa que la precisión del modelo que se ha desarrollado no es la adecuada, en puntos diferentes a los del entrenamiento, es que se necesitan determinar nuevas muestras que añadir a aquellas de las que ya se dispone. Por el contrario, llega un momento en el cual, la obtención de más datos, ya apenas sirve para mejorarla realización del modelo que se consigue; pues la información que se obtiene con cada nueva muestra resulta, en su mayor parte, completamente redundante. Entonces, conviene intentar ahorrar, en la medida de lo posible, en la generación de los datos de entrenamiento; pues esta generación implica, generalmente, la utilización de métodos experimentales, que requieren tiempos de cálculo elevados. Por consiguiente, se hace necesario lograr un equilibrio en el número de muestras que se obtienen: ni muy pocas que impidan la consecución de un modelo preciso en todo el dominio, ni demasiadas que con bastantes menos se llegue casi que a igual resultado.

Una vez que se dispone de los datos necesarios, el siguiente paso para el entrenamiento de la RNA, consiste en el ajuste de los parámetros peso de la misma. Para ello se define primero una función de coste, E , que penalice las desviaciones, para un vector de pesos dado, entre las predicciones de la RNA y el conjunto de entrenamiento. Lo más normal es utilizar una función de coste que, de forma matemática, se pueda expresar mediante una suma.

$$E = \sum_{k \in T} E^k \quad (49)$$

Donde: E^k es una función que penaliza, para la muestra número k del conjunto de entrenamiento, la desviación entre las predicciones de la RNA y los propios datos de entrenamiento. En el caso más común, se define, simplemente, una suma cuadrática de errores.

$$E = \frac{1}{2} \times \sum_{k \in T} \|n^k \times (w) - t^k\|^2 \quad (50)$$

donde n^k es el vector de predicciones del modelo neuronal, función del vector de pesos w , cuando a éste se le presenta la geometría del dispositivo dada por el vector x^k . Luego de esta definición, se puede iniciar ya el proceso de entrenamiento de la RNA propiamente dicho, que se aborda como si se tratara de un problema de optimización. El objetivo que se persigue es determinar un vector de pesos adecuado, que proporcione un buen ajuste entre la RNA utilizada, y los datos contenidos en el conjunto de entrenamiento. Por ello, el problema que se plantea es la minimización, mediante el ajuste de los pesos de la RNA, de la función de coste que se ha definido. Así, el entrenamiento de la RNA se convierte en un problema de optimización, que se puede solventar con los algoritmos de optimización normales, que se utilizan para la resolución de ese tipo de problemas (Press *et al.*, 2007).

Por último, un punto muy importante para que el entrenamiento de una RNA resulte satisfactorio, y que todavía no se ha comentado, es la selección de un grado de complejidad adecuado para la RNA que se utilice. Esto es, el número de pesos de la RNA, que es proporcional a su grado de complejidad. Por un lado, las RNAs demasiado sencillas, no son capaces de aproximar las relaciones entrada-salida más complicadas, porque no pueden alcanzar el grado de complejidad que poseen esos comportamientos. Mientras, por otro lado, las RNAs demasiado complejas, aunque capaces de modelar con precisión la totalidad de los datos de entrenamiento de que se dispone, dan lugar a errores grandes en puntos diferentes a estos. Por consiguiente, se necesita encontrar un equilibrio en el número de parámetros libres internos de la RNA, los pesos, que tienen que ser los suficientes para alcanzar una alta precisión en los puntos de entrenamiento, y los suficientemente pocos que eviten que la RNA entrenada muestre una pobre generalización.

4.1.3. Algoritmo de retropropagación.

El problema del aprendizaje de PMC es de encontrar los pesos W que capturan la correspondencia implícita de entradas/salidas en un conjunto de datos de ejemplos, donde se usa como función objetivo, la suma de errores cuadráticos de las salidas (Rojas, 1996).

$$J(W) = \sum_{n=1}^{N_{EX}} \sum_{k=1}^{N_O} \frac{1}{2} \left(t_k^{(n)} - y_k^{(2)(n)} \right)^2 \quad (51)$$

Donde: $t_k^{(n)}$ es el objetivo deseado de la k^n neuronas de salida para el ejemplo n^n .

$y_k^{(2)(n)}$ es el resultado de la k^{th} salida neurona para la n^{th} ejemplo.

La retro-propagación aprende los pesos a través del gradiente de descenso.

$$w = w + \Delta w = w - \eta \frac{\partial J(W)}{\partial w} \quad (52)$$

La expresión $\frac{\partial J(W)}{\partial w}$ para cada peso en términos de las entradas x_i , las salidas del PMC $y_k^{(2)}$ y los objetivos t_k .

Teniendo en cuenta que W denota el conjunto de todos los pesos en el PMC, mientras que w indica un peso individual por tanto la derivación de un ejemplo ($N_{EX} = 1$), lo que nos permite colocar la suma externa.

$$\partial J(W) = \sum_{k=1}^{N_O} \frac{1}{2} \left(t_k - y_k^{(2)} \right)^2 \quad (53)$$

Cálculo de $\frac{\partial J}{\partial w}$ usando los pesos H-O la regla de la cadena, la derivada de (W) de un peso H-O es:

$$\frac{\partial J(W)}{\partial w_{jk}^{(2)}} = \frac{\partial J(W)}{\partial y_k^{(2)}} \frac{\partial y_k^{(2)}}{\partial net_k^{(2)}} \frac{\partial net_k^{(2)}}{\partial w_{jk}^{(2)}} \quad (54)$$

Se determina por separado cada uno de estos términos.

$$\frac{\partial J(W)}{\partial y_k^{(2)}} = \frac{\partial}{\partial y_k^{(2)}} \left[\sum_{n=1}^{N_o} \frac{1}{2} (y_n^{(2)} - t_n)^2 \right] = (y_k^{(2)} - t_k) \quad (55)$$

$$\frac{\partial y_k^{(2)}}{\partial net_k^{(2)}} = \frac{\partial}{\partial net_k^{(2)}} \left[\frac{1}{1 + \exp(-net_k^{(2)})} \right] = \frac{\exp(-net_k^{(2)})}{(1 + \exp(-net_k^{(2)}))^2} = (1 - y_k^{(2)})y_k^{(2)} \quad (56)$$

$$\frac{\partial net_k^{(2)}}{\partial w_{jk}^{(2)}} = \frac{\partial}{\partial w_{jk}^{(2)}} \left[\sum_{n=1}^{N_H} (w_{nk}^{(2)} y_n^{(1)}) \right] = y_j^{(1)} \quad (57)$$

Combinando las derivadas de los productos.

$$\frac{\partial J(W)}{\partial w_{jk}^{(2)}} = (y_k^{(2)} - t_k)(1 - y_k^{(2)})y_k^{(2)}y_j^{(1)} \quad (58)$$

Para los pesos de las tendencias, se utiliza $y_j^{(1)}$ en la expresión anterior.

Cálculo de $\frac{\partial J}{\partial w}$ los pesos I-H.

Usando la regla de la cadena, la derivada de $J(W)$ de un peso I-H es:

$$\frac{\partial J(W)}{\partial w_{ij}^{(1)}} = \frac{\partial J(W)}{\partial y_j^{(1)}} \frac{\partial y_j^{(1)}}{\partial net_j^{(1)}} \frac{\partial net_j^{(1)}}{\partial w_{ij}^{(1)}} \quad (59)$$

Los términos de 2ª y 3ª son fáciles de calcular desde el resultado anterior:

$$\frac{\partial y_j^{(1)}}{\partial net_j^{(1)}} = (1 - y_j^{(1)})y_j^{(1)} \quad (60)$$

$$\frac{\partial net_j^{(1)}}{\partial w_{ij}^{(1)}} = x_i$$

El primer término, sin embargo, no es sencillo debido a que no sabemos lo que deberían ser que esto se conoce como el problema de asignación de crédito. La solución radica en darse cuenta de que las neuronas H no generan errores, sólo contribuyen a errores en los nodos de salida.

La derivada del error con respecto a la salida de un nodo oculto es, por tanto, la suma de las contribuciones de los nodos ocultos al error de todas las neuronas de salida.

$$\frac{\partial J(W)}{\partial y_j^{(1)}} = \sum_{k=1}^{N_o} \frac{\partial J(W)}{\partial y_n^{(2)}} \frac{\partial y_n^{(2)}}{\partial net_n^{(2)}} \frac{\partial net_n^{(2)}}{\partial y_j^{(1)}} \quad (61)$$

Los dos primeros términos de la suma se conocen desde nuestra anterior derivación.

$$\frac{\partial J(W)}{\partial y_n^{(2)}} \frac{\partial y_n^{(2)}}{\partial net_n^{(2)}} = (y_n^{(2)} - t_n)(1 - y_n^{(2)})y_n^{(2)} = p_n \quad (62)$$

El último término en la sumatoria es:

$$\frac{\partial net_n^{(2)}}{\partial y_j^{(1)}} = w_{jn}^{(2)} \quad (63)$$

Combinar el producto de estas derivadas.

$$\frac{\partial J(W)}{\partial y_j^{(1)}} = \sum_{k=1}^{N_o} \frac{\partial J(W)}{\partial y_n^{(2)}} \frac{\partial y_n^{(2)}}{\partial net_n^{(2)}} \frac{\partial net_n^{(2)}}{\partial y_j^{(1)}} = \underbrace{(y_n^{(2)} - t_n)(1 - y_n^{(2)})y_n^{(2)}}_{p_n} w_{jn}^{(2)} \quad (64)$$

Esto puede ser visto como la forma de propagar el término p_n de error, hacia atrás, a través de la $H - O$,
Figura 32.




Figura 32. Pesos entre las entradas (inputs) y las capas ocultas (I-H)

Y es la expresión final de $\frac{\partial J(W)}{\partial w}$ para los pesos I-H

$$\frac{\partial J(W)}{\partial w_{ij}^{(1)}} = \left[\sum_{n=1}^{N_H} (y_n^{(2)} - t_n)(1 - y_n^{(2)})y_n^{(2)}w_{jn}^{(2)} \right] (1 - y_j^{(1)})y_j^{(1)}x_i \quad (65)$$

Para los pesos de las tendencias, utilice $x_i = 1$ en la expresión anterior.

Una de las principales limitaciones de la propagación hacia atrás son los mínimos locales. Cuando el algoritmo de gradiente descenso alcanza un mínimo local, el gradiente se convierte en cero y los pesos convergen en una solución que no es totalmente óptima. Un método muy popular para evitar mínimos locales es calcular una dirección media temporal en la que los pesos se han movido recientemente.

Una manera fácil de implementar esto es mediante una media exponencial:

$$\Delta w(n) = \mu[\Delta w(n - 1)] + (1 - \mu) \left[\eta \frac{\partial J(w)}{\partial w} \right] \quad (66)$$

El término μ se llama impulso que tiene un valor entre 0 y 1 (normalmente 0,9) cerca de 1 presenta la influencia instantánea más fuerte en la dirección de descenso.




Figura 33. Curva de impulso.

El término de impulso también es útil en espacios con largas pendientes caracterizadas por fuertes curvaturas en el la parte inferior y una superficie suavemente inclinada.




Figura 34. Curva de impulso sobre la superficie de error.

Resulta que las curvaturas no son infrecuentes en problemas de optimización, por lo que el uso de impulso puede ser útil en muchas situaciones. Sin embargo, el término impulso puede repercutir cuando la búsqueda es cercana a los mínimos. Como la red acerca a la parte inferior a superficie de error genera suficiente impulso para propulsar los pesos en la dirección opuesta, creando una oscilación indeseable que se traduce en más convergencia lenta.

Una curvatura estrecha tiende a causar oscilaciones divergentes en la quebrada. Para evitar este problema, se puede disminuir la tasa de aprendizaje, pero esto es demasiado lento. El término impulso filtra la curvatura alta y permite a las medidas de pesos efectivos ser más grandes.

4.1.4. Otras mejoras en la adaptación de las tasas de aprendizaje

En lugar de tener una tasa única de aprendizaje para todos los pesos, el PMC permite ,que cada peso tenga su tasa de aprendizaje, en particular, dejemos que la tasa de aprendizaje se adapte con base en el rendimiento de los pesos durante el entrenamiento. Si la dirección en que $J(W)$ disminuye, el peso es igual que en el anterior y aumenta la tasa de aprendizaje. De lo contrario se reduce.

La dirección de $\delta(n)$ en cual el error decrece en un tiempo n esta dado por el signo de $\frac{\partial J}{\partial w}$.

La dirección $\bar{\delta}(n)$ en cual el error decrecer es computado como la media exponencial de (n) .

$$\bar{\delta}(n + 1) = \theta \bar{\delta}(n) + [1 - \theta] \delta(n) \quad (67)$$

Para determinar si la dirección actual y la dirección reciente coinciden con el producto computado entre (n) y $\bar{\delta}(n)$ se deben cumplir las condiciones siguientes.

- Si el producto es mayor que 0, los signos son los mismos
- Si el producto es menor que 0, los signos son diferentes

Basado en el producto escalar, las tasas de aprendizaje están adaptadas de acuerdo a la siguiente regla:

$$\eta(n) = \begin{cases} \eta(n - 1) + \kappa & \text{if } \bar{\delta}(n)\delta(n) > 0 \\ \eta(n - 1)\Psi & \text{if } \bar{\delta}(n)\delta(n) \leq 0 \end{cases} \quad (68)$$

κ es una constante que se agrega a la tasa de aprendizaje si la dirección no ha cambiado.

Ψ es una fracción que se multiplica por la tasa de aprendizaje si ha cambiado la dirección.

Suponiendo también la duración del impulso, la expresión final para el cambio de peso cambia a:

$$\Delta w(n) = \mu[\Delta w(n - 1)] + (1 - \mu) \left[\eta(n) \frac{\partial J(w)}{\partial w} \right] \quad (69)$$

La naturaleza de adaptación de η se hace explícita por lo que es una función del tiempo (n)

4.1.5. Limitación de la complejidad de la red y determinación del número de capas ocultas.

Dado un número suficientemente grande de neuronas ocultas, dos capas de un PMC se pueden aproximar arbitrariamente bien a cualquier función continua. La Figura 35 muestra es una combinación de cuatro neuronas ocultas que puede producir un “impacto” en el espacio de salida de un PMC dos capas.




Figura 35. Perceptrón multicapas de dos capas (Duda *et al.*, 2001)

Un número considerable de impactos puede aproximar arbitrariamente bien cualquier superficie. Sin embargo, la adición de capas ocultas extra puede permitir al PMC aproximarse de manera más eficiente, es decir, con menos pesos (Bishop, 1995)




Figura 36. Perceptrón multicapas de dos, tres y cuatro capas (Bishop, 1995).

4.1.6. Número de neuronas ocultas.

Mientras el número de entradas y salidas son definidas por el problema el número de neuronas ocultas N_H no está relacionado de forma tan explícita con el dominio de la aplicación por lo que N_H determina los grados de libertad o la potencia expresiva del modelo. Un N_H pequeño puede no ser suficiente para modelar complejas asignaciones de entradas y salidas. Un N_H grande puede sobre ajustar los datos de entrenamiento y evitar que la red se generalice a nuevos ejemplos.

El N_H “óptimo” depende de múltiples factores, incluyendo el número de ejemplos, nivel de ruido en la formación a entrenar, la complejidad de la clasificación del problema, número de entradas y salidas, las funciones de activación y algoritmo de entrenamiento. En la práctica, varios PMC son entrenados y evaluados para determinar un adecuado N_H .

4.1.7. Deterioro de los pesos

Para impedir que los pesos lleguen a un valor demasiado grande (como signo de n sobre entrenamiento) es conveniente añadir el deterioro de los impulsos por la fórmula:

$$w(n + 1) = (1 - \epsilon)w(n) \quad (70)$$

Pesos que no son necesarios eventualmente decaimiento a cero, Considerando necesarios pesos se actualizan continuamente por la propagación hacia atrás.

Desintegración de peso es una forma simple de regularización, que alienta a asignaciones de red más suaves (Bishop, 1995).

4.1.8. Detención temprana.

Parar temprano puede utilizarse para impedir el sobre entrenamiento del PMC por el conjunto de entrenamiento. El punto de parada puede determinarse mediante la supervisión del suma-cuadrado-error de PMC en una validación establecida durante el entrenamiento.

4.2. Teoría del algoritmo genético.

4.2.1. Algoritmo genético simple

El algoritmo evolutivo básico da lugar a una gran variedad de modelos, dependiendo de cómo se especifique la forma de representación de los individuos (codificación) y los operadores genéticos de selección, recombinación y mutación. El algoritmo genético original propuesto junto a algunas de sus variantes se fundamenta teóricamente en el teorema de los esquemas (Glover, 1986) .

El algoritmo genético simple aplica a problemas de optimización de parámetros continuos de la forma:

$$\begin{aligned} \min f(x_{k1}, x_{k2}, \dots, x_{kn}), \\ x_{ki} \in [l_i, u_i] \in \mathfrak{R}, l_i < u_i, \forall i = 1, \dots, n, \end{aligned} \tag{71}$$

donde cada componente x_{ki} tiene un dominio definido por una cota inferior l_i y una cota superior por lo tanto el espacio de búsqueda es un subconjunto \mathfrak{R}^n (Bäck, 1994).

A continuación se especifica un algoritmo genético simple y se explican brevemente sus fundamentos.

Representación y función de adaptación

Un punto de búsqueda $\vec{x}_k = (x_{k1}, x_{k2}, \dots, x_{km})$, se representa mediante una tira binaria (binary string). Cada una de las n componentes del vector se codifica en binario usando ℓ bits. Luego las representaciones binarias de cada parámetro se concatenan en una sola tira, obteniéndose individuos de largo $\ell = nb$ bits.

El algoritmo genético considera una población inicial de M tiras binarias de largo ℓ generadas aleatoriamente. Para evaluar el desempeño de estos individuos se requiere decodificar cada componente representada en binario al entero correspondiente entre 0 y $b^b - 1$ y luego rescatarlo en el intervalo real correspondiente al dominio de esa componente según (1). Durante el proceso evolutivo, el algoritmo genético genera una nueva población de tamaño M a partir de la población actual y evalúa el desempeño de los nuevos individuos. Este mecanismo de codificación implica que en el espacio original continuo sólo se realiza una búsqueda con una grilla de puntos. La precisión de esta búsqueda depende del número de bits utilizados para la codificación de los parámetros.

Métodos de Selección

El mecanismo de selección permite orientar la búsqueda a aquellos puntos más promisorios, i.e. con la mayor adaptación observada hasta el momento. El operador de selección genera a partir de la población actual una población intermedia del mismo tamaño, reproduciendo con un mayor número de copias a los individuos más aptos y eliminando o asignando un menor número de copias a los individuos menos aptos. El operador de selección no produce puntos nuevos en el espacio de búsqueda, sino que determina qué individuos dejarán descendencia y en qué cantidad en la próxima generación.

El algoritmo genético simple utiliza una regla de supervivencia probabilística donde la estrategia óptima de selección consiste en aumentar exponencialmente el número de copias del mejor individuo observado respecto al peor. Este método se conoce como selección proporcional.

1. Selección Proporcional

La probabilidad de selección $p_{i,t}$ del i -ésimo individuo en la población $P_{(t)}$ depende de la adaptación relativa de éste con respecto a la población:

$$P_{i,t} = \frac{f_i}{n_{j=1}f_j} \quad (72)$$

donde f_j es la adaptación del j-ésimo individuo.

El número esperado de copias N_e del i-ésimo individuo en la próxima generación es:

$$N_e [i] = Mp_{i,t} = \frac{f_i}{\bar{f}_t} \quad (73)$$

Donde \bar{f}_t es la adaptación promedio de la población $P_{(t)}$, y M es el tamaño de ésta.

La fase de selección de un algoritmo genético basado en valores esperados se compone de dos partes, la primera es la determinación de los valores esperados N_e y luego la conversión de los valores esperados a números discretos de descendencia (muestreo).

El algoritmo de muestreo debe mantener una población constante y al mismo tiempo proveer de un muestreo exacto, consistente y eficiente. El algoritmo de muestreo se conoce como el método de la ruleta.

2. Método de La ruleta:

- Determinar la suma S de las adaptaciones de toda la población.
- Relacionar uno a uno los individuos tal que cada segmento individual sea igual en su tamaño a su grado de adaptación.
- General un número aleatorio.
- Seleccionar el individuo cuyo segmento cubre el número aleatorio.
- Repetir el proceso hasta obtener el número deseado de muestras.

El método de la ruleta sufre de una dispersión ilimitada, es decir, la discrepancia entre el número esperado de copias y el número real obtenido por el método de la ruleta puede ser la máxima posible. El algoritmo óptimo de Muestreo Estocástico Universal (SLTS) corrige esta situación (Bäck, 1994).

3. Muestreo Estocástico Universal:

SUS es análogo a una ruleta con M punteros igualmente espaciados entre sí, de modo que con un solo lanzamiento se obtienen M ganadores. El método SUS no tiene sesgo y su dispersión es la mínima posible.

4. Selección por Ranking

El algoritmo de selección por ranking es como sigue:

Ordenar la población del mejor individuo ($x = 1$) al peor ($x = M$).

Asignar un número de copias esperadas según:

$$\alpha(x) = \eta^+ - (\eta^+ - \eta^-) \frac{(x-1)}{(M-1)} \quad (74)$$

Donde:

$${}_x\alpha(x) = M, 1 \leq \eta^+ \leq 2, \eta^- = 2 - \eta^+ \quad (75)$$

η^+ : máximo valor esperado y η^- : mínimo valor esperado.

5. Selección por Torneo.

Este método de selección no se basa en valores esperados y no requiere por lo tanto de un algoritmo de muestreo. El algoritmo es como sigue:

Escoger tamaño de torneo.

Crear una permutación aleatoria de M enteros.

Comparar la adaptación de los próximos miembros de la población y seleccionar el mejor.

Si se acaba la permutación, generar una nueva permutación. Repetir hasta llenar la población.

Los distintos métodos de selección pueden ser analizados en términos de su presión selectiva. Esta se mide como el inverso del tiempo requerido por el mejor individuo para llenar la población con copias de sí mismo.

6. Recombinación.

El operador de recombinación (crossover) es el operador de búsqueda más importante en los algoritmos genéticos. Este es un operador sexuado que intercambia el material genético de un par de padres produciendo descendientes que normalmente difieren de sus padres. La idea central es que segmentos distintos de padres diferentes con alta adaptación deberían combinarse en nuevos individuos que tomen ventaja de esta combinación.

El algoritmo genético explota las regiones con mayor adaptación, ya que generaciones sucesivas de selección y recombinación producen un número creciente de puntos en estas regiones.

El operador de recombinación opera con probabilidad p_c . Dados p y q un par de padres, de largo ℓ bits, se escoge aleatoriamente un punto $k \in \{1, \dots, \ell - 1\}$ y se intercambian los bits a la derecha de esa posición entre ambos individuos, obteniéndose los descendientes como se indica a continuación:

$$\begin{aligned} \vec{p} &= (p_1, \dots, p_{k-1}, p_k, \dots, p_\ell) & \vec{s} &= (p_1, \dots, p_{k-1}, q_k, \dots, q_\ell) \\ \vec{q} &= (q_1, \dots, q_{k-1}, q_k, \dots, q_\ell) & \vec{v} &= (q_1, \dots, q_{k-1}, p_k, \dots, p_\ell) \end{aligned} \quad (76)$$

7. Mutación.

En el algoritmo genético simple, el operador de mutación juega un papel secundario, invirtiendo ocasionalmente un bit. Las tasas de mutación pequeñas garantizan que un individuo no difiera mucho de sus padres en el genotipo (tira binaria). La mutación sirve para evitar la pérdida de diversidad producto de bits que han convergido a un cierto valor para toda la población, y que por

tanto no pueden ser recuperados por el operador de recombinación. El operador de mutación invierte cada bit de la tira binaria sobre una base bit a bit con probabilidad p_m .

$$m'_{\{p_m\}}(q_1, q_2, \dots, q_\ell) = (q'_1, q'_2, \dots, q'_\ell), \forall i \in \{1, \dots, \ell\}, \quad (77)$$

Donde $q'_i = \begin{cases} q_i & \text{si } r > p_m \\ 1 - q_i & \text{si } r \leq p_m \end{cases}$ y $r \in [0,1]$ uniformemente aleatorio, distinto para cada bit q_i .

4.3. Formulación matemática de la optimización multiobjetivo.

El problema de optimización multiobjetivo involucra varios objetivos y se puede formular matemáticamente como:

$$\begin{aligned} & \text{minimize} && F(x) = (f_1(x), \dots, f_m(x))^T \\ & \text{s. t.} && x \in \Omega, \end{aligned} \quad (78)$$

Donde Ω es el espacio de decisión y $x \in \Omega$ es un vector de decisión $F(x)$ funciones objetivos $f_i : \Omega \rightarrow \mathbb{R}, i = 1, \dots, m$, Donde \mathbb{R}^m es el espacio objetivo.

Los objetivos en la ecuación (78) a menudo están en conflicto con otros, lo que significa que la mejora de uno de los objetivos puede conducir al empeoramiento del otro. Por lo tanto, no existe una única solución, que puede optimizar los objetivos simultáneamente. En cambio, las mejores soluciones de compromiso, llamadas las soluciones óptimas de Pareto, son importantes para la toma de decisiones.

El concepto de óptimo de Pareto, que fue propuesto por primera vez por Edgeworth y Pareto, se define formalmente como:

Dominancia de Pareto. El vector $u = (u_1, \dots, u_k)^T$ se puede decir que domina a otro vector $v = (v_1, \dots, v_k)^T$ denotado como $u \prec v$, si y sólo si u es parcialmente menor a v : $\forall i \in \{1, \dots, k\}, u_i \leq v_i$ $u \neq v$.

Solución óptima de Pareto. Decimos que una solución viable $\vec{x}^* \in \Omega$ es un óptimo de Pareto si para toda $\vec{x} \in \Omega$ e $I = \{1, 2, \dots, k\}$ ya sea,

$$\forall i \in I (f_i(\vec{x}) = f_i(\vec{x}^*)), \quad (79)$$

o hay al menos $i \in I$ tal que $(f_i(\vec{x}) > f_i(\vec{x}^*))$.

El conjunto de todas las soluciones óptimas de Pareto se llama el conjunto de Pareto, denotado como.

$$CP = \{x \in \Omega | \nexists y \in \Omega, F(y) < F(x)\}. \quad (80)$$

La imagen en el espacio objetivo se llama el frente de Pareto (FP).

$$FP = \{F(x) | x \in PS\} \quad (81)$$

4.3.1. Algoritmos de nichos paralelos.

El algoritmo genético simple converge a una sola solución debido al tamaño finito de la población y a la acumulación de errores estocásticos de muestreo. Los algoritmos de nichos extienden los algoritmos genéticos a dominios que requieren de la localización y mantención de múltiples soluciones, por ejemplo la optimización de funciones con múltiples máximos. Los algoritmos de nichos paralelos forman y mantienen subpoblaciones dentro del espacio de una población única, mediante la disminución de la competencia entre puntos distantes en el espacio de búsqueda. Para esto se introduce una métrica d en el espacio genotípico, i.e., $d_{ij} = d(s_i, s_j)$, donde s_j y s_i son las tiras binarias (genotipos) y d es la distancia de Hamming (número de bits diferentes entre tiras). Alternativamente, la distancia se puede medir en el espacio fenotípico, i.e., $d_{ij} = d(x_i, x_j)$ donde x_i y x_j son los vectores de parámetros decodificados y d es la distancia Euclidiana (VALENCIA, 1997).

Hay dos tipos básicos de algoritmos de nichos: compartimiento (sharing) y hacinamiento (crowding).

Método de Compartimiento

Los algoritmos de compartimiento se basan en la idea de que la adaptación debe ser compartida como un recurso único entre individuos similares en una población. Se define una nueva adaptación compartida f' , dividiendo la función de adaptación original por un factor que toma en cuenta la similitud del individuo con el resto de la población:

$$f'(j) = \frac{f(j)}{sh(d_{ij})}, \quad (82)$$

donde sh es la función de compartimiento,

$$sh(d) = \begin{cases} 1 - \left(\frac{d}{\sigma_{share}}\right)^\alpha, & d \leq \sigma_{share}, \\ 0 & \text{otro caso} \end{cases} \quad (83)$$

α y σ_{share} son constantes.

La función de compartimiento entrega un 1 cuando dos individuos son idénticos, 0 cuando su grado de similitud supera un cierto umbral y un número entre 0 y 1 para grados intermedios de similitud. El umbral de similitud está especificado por la constante σ_{share} . Si la distancia entre dos individuos es mayor que este umbral entonces ellos no compiten entre sí.

La proporción de la población esperada en una clase (p.ej. un máximo local) es función de la adaptación de esa clase dividida por la suma de las adaptaciones de todas las clases. Usualmente se utiliza compartimiento con selección proporcional, pero en principio se podría utilizar cualquier método de selección.

El algoritmo de compartimiento es capaz de mantener múltiples soluciones. Su principal desventaja es que es costoso computacionalmente, ya que se requiere calcular la distancia entre todos los elementos de la población en cada generación. Además requiere del ajuste de los parámetros de la función de compartimiento.

Método de Hacinamiento

Estos algoritmos forman y mantienen nichos mediante el reemplazo de los elementos de la población con individuos similares. En el modelo de hacinamiento determinístico, un individuo compite en un torneo con sus padres. Dado un par de padres y sus descendientes se realizan los torneos que hagan competir a aquellos individuos más cercanos y se selecciona por reemplazo.

Algoritmo de Hacinamiento Determinístico:

Repetir $n/2$ veces

1. Seleccionar 2 padres, p_1 y p_2 , aleatoriamente sin reemplazo.
2. Recombinarlos, dando origen a c_1 y c_2 .
3. Opcionalmente mutar dando origen a c_1' y c_2' .

Dada una medida de distancia $d(x, y)$ aplicar la siguiente regla de reemplazo:

Si $[d(p_1, c_1') + d(p_2, c_2')] \leq [d(p_1, c_2') + d(p_2, c_1')]$

$$\begin{cases} \text{Si } f(c_1') < f(p_1) & \text{reemplazar } p_1 \text{ por } c_1' \\ \text{si } f(c_2') < f(p_2) & \text{reemplazar } p_2 \text{ por } c_2' \end{cases}$$

De otro modo

$$\begin{cases} \text{Si } f(c_2') < f(p_1) & \text{reemplazar } p_1 \text{ por } c_2' \\ \text{si } f(c_1') < f(p_2) & \text{reemplazar } p_2 \text{ por } c_1' \end{cases}$$

4.3.2. Algoritmo genético con operador elitista basado en un ordenamiento no-dominado (NSGA-II).

Los algoritmos multiobjetivo introducen el operador de *Dominancia*, el cual define que una solución

$x_{(1)}$ domina otra solución $x_{(2)}$ si se cumplen las siguientes condiciones:

La solución $x_{(1)}$ no es de menor calidad que $x_{(2)}$ en todos los objetivos.

La solución $x_{(1)}$ es estrictamente mejor que $x_{(2)}$ en al menos uno de los objetivos.

Aplicando iterativamente estas reglas sobre un conjunto cualquiera de soluciones de un problema de optimización multiobjetivo, se puede establecer cuáles son las alternativas dominantes, conocidas como *Conjunto No Dominado*. Las soluciones restantes forman parte del Conjunto de *Soluciones Dominadas*. Si se logra establecer cuál es el conjunto de Soluciones Dominantes a través de todo el espacio objetivo, que no es más que el Frente óptimo de Pareto.

Operador de Apilamiento.

Para que los algoritmos multiobjetivo puedan encontrar el mayor número posible de soluciones que pertenezcan al frente de Pareto es necesario mantener una población tan diversa como sea posible. El operador de apilamiento permite cuantificar el espacio alrededor de una alternativa que no se encuentra ocupada por ninguna otra solución. Para esto se debe calcular el perímetro del cuboide formado por las soluciones vecinas que poseen el mismo rango de dominancia que la alternativa i , lo cual se describe por medio de la ecuación (84) como:

$$d_i = \sum_{m=1}^M \left| \frac{f_m^{(I_{i+1}^m)} - f_m^{(I_{i-1}^m)}}{f_m^{max} - f_m^{min}} \right| \quad (84)$$

Donde I^m es un vector que indica la alternativa de solución vecina a la alternativa i , f_m^{max} y f_m^{min} son los valores máximo y mínimo sobre todo el espacio de solución de la función objetivo m , y M es el número de funciones objetivo optimizadas.




Figura 37. Distancia de apilamiento para alternativa de solución X_i .

Para el caso de dos funciones objetivo y tres rangos de dominancia para las 10 alternativas mostradas, el semiperímetro del área sombreada está dado por medio de la ecuación (85) como:

$$d_i = \left| \frac{f_1^{X(i+1)} - f_1^{X(i-1)}}{f_1^{max} - f_1^{min}} \right| + \left| \frac{f_2^{X(i+1)} - f_2^{X(i-1)}}{f_2^{max} - f_2^{min}} \right| \quad (85)$$

De esta manera se puede afirmar que para un conjunto de soluciones en competencia, la alternativa que introduce el mayor nivel de diversidad es aquella con la mayor distancia de apilamiento dada por la ecuación (85).

Selección por torneo según operador de apilamiento.

Este procedimiento reemplaza la selección usada en el algoritmo genético tradicional. Consiste en comparar dos soluciones las cuales poseen, cada una, dos atributos:

- Un rango de no dominación r_i . Según el frente de Pareto.
- Una distancia local de apilamiento d_i .

La selección retorna la solución ganadora i basándose en dos criterios fundamentales.

- Si tiene mejor rango: $r_i < r_j$
- Si tienen el mismo rango pero i tiene mejor distancia de apilamiento: $d_i > d_j$ Determinación del Conjunto Descendiente Final.

Antes de finalizar una generación del algoritmo se ejecuta un proceso de preselección y preservación de las soluciones de élite, que consiste en reunir el conjunto de soluciones Padres y los descendientes obtenidos por medio de los operadores de elección, cruce y mutación.

De esta manera la población actual aumenta al doble de los individuos de la población inicial. Para ello es necesario clasificar el conjunto completo en sus respectivos frentes de dominancia y preservar los individuos que pertenezcan a los frentes de mejor calidad, tal como se ilustra en Figura 38.




Figura 38. Determinación de la nueva Población.

Si no es posible ingresar todas las alternativas de un frente determinado, entonces son eliminados aquellos individuos con una menor distancia de apilamiento.

Seudo-Código para el NSGA-II.

1. Generar una población P de tamaño N.

2. Identificar los frentes de dominancia y evaluar las distancias de apilamiento en cada frente.
3. Usando selección ($<c$), cruzamiento y mutación se genera una población descendiente del mismo tamaño de P .
4. Reunir Padres e hijos en un conjunto de tamaño $2N$ y clasificar los frentes de dominancia.
5. Determinar el conjunto descendiente final seleccionando los frentes de mejor rango. Si se supera el límite de población N , eliminar las soluciones con menor distancia de apilamiento en el último frente seleccionado.
6. Sí se cumple el criterio de convergencia, Fin del proceso. De lo contrario retornar al paso 3.

V. ANÁLISIS Y DISCUSIÓN DE RESULTADOS.

5.1. Caracterización mecánicas de las hojas del *Agave angustifolia* Haw y del *Agave fourcroydes*.

5.1.1. Características geométricas de las hojas del *Agave angustifolia* Haw y el *Agave fourcroydes*.

Tabla 2. Características de las hojas del *Agave angustifolia* Haw y *Agave fourcroydes*.

Parámetros	Longitud (m)	Ancho (mm)	Humedad (%)
<i>Angustifolia</i> Haw	1.1-1.3	80-100	79.5
<i>Fourcroydes</i>	0.9-1.8	100-150	90.2

En la Tabla 2 se aprecia que las hojas del *Agave angustifolia* Haw y del *Agave fourcroydes*, son muy similares en cuanto a sus dimensiones medias. La diferencia más significativa de esas hojas radica en su contenido de humedad, pues el *Agave Angustifolia* Haw presenta un 10.7 % menos de humedad que el *Agave fourcroydes* una de las razones por las cual se espera que las propiedades mecánicas de las hojas sean diferentes.

5.1.2. Características mecánicas de las hojas del *Agave angustifolia* Haw y el *Agave fourcroydes*.

A continuación en la Tabla 3, se muestran los valores del comportamiento mecánico de las hojas de *Agave angustifolia* Haw y del *Agave fourcroydes*. Se puede apreciar que en la compresión en ambas direcciones, en el cizallamiento en sentido paralelo a las fibras y en la tracción perpendicular a las fibras, el *Agave fourcroydes* presenta un menor valor de la tensión máxima $\sigma_{\text{máx}}$ teniendo en cuenta que es los tipos de esfuerzo antes mencionado las fibras no son sometidas a tracción que es donde estas determinan en mayor

grado el comportamiento mecánico de la hoja y solo es la parte no fibrosa la que soporta las cargas antes descritas estos valores son claramente consecuencia del mayor contenido de humedad en las hojas que provoca menor resistencia máxima a los esfuerzo mencionados.

Tabla 3. Propiedades mecánicas de las hojas.

Dirección del ensayo.	Tipo de Agave.	Compresión.				Tracción.				Cizallamiento.			
		$\sigma_{m\acute{a}x}$ (MPa)	E (MPa)	ϵ (%)	C (J)	$\sigma_{m\acute{a}x}$ (MPa)	E (MPa)	ϵ (%)	C (J)	$\sigma_{m\acute{a}x}$ (MPa)	E (MPa)	ϵ (%)	C (J)
Paralela de las fibras.	A. Haw	0.96	12.6	2.02	0.81	11.7	64.2	9.1	25	0.57	0.327	60	86.4
	<i>Fourcroydes</i>	0.59	11.62	1.73	0.56	14.5	60.3	12.1	31	0.37	0.28	46	38
Perpendicular a las fibras.	A. Haw	1.98	3.21	1.52	2.94	0.25	2.35	1.8	0.29	2.45	1.94	90	471
	<i>Fourcroydes</i>	1.65	3.14	1.24	1.25	0.16	2.13	288	0.20	2.86	2.14	94	521

También, se aprecia el comportamiento a tracción, resulta mayor $\sigma_{m\acute{a}x}$ para el *Agave fourcroydes* esto puede ser causado por la mayor resistencia a la tracción d sus fibras.

Durante el ensayo de compresión paralelo a las fibras los gráficos de esfuerzo-deformación unitaria, los agaves analizados presentan considerables diferencias, debido a que la curva que representa el comportamiento del *Agave Angustifolia* Haw comienza con una pendiente mayor que la curva de comportamiento que el *Agave fourcroydes* como se puede apreciar en la Figura 39.




Figura 39. Comportamiento a compresión paralela a la fibra.

Durante la compresión en sentido perpendicular a las fibras la pendiente de la curva de comportamiento del *Agave fourcroydes*, comienza siendo más suave que la del *Agave angustifolia* Haw según nos muestra la Figura 40,

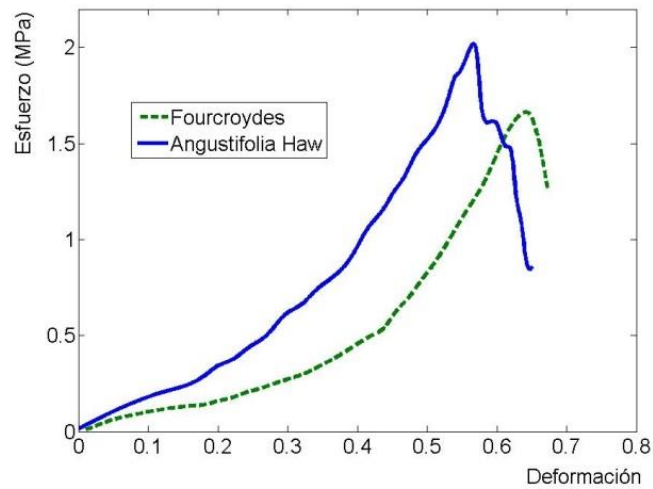


Figura 40. Comportamiento a compresión perpendicular a la fibra.

Las curvas del gráfico longitudinal a las fibras muestran que el *Agave fourcroydes* presenta mayor esfuerzo último a la tracción esto se puede deber a que a la mayor resistencia a la tensión de sus fibras, como se aprecia en la Figura 41.

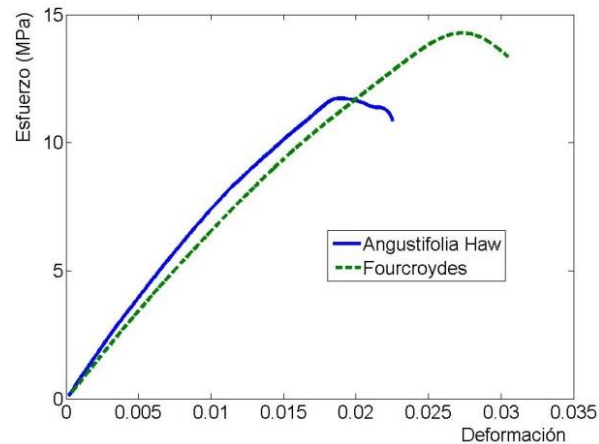


Figura 41. Comportamiento a tracción longitudinal a la fibra.

Para el comportamiento a tracción perpendicular a las fibras, se puede observar que la resistencia de las hojas del *Agave angustifolia* Haw es mayor en comparación de las hojas del *Agave fourcroydes*. Sin embargo, la deformación alcanzada hasta el punto de ruptura del *Agave fourcroydes* es mayor que el del *Agave angustifolia* Haw, como se puede observar en la Figura 42.

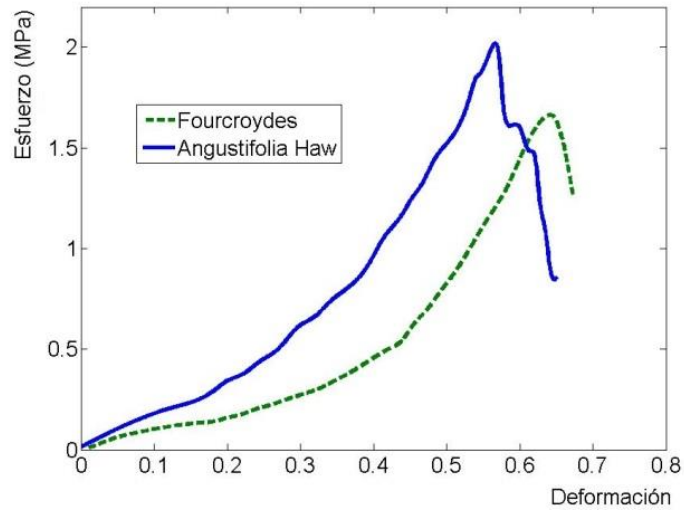


Figura 42. Comportamiento a tracción perpendicular a la fibra.

En el comportamiento a cizallamiento en dirección de las fibras para ambos materiales se puede ver la cima de la curva que no es puntiaguda, lo que indica, claramente la no existencia de un punto de ruptura, un comportamiento más típico de un material plástico que elástico.

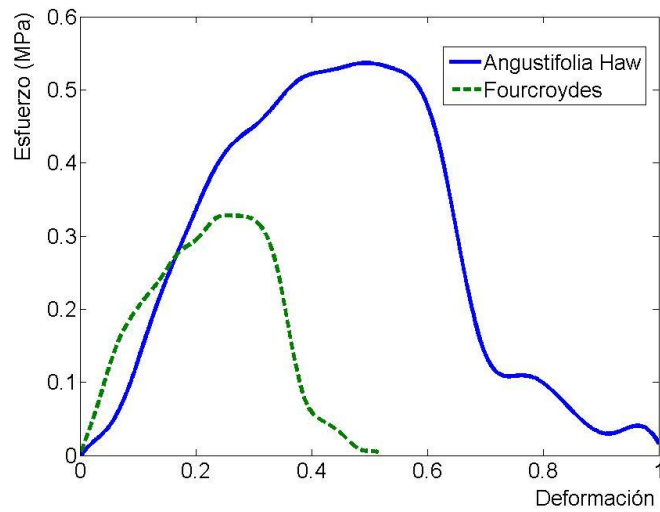


Figura 43. Comportamiento a cizallamiento longitudinal.

En el caso del cizallamiento transversal a la fibra en ambas curvas se puede apreciar un la formación de una cresta también puntiaguda, que indica claramente el punto de fractura, fenómeno típico de los materiales elásticos, de igual manera, el esfuerzo y la deformación alcanzada de ambos tipos de hojas de agave son similares




Figura 44. Comportamiento a cizallamiento Transversal.

5.2. Resultados de los cálculos previos para determinar dimensiones iniciales del banco de ensayos.

Los resultados del cálculo de los parámetros de diseño de los órganos de trabajo de la desfibradora permitieron definir las dimensiones racionales del órgano desfibrador. El diámetro del tambor desfibrador $D=0,370$ m y su longitud $L_r=0,285$ m, la cual coincide con la longitud de las cuchillas ($L_r=L_c$). Esta longitud es suficiente para cubrir todo el ancho de la hoja. Como soporte para las cuchillas desfibradoras se empleó un perfil angular con dimensiones $0,0381 \times 0,0381 \times 0,0635$ m. Como fuente energética se seleccionó un motor eléctrico de $5,6$ kW ($7,5$ hp) que gira a $1\ 765$ rpm. El diámetro de los rodillos de alimentación para el cumplimiento de la condición de agarre de las hojas $D_r=0,115$ m. Las revoluciones del cilindro desfibrador se fijaron mediante ensayos previos que consistieron en aumentar paulatinamente la frecuencia de rotación del órgano desfibrador hasta lograr el desprendimiento de toda la corteza de la hoja, en este caso la frecuencia

mínima del órgano desfibrador fue de 1 500 rpm, para una velocidad tangencial del filo de las cuchillas $V_t=27,175$ m/s.

El un número de cuchillas máximo que se pudieron colocar en el cilindro desfibrador fue $Z=16$, para elevar al máximo en número de cortes a la hoja por frecuencia de rotación del órgano desfibrador.

La altura del desfibrado expresada como la distancia desde la contracuchilla al centro del cilindro desfibrador para la cual se cumple la condición de la ecuación (13) se fijó en $a=0,028$ m. Obteniéndose una distancia del tramo de desfibrado de 0,00020439 m.

5.3. Resultados de la experimentación en el banco de ensayos.

5.3.1. Resultados de la evaluación energética.

Los resultados muestran que la energía consumida en el proceso de desfibrado durante la entrada de la hoja al órgano desfibrador tiene una dependencia bien marcada respecto a la velocidad de alimentación, pues en la medida que aumenta la velocidad de alimentación disminuye exponencialmente la energía consumida (Figura 45^a). El coeficiente de regresión del modelo fue $R^2=0,9925$ para el 95% del intervalo de confianza. En el rango de velocidades de 0,05 a 0,2 m/s, se observó un efecto más marcado de la influencia de la velocidad de entrada en el consumo de energía.

Para velocidades de alimentación del material de 0,5 m/s la energía de entrada requerida para desfibrar la hoja de agave sería $E_{ent}=7,47$ kJ.

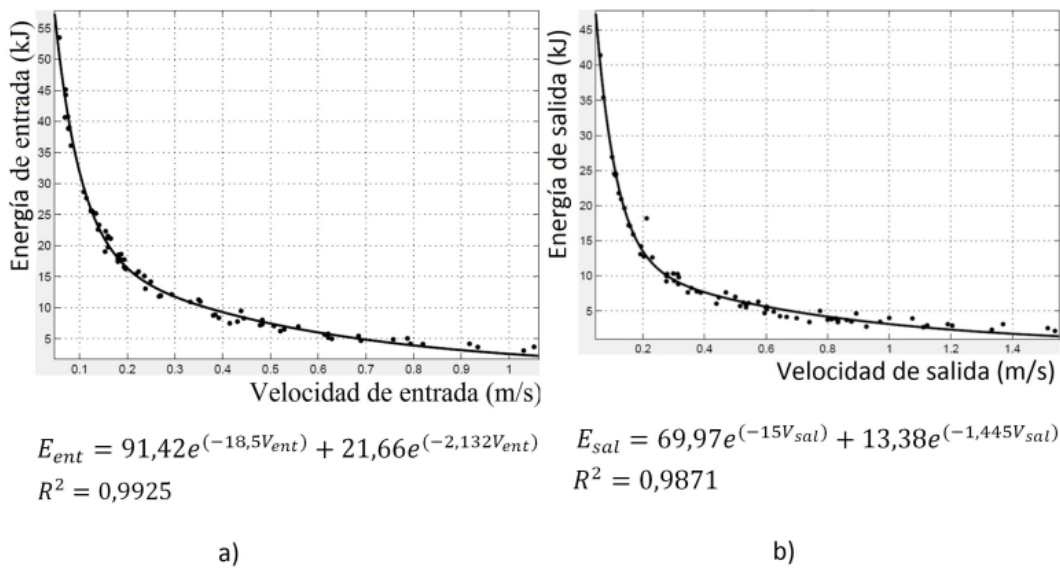


Figura 45. Relación energía-velocidad del material desfibrado. a) energía de entrada-velocidad de alimentación. b) energía de salida-velocidad de salida.

De igual forma, la energía consumida para retirar la fibra mostró la misma tendencia con respecto a la velocidad de salida, pues esta disminuye exponencialmente con el aumento de la velocidad de salida de la fibra. El coeficiente de regresión del modelo fue $R^2=0,9871$ para el 95% del intervalo de confianza. Además se observó que para velocidades de salida mayores de 0,3 m/s se obtienen valores más bajos de energía de salida. El valor de la energía requerida durante la salida de las fibras $E_{sal}=6,2$ kJ para una velocidad de salida de 0,5 m/s. Este valor al igual que en el caso de la energía de entrada está referido a la mitad de la hoja.

5.3.2. Resultados de la evaluación de la calidad del desfibrado.

Los resultados evidencian que holguras entre 0,0012 a 0,00135 m se hace más pronunciada la pendiente de la curva, indicando que entre estos límites tiene menor variación el porcentaje de fibras enteras respecto a la holgura de desfibrado. Para valores mayores a 0,00135 m de la holgura de desfibrado se obtiene un mayor porcentaje de variación del porcentaje de fibras enteras. Para una holgura de desfibrado de 0,0013 m se obtiene un 79,8% de fibras enteras.

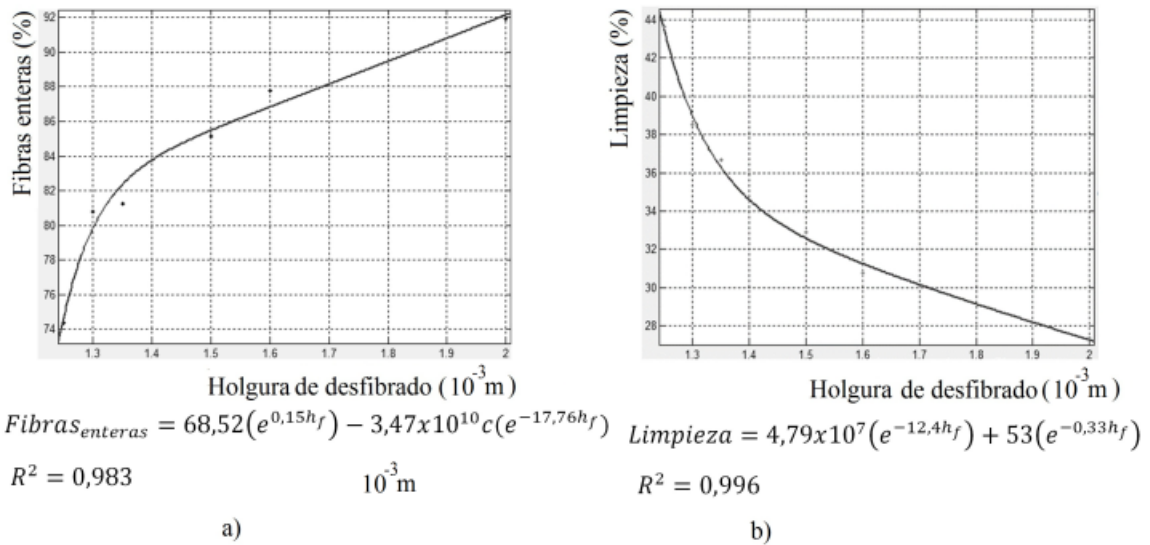


Figura 46. Calidad del desfibrado. a) Comportamiento de la limpieza respecto a la holgura de desfibrado. b) Comportamiento de la cantidad de fibras enteras respecto a la holgura de desfibrado.

El otro parámetro que caracteriza la calidad del desfibrado es la limpieza de las fibras, el cual decrece exponencialmente dentro de los límites investigados con respecto a la holgura del desfibrado, haciéndose mayor para para distancias menores a 0,0013 m.

Como se puede apreciar en la Figura 470, para una distancia de desfibrado de 0,0013 m las fibras quedan lo suficientemente limpias (caso A). Sin embargo para una distancia de desfibrado de 0,002 m las fibras obtenidas no pueden ser utilizadas debido a la gran cantidad de material no fibroso que aún se encuentra adherido a las mimas (caso B).

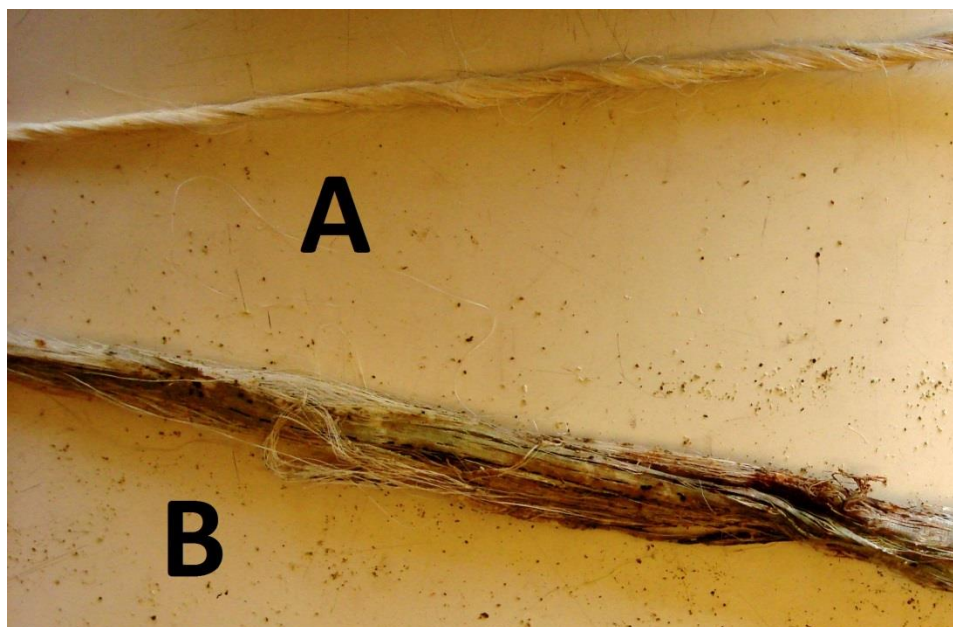


Figura 47. Fibras con diferente porcentaje de residuos.

Estos resultados están en correspondencia con estudios realizados por (Gratton y Chen, 2004) en *Cannabis sativa* para un rendimiento de un 41% a 61% del contenido inicial de la fibra en el tallo. (Anthony, 2002), alcanzó de un 7,1% a 12,8% de fibra pura para separar la fibra de lino, durante el desmote de algodón.

5.3.3. Relación entre el porcentaje de fibra entera y el porcentaje de limpieza.

Los resultados de la Figura 481 muestran una relación inversamente proporcional entre las variables que definen la calidad del desfibrado, poniéndose de manifiesto que el aumento de la limpieza de las fibras trae consigo un aumento del porcentaje de fibras rotas. Tomando en cuenta que según los resultados experimentales para una distancia de desfibrado de 0,0013 m se obtiene un 37% de limpieza (Figura 9b), entonces el porcentaje de fibras enteras esperado será del 78% con un 95% de confiabilidad (Figura 11). Este porcentaje de fibras enteras es superior a los alcanzados por (Rössel Kipping et al., 2003), los cuales obtuvieron del 47 a 60% de fibras enteras en una desfibradora de *Agave lechuguilla* Torey, y un 70% mediante el desfibrado manual.

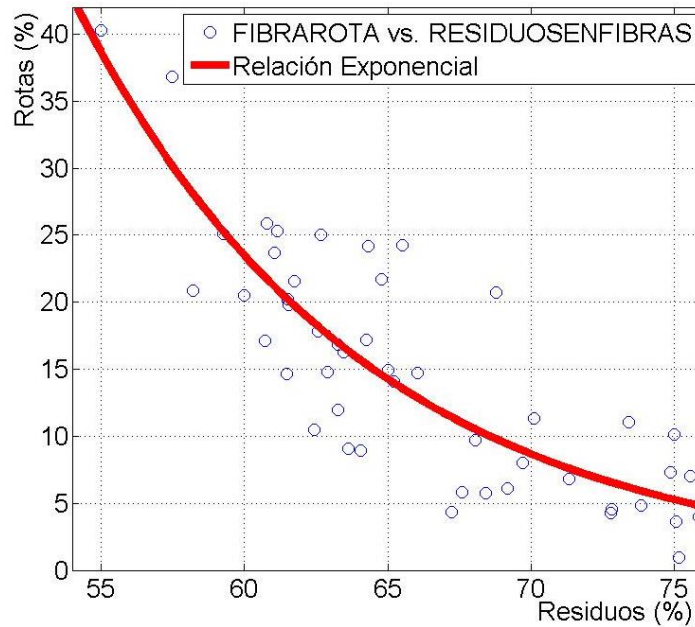


Figura 48. Calidad del desfibrado.

En la Tabla 4 se muestra una clasificación por estimados de la calidad del desfibrado basados en la observación a las fibras en el momento de salir del órgano desfibrador.

Para el porcentaje de residuos tenemos:

Exceso: las fibras salen con una parte continua de material no fibroso que impide cualquier forma de separación no se logran ver una considerable parte de las fibras.

Regular: aparecen algunas zonas donde el las fibras continúan unidas a la parte fibrosa de la hoja.

Aceptable: aunque presenten algunas partículas de material no fibroso las fibras están independientes y listas para ser procesadas y utilizadas.

Para el porcentaje de fibras rotas tenemos:

Exceso: la cantidad de fibras rotas es considerable en comparación con las fibras enteras desde un tercio hasta aproximadamente la mitad, además, el exceso de fibras rotas terminan por entorpecer el proceso de desfibrado por la acumulación de fibras en el momento de retirar la hoja.

Regular: se aprecia una cantidad de fibras rotas que no entorpece el proceso de desfibrado pero constituye una pérdida importante que puede afectar el rendimiento al final del proceso.

Aceptable: solo se rompen las fibras que presentan anomalías en su estructura o las que presentan una resistencia menor a la fuerza de adherencia del material no fibroso sobre estas e inevitablemente termina rompiéndose.

Tabla 4. Estimados de calidad del proceso de desfibrado.

Clasificación	Residuos (%)	Fibras Rotas (%)
Exceso	70-75	30-40
Regular	65-75	20-30
Aceptable	55-65	20-0

5.3.4. Influencia de las velocidades de entrada y de las hojas en la calidad del desfibrado.

La relación de las velocidades analizadas con respecto a la calidad del desfibrado mostró una relación directamente proporcional entre estos parámetros, pues en la medida que aumenta la velocidad aumenta la calidad del desfibrado. La limitante del aumento de las velocidades desde el punto de vista operacional se centra mayormente en el momento de la entrada de la hoja, pues depende de la capacidad del operario para manipular este tipo de material, así como los tiempos de reacción durante el proceso de alimentación en el momento de llevar la hoja a la entrada del órgano de alimentación, además del tiempo que se consume para accionar el mando de pedal hasta que la hoja regrese. Los resultados experimentales mostraron que una velocidad de 0,5 m/s mantiene buen rendimiento horario y permite movimientos coordinados del operario para alimentar la máquina. Estas velocidades además permiten obtener un 80 % de fibras enteras y 35 % de limpieza, parámetros que se encuentran dentro de los rangos aceptados para la comercialización y que son posibles a obtener con la holgura de desfibrado seleccionada (0,0013 m).




Figura 49. Influencia de la velocidad de entrada y salida de las hojas en la calidad del desfibrado.

a) Influencia en el % de fibras enteras. b) Influencias en la limpieza de las fibras.

5.3.5. Influencia de las velocidades de entrada y de las hojas en la seguridad del operario.

Uno de los problemas que presentan el tipo de máquina desarrollado radica fundamentalmente en la seguridad del operario. Como se puede apreciar en la imagen de la Figura 50, es necesario acercar la hoja manualmente hasta el rodillo de alimentación, lo que coloca las manos del operario cerca de este.



Figura 50. Colocación de las hojas en el órgano desfibrador.

Durante los experimentos se comprobó que a velocidades de entrada de la hoja menores de 0.6 m/s el movimiento del operario se realiza de forma fluida dejando tiempo reacción en caso de ser necesario.

Igualmente se comprobó que para velocidades de salida menores a 0.8 m/s existe una buena maniobrabilidad del operario.

Las velocidades de entrada y salida de la máquina influyen en el consumo de energía de esta por la cantidad de hojas desfibradas pues a velocidades muy bajas aumenta el consumo de energía y disminuye el rendimiento horario de la máquina.

En la Tabla 5, se recomiendan los rangos de velocidades teniendo en cuenta la maniobrabilidad, el consumo de energía y el rendimiento de la máquina.

Tabla 5. Rangos de velocidad de entrada y salida de la hoja.

Velocidades	Mínimo (m/s)	Máximo (m/s)
Velocidad de entrada.	0.4	0.6
Velocidad de salida	0.5	0.8

5.4. Modelado con la red neuronal.

5.4.1. Entrenamiento de la red neuronal.

En la validación del entrenamiento de la red neuronal, como se puede apreciar, el valor mínimo de error cuadrado medio se obtiene a las 27 épocas. Este valor indica cuanto se aproxima el modelo de la red neuronal a los valores reales obtenidos mediante los experimentos.




Figura 51. Desempeño de la red neuronal.

Como se puede apreciar en la Figura 51 el modelo es validado para un valor del error cuadrático medio mínimo igual a 13.2421 que coincide con la varianza.

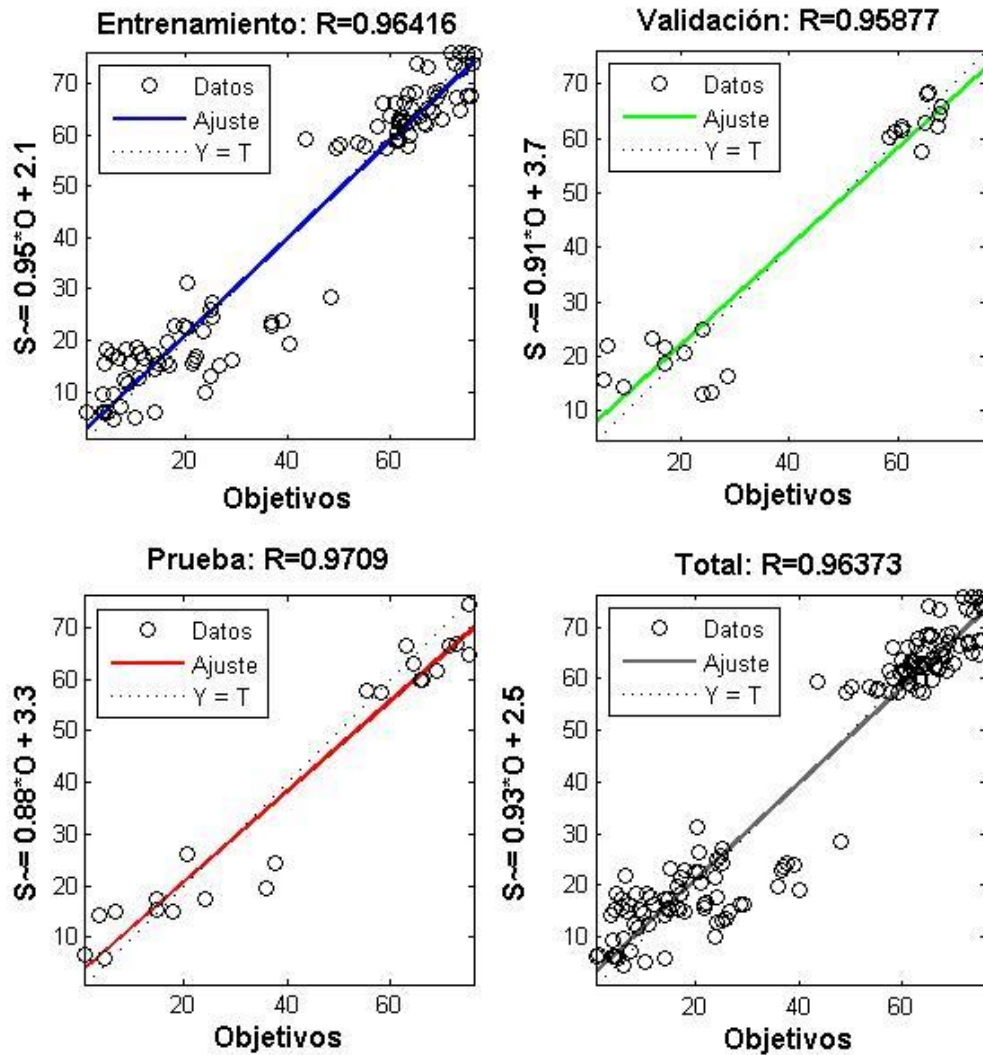


Figura 52. Regresión entre los valores reales y el modelo.

La Figura 52, muestra la aproximación del modelo a través del ajuste de la regresión con relación a la regresión de los valores reales tanto para los experimentos usados como entrenamiento, prueba y validación, y para el total de los experimentos realizados, mostrando un valor de la correlación, para cada caso que se aproxima a 1.

5.4.2. Aproximación del modelo a los valores experimentales.

En la Figura 53 representa gráficamente como el modelo ajustado es capaz de aproximarse a los valores reales del porcentaje de fibras rotas, para el caso de valores reales que no manifiestan el comportamiento adecuado como el modelo no toma en cuenta estos valores y genera valores que toman en cuenta el comportamiento de las demás variables.




Figura 53. Fibras rotas.

De igual manera en la Figura 54, se muestra el ajuste del modelo, respecto a los datos experimentales del porcentaje de residuos en fibra. De igual manera que para el caso del porcentaje de las fibras rotas.




Figura 54. Residuos.

5.5. Optimización mediante algoritmos genéticos.

En el análisis se utilizó un algoritmo genético elitista controlado en su variante de selección no dominada, que favorece a los individuos con un mejor valor de aptitud y a los individuos que pueden ayudar a aumentar la diversidad de la población, incluso si tienen un valor menor aptitud. Haciendo hincapié en la importancia de mantener la diversidad de la población para la convergencia del frente óptimo de Pareto. La diversidad se mantiene mediante el control de los miembros de la élite de la población a medida que avanza el algoritmo. El elitismo es controlado con dos opciones, fracción de Pareto que limita el número de los individuos en el frente Pareto (miembros de la élite), y la función de selección de distancia, que ayuda a mantener la diversidad en el frente al favorecer a los individuos que están relativamente alejados del frente.

Este tipo de AG es capaz de encontrar mejor difusión de soluciones y una mejor convergencia cerca del verdadero frente óptimo de Pareto en comparación con otras estrategias de evolución




Figura 55. Frente de Pareto.

La Figura 55 se corresponde con el frente de Pareto generado durante la optimización multiobjetivo, de los 16 valores obtenidos, debemos seleccionar por criterio de la calidad de desfibrado deseada. En la Tabla 6 aparece cada una de las 16 posibles soluciones óptimas de diseño, de los elementos estudiados. Tanto el criterio de fibras rotas como los residuos en fibras fueron minimizados.

Tabla 6. Soluciones de Pareto.

	Holgura de desfibrado	Velocidad de entrada	Velocidad de salida	Fibras rotas	Residuos en fibras.
1.	1.64140807	0.40156368	0.74005848	14.1196382	67.5558117
2.	1.48315587	0.51513441	0.75617552	16.5292743	67.5063584
3.	1.26754041	0.4695821	0.75401849	18.5550178	62.731703
4.	1.72997484	0.44142871	0.77027529	3.74743554	72.5996349
5.	1.64199674	0.43777124	0.76144108	11.7569753	68.0227804
6.	1.68197705	0.41076487	0.77607694	9.35146544	68.9525318
7.	1.6521783	0.47243238	0.75408344	8.27123891	69.8880598
8.	1.50279676	0.54068301	0.74320017	15.6342993	67.5515086
9.	1.6907915	0.4710242	0.75728852	4.88485173	71.9697952
10.	1.61509258	0.46626354	0.75178212	12.5005245	67.9421595
11.	1.62504894	0.43821247	0.76196988	13.205875	67.6858515
12.	1.27668442	0.52450819	0.74910386	17.4761673	63.6507638
13.	1.70505374	0.40082632	0.77917603	7.56587237	70.0092532
14.	1.80866821	0.39929173	0.7801532	2.83092437	73.1525605
15.	1.65806736	0.43371478	0.76392693	10.3783489	68.5319593
16.	1.24901764	0.39901769	0.75001	20.3825732	61.1817013

El punto óptimo número 14 se corresponde con el óptimo de menor cantidad de fibras rotas (2.83%) pero a su vez este es el de mayor cantidad de residuos (73.15%) por otro lado el óptimo número 16 presenta el menor porcentaje de residuos en fibras con un 61.18 % pero presenta el mayor porcentaje de fibras rotas un 20.38%.

5.6. Subproductos obtenidos.

Además de las fibras enteras, en el proceso de desfibrado se obtienen como subproductos la parte no fibrosa junto a las fibras rotas. El material obtenido se puede secar al sol y luego ser almacenado con bajo porcentaje de humedad.

Para separar la parte no fibrosa de las fibras rotas se hace necesario algún tipo de método de separación, por las características de los materiales sería factible utilizar una trilladora cilíndrica como aparece en la Figura 7 del Capítulo I.

El material no fibroso obtenido de las hojas del *Agave angustifolia* Haw está formado por las virutas de la corteza de color verde oscuro y por láminas finas constituidas por la epidermis de la hoja de cierta transparencia como se muestra en la Figura 56



Figura 56. Residuos no fibrosos.

Podemos agregar que el material no fibroso puede constituir una fuente importante de alimento para el ganado, sobre todo en zonas semiáridas donde la disponibilidad de recursos para alimentar a la ganadería que depende del pasto es muy escasa.

CONCLUSIONES

1. Existen diferencias significativas en las propiedades físicas y mecánicas de las hojas del *Agave angustifolia* Haw y del *Agave fourcroydes* que justificaron la necesidad de determinar los parámetros específicos de diseño de los órganos de trabajo de una máquina desfibadora de hojas verdes de *Agave angustifolia* Haw.
2. El modelo de máquina desfibadora más adecuada para realizar ensayos y determinar sus índices de trabajo es una desfibadora de un solo tambor y rodillos de presión en el sistema de alimentación. La velocidad de corte de las cuchillas se estableció en $V_t=27,175$ m/s y se acoplaron 16 cuchillas al cilindro desfibador.
3. Para los experimentos planeados, la variación de los niveles de la velocidad de avance de las hojas tendrán una influencia mayor sobre longitud de acción de una paleta que la variación de las revoluciones por minuto del órgano desfibador.
4. Se entrenó una red neuronal de retropropagación que logró correlacionar la calidad del proceso de desfibado de hojas verdes de *Agave angustifolia* Haw y los parámetros de diseño de la máquina desfibadora. El modelo se con un valor del error cuadrático medio mínimo igual a 4.3.
5. La optimización multiobjetivo mediante algoritmos genéticos demostró ser una vía factible para llegar a una solución de tres parámetros óptimos de diseño en un problema complejo y con carencia de información. Por tato, para producir fibra con la menor cantidad de residuos con una menor calidad de fibras rotas se fijó la holgura de desfibado en 1.28 mm, la velocidad de entrada en 0.52 m/s y la velocidad de salida en 0.75 m/s. De esta forma se obtiene un 63.65 % de limpieza de las fibras que indica que está dentro de la limpieza

aceptable, es decir por debajo del 65% además de ser la que menor cantidad de fibras rotas produce con un 17.47 %.

RECOMENDACIONES

- 1- En el momento de aplicar método empleado se deben considera las peculiaridades del problema en sí que se quiera optimizar. En dependencia del proceso, se deben elegir las variables que se van a relacionar en el modelo y luego a optimizar.
- 2- En trabajos futuros se recomienda variar el ángulo de afilamiento de las cuchillas, así como la velocidad de impacto de las mismas para continuar buscando posibles relaciones que lleven a disponer de mayor información sobre el proceso de desfibrado de hojas *Agave angustifolia* Haw.

BIBLIOGRAFIA

- Abouhamze, M. y Shakeri, M. (2007). Multi-objective stacking sequence optimization of laminated cylindrical panels using a genetic algorithm and neural networks. *Composite Structures*, 81 (2), p.253–263.
- Aguir, H., BelHadjSalah, H. y Hambli, R. (2011). Parameter identification of an elasto-plastic behaviour using artificial neural networks–genetic algorithm method. *Materials & Design*, 32 (1), p.48–53.
- Alves, M. O. y Santiago, E. G. (2006). Tecnologia e relações sociais de produção no setor sisaleiro nordestino. *Revista Econômica do Nordeste, Fortaleza*, 37 (3).
- ASTM D 6110. (2010). *Test Method for Determining the Charpy Impact Resistance of Notched Specimens of Plastics*. ASTM International.
- ASTM D 695. (2010). *Test Method for Compressive Properties of Rigid Plastics*. ASTM International.
- ASTM D 732-02. (2010). *Test Method for Shear Strength of Plastics by Punch Tool*. ASTM International.
- ASTM D-4000. (2012). *Classification System for Specifying Plastic Materials*. ASTM International.
- ASTM D5947. (2011). *Test Methods for Physical Dimensions of Solid Plastics Specimens*. ASTM International.
- Bäck, T. (1994). *Evolutionary algorithms in theory and practice: Evolution Strategies, Evolutionary Programming, Genetic Algorithms*. New York: Oxford University Press.
- Bagirov, A. M., Rubinov, A. M. y Yearwood, J. (2002). A global optimization approach to classification. *Optimization and Engineering*, 3 (2), p.129–155.
- Bishop, C. M. (1995). *Neural networks for pattern recognition*. Oxford University Press.
- Bratina, B., Muškinja, N. y Tovornik, B. (2009). Design of an auto-associative neural network by using design of experiments approach. *Neural Computing and Applications*, 19 (2), p.207–218.
- Al-Bulushi, N. I., King, P. R., Blunt, M. J. y Kraaijveld, M. (2010). Artificial neural networks workflow and its application in the petroleum industry. *Neural Computing and Applications*, 21 (3), p.409–421.
- Caballero, M. C., Santos, L. S., Hernández, I. L., José, A. J., Martínez, C. I. ., Bernabé, J. L. . y Méndez, R. F. . (2008). *Caracterización de propiedades mecánicas de fibras del Agave angustifolia Haw*. En: 2008, SOMIM.

Cao, M., Qiao, P. y Ren, Q. (2009). Improved hybrid wavelet neural network methodology for time-varying behavior prediction of engineering structures. *Neural Computing and Applications*, 18 (7), p.821–832.

Chen, Y., Gratton, J. L. y Liu, J. (2004). Power Requirements of Hemp Cutting and Conditioning. *Biosystems Engineering*, 87 (4), p.417–424.

Cid Álvarez, J. M. (2007). *Nuevas herramientas software para el diseño de dispositivos pasivos de microondas basadas en elementos finitos 3D y redes neuronales*. Doctorado, Universidad Politécnica de Madrid: Escuela Técnica Superior de Ingeniería de Telecomunicación.

Cruz, F. de J. P. (2011). *Agaves productores de fibras duras en el estado de Oaxaca, México*.

Cruz, F. J. . (2000). Agaves productores de fibras duras en el estado de Oaxaca, Mexico. *Boletín de la Sociedad Botánica de México*, (66), p.93–102.

Davis, C., Hong, S., Setia, R., Pratap, R., Brown, T., Ku, B., Triplett, G. y May, G. (2004). An object-oriented neural network simulator for semiconductor manufacturing applications. En: *Proc. 8th World Multi-Conference on Systemics, Cybernetics and Informatics*, 2004.

Davis, L. (1991). *Handbook of genetic algorithms*. Lawrence Davis.

Duda, R. O., Hart, P. E. y Stork, D. G. (2001). Pattern classification. *New York: John Wiley, Section*, 10, p.1.

Elsayed, K. y Lacor, C. (2013). CFD modeling and multi-objective optimization of cyclone geometry using desirability function, artificial neural networks and genetic algorithms. *Applied Mathematical Modelling*, 37 (8), p.5680–5704.

Farley, S. J., Durodola, J. F., Fellows, N. A. y Hernández-Gómez, L. H. (2008). A Neural Network Approach for Locating Multiple defects. *Applied Mechanics and Materials*, 13, p.125–131.

Fernández, E. y Martínez, A. (1988). Modelo matematico para la determinacion de la potencia consumida en el proceso tecnologico del corte de tallos mediante organos de cortes rotacionales de eje horizontal [forraje]. *Revista Ciencias Tecnicas Agropecuarias. CU. 1988 Pag*, 1, p.79–88.

Fonseca, C. M. y Fleming, P. J. (1993). Genetic Algorithms for Multiobjective Optimization: Formulation Discussion and Generalization. En: *ICGA*, 93, 1993, p.416–423.

Fonseca, C. M. y Fleming, P. J. (1995). An overview of evolutionary algorithms in multiobjective optimization. *Evolutionary computation*, 3 (1), p.1–16.

Gen, M. y Cheng, R. (2000). *Genetic algorithms and engineering optimization*. John Wiley & Sons.

Ghaboussi, J. (2010). Advances in Neural Networks in Computational Mechanics and Engineering. En: Waszczyszyn, Z. (ED.), *Advances of Soft Computing in Engineering*, CISM International Centre for Mechanical Sciences 512, Springer Vienna, p.191–236.

- Gholizadeh, S., Salajegheh, E. y Torkzadeh, P. (2008). Structural optimization with frequency constraints by genetic algorithm using wavelet radial basis function neural network. *Journal of Sound and Vibration*, 312 (1–2), p.316–331.
- Ghorbanian, J., Ahmadi, M. y Soltani, R. (2011). Design predictive tool and optimization of journal bearing using neural network model and multi-objective genetic algorithm. *Scientia Iranica*, 18 (5), p.1095–1105.
- Glover, F. (1986). Future paths for integer programming and links to artificial intelligence. *Computers & Operations Research*, 13 (5), p.533–549.
- Havel, J., Peña, E. M., Rojas-Hernández, A., Doucet, J.-P. y Panaye, A. (1998). Neural networks for optimization of high-performance capillary zone electrophoresis methods: A new method using a combination of experimental design and artificial neural networks. *Journal of Chromatography A*, 793 (2), p.317–329.
- Husseinzadeh Kashan, A. (2011). An efficient algorithm for constrained global optimization and application to mechanical engineering design: League championship algorithm (LCA). *Computer-Aided Design*, 43 (12), p.1769–1792.
- Izeboudjen, N., Bouridane, A., Farah, A. y Bessalah, H. (2011). Application of design reuse to artificial neural networks: case study of the back propagation algorithm. *Neural Computing and Applications*.
- Jain, L. C. (2010). Advances in design and application of neural networks. *Neural Computing and Applications*, 19 (2), p.167–168.
- Joseph, G. M. (1992). *Revolución desde afuera: Yucatán, México y los Estados Unidos, 1880-1924*. Fondo De Cultura Economica USA.
- Juvinall, R. C. y Marshek, K. M. (2011). *Fundamentals of Machine Component Design*. 5th ED. Wiley.
- Kim, G.-H., Yoon, J.-E., An, S.-H., Cho, H.-H. y Kang, K.-I. (2004). Neural network model incorporating a genetic algorithm in estimating construction costs. *Building and Environment*, 39 (11), p.1333–1340.
- Krish, S. (2011). A practical generative design method. *Computer-Aided Design*, 43 (1), p.88–100.
- Lambert, W. O. (1921). *Fiber-Extracting Machine*. p.12.
- López Hernández, I. (2008). *Pruebas de resistencia a la tensión en fibras de las hojas del Agave angustifolia Haw para determinar su comportamiento mecánico*. Maestría, CIIDIR Unidad Oaxaca.
- Marín, L., Trias, D., Badalló, P., Rus, G. y Mayugo, J. A. (2012). Optimization of composite stiffened panels under mechanical and hygrothermal loads using neural networks and genetic algorithms. *Composite Structures*, 94 (11), p.3321–3326.

- Marzbanrad, J. y Ebrahimi, M. R. (2011). Multi-Objective Optimization of aluminum hollow tubes for vehicle crash energy absorption using a genetic algorithm and neural networks. *Thin-Walled Structures*, 49 (12), p.1605–1615.
- Mengistu, T. y Ghaly, W. (2007). Aerodynamic optimization of turbomachinery blades using evolutionary methods and ANN-based surrogate models. *Optimization and Engineering*, 9 (3), p.239–255.
- Miller, R. W. (1997). Roller compaction technology. *Drugs and the pharmaceutical sciences*, 81, p.99–150.
- Mirzaei, M., Shakeri, M., Sadighi, M. y Akbarshahi, H. (2011). Crashworthiness Design for Cylindrical Tube using Neural Network and Genetic Algorithm. *Procedia Engineering*, 14, p.3346–3353.
- Mutluer, M. y Bilgin, O. (2011). Comparison of stochastic optimization methods for design optimization of permanent magnet synchronous motor. *Neural Computing and Applications*.
- NOM-168-SCFI. (2005). NORMA OFICIAL MEXICANA NOM-168-SCFI-2005, BEBIDAS ALCOHOLICAS-BACANORA-ESPECIFICACIONES DE ELABORACION, ENVASADO Y ETIQUETADO PREFACIO. *DIARIO OFICIAL DE LA FEDERACIÓN*, p.37.
- Pateullo, E. J. Y. (1861). *Improvement in Machines for Dressing the Leaves of the Agave Plant*.
- Pérez de Corcho Fuentes, J. S., Garbati Pegna, F., Iglesias Coronel, C., García Reina, F. y Spugnoli, P. (2009). Power demand of a flail shredder during the harvest of pineapple fields. *Ciencia e investigación agraria*, 36 (1), p.59–68.
- Pérez de Corcho-Fuentes, J. S. y Garbati-Pegna, F. (2008). Mathematically modelling the power requirement for a vertical shaft mowing machine. *Ingeniería e Investigación*, 28 (3), p.122–125.
- Poloni, C., Giurgevich, A., Onesti, L. y Pediroda, V. (2000). Hybridization of a multi-objective genetic algorithm, a neural network and a classical optimizer for a complex design problem in fluid dynamics. *Computer Methods in Applied Mechanics and Engineering*, 186 (2–4), p.403–420.
- Press, W. H., Teukolsky, S. A., Vetterling, W. T. y Flannery, B. P. (2007). *Numerical Recipes Source Code CD-ROM 3rd Edition: The Art of Scientific Computing*. Cambridge University Press.
- Abu Qdais, H., Bani Hani, K. y Shatnawi, N. (2010). Modeling and optimization of biogas production from a waste digester using artificial neural network and genetic algorithm. *Resources, Conservation and Recycling*, 54 (6), p.359–363.
- Ramírez, J. (1995). Los magueyes, plantas de infinitos usos. *Biodiversitas*, 3, p.1–7.
- Rao, R. V., Savsani, V. J. y Vakharia, D. P. (2011). Teaching–learning-based optimization: A novel method for constrained mechanical design optimization problems. *Computer-Aided Design*, 43 (3), p.303–315.










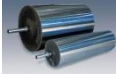




- Ribeiro Ferreira da Silva, O. R. y Macedo Coutinho, W. (2006). Cultivo do Sisal. *Embrapa Algodão*, 5.
- Richardson, J., Ormerod, T. C. y Shepherd, A. (1998). The role of task analysis in capturing requirements for interface design. *Interacting with Computers*, 9 (4), p.367–384.
- Rojas, R. (1996). The backpropagation algorithm. En: *Neural Networks*, Springer, p.149–182.
- Rössel Kipping, D., Ortiz Laurel, H. y Mayorga Hernández, E. (2003). Teoría funcional de una máquina desfibadora de lechuguilla (agave lechuguilla torr) de tipo tambor. *Naturaleza y Desarrollo*, 1 (2).
- Ruijter, W., Spallino, R., Warnet, L. y de Boer, A. (2003). Optimization of composite panels using neural networks and genetic algorithms. En: K.J. Bathe (ED.), *Computational Fluid and Solid Mechanics 2003*, Oxford: Elsevier Science Ltd, p.2359–2363.
- SAGARPA. (2012). *Anuario Estadístico de Producción Agrícola. Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación*. México.
- Sanders, T. G. (1977). *Henequen: the structure of agrarian frustration*, 3. American Universities Field Staff, inc.
- Sathiya, P., Panneerselvam, K. y Abdul Jaleel, M. Y. (2012). Optimization of laser welding process parameters for super austenitic stainless steel using artificial neural networks and genetic algorithm. *Materials & Design*, 36, p.490–498.
- Shinners, K. J., Binversie, B. N., Muck, R. E. y Weimer, P. J. (2007). Comparison of wet and dry corn stover harvest and storage. *Biomass and Bioenergy*, 31 (4), p.211–221.
- Silva Santos, L., Hernández Gómez, L. H., Caballero Caballero, M. y López Hernández, I. (2009). Tensile Strength of Fibers Extracted from the Leaves of the angustifolia Haw Agave in Function of their Length. *Applied Mechanics and Materials*, 15, p.103–108.
- Smith, S., Smith, G. y Shen, Y.-T. (2012). Redesign for product innovation. *Design Studies*, 33 (2), p.160–184.
- Srivastava, A. K., Goering, C. E., Rohrbach, R. P. y Buckmaster, D. R. (1993). *Engineering principles of agricultural machines*. American society of agricultural engineers.
- Sudhakaran, R., Vel Murugan, V., Sivasakthivel, P. S. y Balaji, M. (2011). Prediction and optimization of depth of penetration for stainless steel gas tungsten arc welded plates using artificial neural networks and simulated annealing algorithm. *Neural Computing & Applications*, p.1–13.
- Suinaga, F. A. (2006). Cultivo de sisal na região semi-árida do nordeste brasileiro. *Embrapa Algodão*.

- Tan, C. J., Lim, C. P. y Cheah, Y. (2012). A multi-objective evolutionary algorithm-based ensemble optimizer for feature selection and classification with neural network models. *Neurocomputing*.
- Trujillo, N. (1944). Las primeras máquinas desfibradoras de henequén. *Enciclopedia Yucatanense*, 3.
- VALENCIA, E. (1997). Optimización mediante algoritmos genéticos. En: *Anales del Instituto de Ingenieros de Chile*, 109, 1997, p.83–92.
- Wang, X., Zhang, C., Li, P., Wang, K., Hu, Y., Zhang, P. y Liu, H. (2012). Modeling and optimization of joint quality for laser transmission joint of thermoplastic using an artificial neural network and a genetic algorithm. *Optics and Lasers in Engineering*, 50 (11), p.1522–1532.
- Watrous, R. L. (1988). Learning algorithms for connectionist networks: Applied gradient methods of nonlinear optimization. *Technical Reports (CIS)*, p.597.
- Xu, J. (2010). *Analysis and design of hemp fibre decorticators*. Maestría, Winnipeg: University of Manitoba.
- Yao, X. y Liu, Y. (1997). A new evolutionary system for evolving artificial neural networks. *Neural Networks, IEEE Transactions on*, 8 (3), p.694–713.
- Yasuko Yamashita, R., Kato, M., Piva, R., do Valle Giuliano, R., Meigikos dos Santos, A. y Barreto de Carvalho, A. (2008). *Diagnóstico das condições de trabalho no beneficiamento do sisal*. En: 2008, p.4.
- Yu, Y., Min, W., Haibo, W. y Lin, H. (2010). Design and Optimization of Press Bend Forming Path for Producing Aircraft Integral Panels with Compound Curvatures. *Chinese Journal of Aeronautics*, 23 (2), p.274–282.
- Zhang, L. y Subbarayan, G. (2002). An evaluation of back-propagation neural networks for the optimal design of structural systems: Part I. Training procedures. *Computer Methods in Applied Mechanics and Engineering*, 191 (25–26), p.2873–2886.
- Zhang, Q. J., Gupta, K. C. y Devabhaktuni, V. K. (2003). Artificial neural networks for RF and microwave design-from theory to practice. *Microwave Theory and Techniques, IEEE Transactions on*, 51 (4), p.1339–1350.
- Zhou, A., Qu, B.-Y., Li, H., Zhao, S.-Z., Suganthan, P. N. y Zhang, Q. (2011). Multiobjective evolutionary algorithms: A survey of the state of the art. *Swarm and Evolutionary Computation*, 1 (1), p.32–49.



















ANEXOS







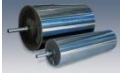
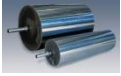
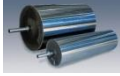
ANEXO 1. FUNCIONES DEL PROCESO DE DESFIBRADO.

Función primaria	Función secundaria	OPCIONES PROPUESTAS (DISPOSITIVOS)				
Energizar	Mover	 Motor eléctrico	 Motor Gasolina.	 Motor Diésel.	 Árbol toma de fuerza.	
	Trasmitir	 Poleas y correas	 Cadenas y ruedas dentadas	 Engranajes		
Alimentar	Comprimir	 Rodillos	 Prensa para comprimir			
	Transportar	 Transportador De bandas	 rodillos Transportadores	 Tornillo Sin fin	 Cadenas Transportadoras	 Rodillos
	Sujetar	 Bandas	 Rodillos	 Guantes		
Desfibrar	Golpear	 Cuchillas	 Martillos			
	Desgarrar	 Púas	 Cepillo acero			

	Impulsar					
		Cuchillas	Centrifuga			
	Contener					
		Bastidor compuesto	Casco circular			
	Soportar					
		Bastidor perfiles	Mesa soporte			
Expulsar	Proyectar					
	Expandir	Cuchillas	Púas	Martillos		
Retirar	Comprimir					
	Transportar	Rodillos				
	Sujetar					
	Peinar					
		Púas	Cepillo acero			



ANEXO 2. GENERACIÓN DE CONCEPTOS.

Función	CONCEPTO 1	CONCEPTO 2	CONCEPTO 3
Mover	 Motor eléctrico	 Motor Eléctrico	 Motor Eléctrico
Comprimir Transportar Sujetar	 Rodillos	 Rodillos	 Rodillos
Trasmitir 1	 Poleas y correas	 Poleas y correas	 Poleas y correas
Trasmitir 2	 Cadenas y ruedas dentadas	 Cadenas y ruedas dentadas	 Cadenas y ruedas dentadas
Golpear Desgarrar Impulsar	 Cuchillas	 Púas	 Mixto
Contener	 Casco circular	 Casco circular	 Casco circular


Soportar	 Bastidor perfiles	 Bastidor perfiles	 Bastidor perfiles
Peinar	 Cuchillas	 Púas	 Mixto
Transportar	 Rodillos	 Rodillos	 Rodillos

HISTORIAL DE REVISIONES

REV	DESCRIPCION	FECHA	APROVADO





FRESADO: 16 ELEMENTOS



NOMBRE	FECHA	IPN-CIIDIR-OAXACA raudetrio@gmail.com	
DIBUJADO	Raudel	10/10/2013	
REVISADO			
APROVADO			
DIRECTOR			
DESFIBRADORA DE HOJAS DE AGAVE		TITULO	CILINDRO DESFIBRADOR
		FORMATO	A4
		DIBUJO NUMERO	1
		ACERO	Acero Estructural
		ESCALA: 1:5	PESO: 15.154 kg

HISTORIAL DE REVISIONES

REV	DESCRIPCION	FECHA	APROVADO



NOMBRE	FECHA
Raudel	10/10/2013



IPN-CIIDIR-OAXACA raudelrio@gmail.com
TITULO CILINDRO DE ALIMENTACION

DESFIBRADORA DE HOJAS DE AGAVE	FORMATO	DIBUJO NUMERO	REV
	A4	6	
ESCALA: 1:5		PESO: 4.807 kg	


Acero al carbono

HISTORIAL DE REVISIONES

REV	DESCRIPCION	FECHA	APROVADO



SECCION A-A



NOMBRE	FECHA
Raudel	10/10/2013


IPN-CIIDIR-OAXACA raudelrio@gmail.com	
DISCO CENTRO	
FORMATO	DIBUJO NUMERO
A4	3
Acero Estructural	
ESCALA: 1:5	PESO: 15.154 kg

DESFIBRADORA DE HOJAS DE AGAVE

REV	
-----	--


HISTORIAL DE REVISIONES

REV	DESCRIPCION	FECHA	APROVADO




SECCION B-B

SECCION A-A



DIBUJADO	Raudel	FECHA	10/10/2013
REVISADO			
APROVADO			
DIRECTOR			
IPN-CIIDIR-OAXACA raudelrio@gmail.com			
TITULO		EJE DEL CILINDRO DESFIBRADOR	
FORMATO	DIBUJO NUMERO	REV	
A4	2		
DESCFIBRADORA DE HOJAS DE AGAVE			
ESCALA: 1:4	PESO: 6.221 kg		

HISTORIAL DE REVISIONES		
REV	DESCRIPCION	FECHA





SECCION A-A

SECCION B-B

DIBUJADO	Raudel	FECHA	10/10/2013
REVISADO			
APROVADO			
DIRECTOR			
IPN-CIIDIR-OAXACA		raudelrio@gmail.com	
TITULO			
EJE DEL CILINDRO DE ALIMENTACION			
FORMATO	DIBUJO NUMERO	REV	
A4	8		
DESCRIPCION			
DEFIBRADORA DE HOJAS DE AGAVE			
ESCALA: 1:5	PESO: 2.215 kg		

HISTORIAL DE REVISIONES

REV	DESCRIPCION	FECHA	APROVADO






NOMBRE	FECHA
Raudel	10/10/2013

IPN-CIDIR-OAXACA raudelrio@gmail.com	
TITULO CUCHILLA	
FORMATO A4	DIBUJO NUMERO 5
Acero Inoxidable	
ESCALA: 1:2	PESO: 0.524 kg


DESFIBRADORA DE HOJAS DE AGAVE

HISTORIAL DE REVISIONES

REV	DESCRIPCION	FECHA	APROVADO



ϕ 9.29



NOMBRE	FECHA
Raudel	11/06/13

IPN-CIIDIR-OAXACA
 raudelrio@gmail.com

TITULO
SOPORTE CUCHILLA

FORMATO	DIBUJO NUMERO	REV
A4	4	



DESFIBRADORA DE HOJAS DE AGAVE

Acero estructural

ESCALA: 1:2 PESO: 0.77 kg

HISTORIAL DE REVISIONES

REV	DESCRIPCION	FECHA	APROVADO



DIBUJADO	NOMBRE	FECHA
Raudel	Raudel	10/10/2013
REVISADO		
APROVADO		
DIRECTOR		

IPN-CIIDIR-OAXACA raudelrio@gmail.com	
TITULO	Disco y centro cilindro de alimentaci3n
FORMATO	DIBUJO NUMERO
A4	7
Acero Estructural	
ESCALA: 1:1	PESO: 0,808 kg

DESFIBRADORA DE HOJAS DE AGAVE

ANEXO 4. PARÁMETROS EXPERIMENTALES DE LA MÁQUINA DESFIBRADORA.

	Intensidades de entrada			Intensidades de salida			Tiempo de entrada	Tiempo de salida
	I1	I2	I3	I1	I2	I3		
1.	12.22	11.15	11.04	9.98	9.39	8.82	6.05	3.59
2.	11.15	10.35	9.96	11.79	10.59	10.29	5.08	0.89
3.	11.06	10.29	9.6	13.32	12.76	12.29	1.59	0.66
4.	13.85	12.91	12.4	14.85	13.67	11.02	1.27	1
5.	13.84	12.21	12.8	12.2	12.25	10.92	2.86	2.13
6.	13.19	12.27	12.34	14.74	13.58	13.44	1.09	0.93
7.	10.99	9.89	9.79	9.97	8.71	8.3	9.2	7.16
8.	11.95	11	10.15	11.08	10.1	9.4	4.58	3.16
9.	12.71	13.13	12.47	11.79	11.62	11.27	0.95	0.83
10.	11.67	9.06	10.64	14.41	13.46	13.07	0.97	1.12
11.	10.9	9.85	9.64	10.31	9.35	9.09	17.33	2.67
12.	13.55	12.09	12.58	10.2	9.01	9.88	2.83	2.58
13.	11.25	10.02	9.92	9.79	8.76	8.61	8.06	5.15
14.	11.37	10.18	9.98	9.55	8.64	8.4	14.09	7.75
15.	10.89	9.76	9.54	9.71	8.86	8.61	12.72	3.61
16.	11.95	10.99	10.21	11.71	10.48	11.02	5.5	1.66
17.	12.54	11.24	11.11	11.94	10.17	10.06	2.07	1.9

18.	12.09	11.48	11.26	11.2	10.89	9.49	4.47	3.2
19.	11.3	10.35	10.08	10.81	9.98	9.58	5.54	3.35
20.	11.15	10.11	9.8	9.57	9.03	8.76	6.26	3.18
21.	11.18	10.05	9.74	11.29	10.12	8.78	5.54	1.6
22.	12.11	11.11	10.65	10.9	9.77	8.79	6.26	1.2
23.	11.15	9.9	9.85	9.73	8.75	8.89	7.19	1.5
24.	12.38	10.94	11.02	13.28	10.02	8.85	1.63	1.21
25.	11.65	9.83	10.43	12.6	10.67	11.34	1.92	2
26.	14.27	13.21	13.42	12.43	10.98	13.21	2.28	0.84
27.	11.21	10.53	9.93	9.66	8.85	8.54	3.7	1.55
28.	11.05	10.03	9.9	9.86	8.86	8.7	3.75	1.43
29.	13.11	12.73	12.4	14.8	13.96	13.59	2.07	0.73
30.	12.85	10.03	10.69	13.51	11.82	10.47	2.6	1.74
31.	11.49	10.33	10.09	11.18	9.68	9.65	7.87	2.24
32.	11.62	10.59	10.28	9.75	8.86	8.52	5.4	8.89
33.	14.12	12.08	12.11	14.67	11.92	11.37	1.79	4.72
34.	13.02	11.66	11.64	11.26	10.01	9.79	2.25	1.87
35.	11.3	10.14	9.96	10.27	9.75	9.67	8.05	1.25
36.	12.68	11.6	12.27	13.32	12.49	12.44	1.32	1.29
37.	11.05	10.02	9.55	10.85	9.79	9.99	4.2	1.23
38.	11.67	10.51	10.16	9.63	8.7	8.31	7.1	8.97
39.	12.05	11.02	10.78	12.16	11.12	9.84	2.09	1.03
40.	12.71	10.5	10.53	11.19	10.18	10.28	1.07	1.16

41.	10.79	9.39	9.04	9.49	8.5	7.98	12.16	6.52
42.	12.61	10.85	10.86	9.18	7.99	7.58	5.34	5.21
43.	13.43	11.1	10.56	9.19	8	7.89	4.24	3.62
44.	12.61	11.83	10.59	9.08	8.04	8.95	3.41	2.89
45.	10.97	9.66	9.74	9.57	8.4	8.42	13.21	10.04
46.	10.63	9.21	9.41	9.43	8.31	8.33	13.07	8.22
47.	10.16	8.84	8.82	9.08	7.97	7.93	14.38	16.32
48.	11.3	9.67	9.91	9.1	7.9	7.95	14.11	13.96
49.	10.81	8.98	8.99	10	8.84	8.74	6.51	3.32
50.	11.42	10.03	10.02	10.58	9.26	9.26	5.17	2.8
51.	12.2	11.32	10.34	10.36	9.62	8.64	5.16	4.34
52.	11.92	11.04	9.82	11.1	10.86	9.14	2.63	1.66
53.	11.95	10.84	8.9	9.49	9.11	8.96	1.61	1.68
54.	11.79	11.03	9.77	8.98	8.59	7.8	1.26	1.08
55.	11.04	10.24	9.26	9.12	8.65	7.69	2.41	4.93
56.	11.69	10.71	9.89	8.49	8.94	8.67	2.55	2.28
57.	11.96	11.42	10.53	10.49	8.94	8.67	1.89	1.2
58.	10.98	10.25	10.53	8.94	8.44	7.63	3.71	1.35
59.	11.18	10.66	9.91	10.23	10.18	8.71	1.45	1.87
60.	12.59	11.79	8.98	10.36	9.88	8.8	1.22	1.94
61.	12.07	11.78	11	11.14	11.76	9.62	4.01	1.67
62.	12.32	10.86	10.83	9.66	8.59	8.32	6.46	6.34
63.	13.3	11.68	11.75	11.63	10.78	10.31	1.46	0.65

64.	12.58	11.56	11.18	11.39	9.59	9.8	1.61	0.75
65.	12.08	10.64	10.55	11.68	9.55	9.05	6.28	1.14
66.	12.05	10.69	10.49	9.55	8.54	8.26	7.46	5.94
67.	12.71	11.72	11.33	11.71	10.19	10.04	3.01	0.89
68.	11.63	10.67	10.66	10.71	9.5	9.34	2.32	0.9
69.	11.13	10.08	9.94	9.17	8.38	8.21	8.74	9.37
70.	12.69	11.45	11.14	11.36	10.15	11.3	1.97	1.84

ANEXO 5. PARÁMETROS EXPERIMENTALES DEL MATERIAL DESFIBRADO.

	Peso hoja entera	peso agarre	Peso fibras enteras y residuo húmedo	Peso fibras rotas	Peso fibras secas sucias	Peso fibras secas limpias
1.	408	68	35	4.6	15.5	13.6
2.	375	65	25	9	14.7	14.1
3.	435	121	41	5.6	19.2	16.7
4.	481	109	30	9.1	14.2	13.5
5.	392	61	28	4.4	16.4	14.2
6.	434	74	39	4.3	18.3	16.3
7.	362	64	40	3.9	16.5	15.4
8.	415	72	30	4.6	15.2	13.9
9.	412	113	39	3.7	18.7	15
10.	437	11	42	3.4	19.8	16.5
11.	322	60	44	2.7	16.5	15.4
12.	485	108	56	10.7	20.1	19.1
13.	409	100	65	5.3	21.5	20.3
14.	470	110	49	15.1	17.5	16.2
15.	391	83	46	4.8	16.2	15.1
16.	447	102	84	3.2	26.8	25.1
17.	469	158	40	3.2	22.1	19.9
18.	559	79	79	2.2	28.7	32
19.	479	40	40	9.9	17.8	17
20.	431	43	43	3.5	17.4	16.1

21.	456	51	51	5.8	20	18.2
22.	628	75	75	2.7	31.1	28.8
23.	301	57	57	2.5	22.6	21.4
24.	371	59	45	4.1	20	18.9
25.	392	138	54	4	21.3	19.3
26.	631	242	80	2.9	31.1	29.1
27.	301	42	52	3.7	20.4	19
28.	295	59	40	4.2	16	15.3
29.	434	71	53	3.1	20.9	18
30.	376	52	47	3.1	19.2	18.1
31.	346	56	57	1.1	21.1	18
32.	369	55	31	3.2	14.3	12.4
33.	514	106	30	8.1	14.6	13.4
34.	422	80	38	5.2	17.1	14.9
35.	418	99	48	5.7	19.6	15.7
36.	432	110	43	3.2	19.4	15.8
37.	396	80	37	1.3	15.4	13.3
38.	418	89	34	6.8	13.7	11.6
39.	334	72	51	0.7	19.3	17.1
40.	363	82	39	0.7	17.2	14.9
41.	320	63	81	1.5	23.9	19.8
42.	378	81	90	1.1	27.7	24.5
43.	487	190	76	1.6	24.8	21.8

44.	496	181	67	2.3	23.3	21.4
45.	427	145	46	6.4	17.4	15.9
46.	489	258	46	2.3	16.9	16.9
47.	428	193	46	4.5	16.2	16.2
48.	647	319	50	6.5	18.4	15.7
49.	348	93	31	2	12.6	11.5
50.	409	120	38	2.6	16.4	15.8
51.	466	135	49	5.4	19.6	16.9
52.	388	93	38	4.6	16.5	14.8
53.	344	103	85	2.8	26.8	22.6
54.	366	106	85	1.1	27.6	23.1
55.	306	46	72	1.9	24	21.8
56.	287	39	41	5.1	17.1	15.3
57.	378	70	85	1.7	27.1	26.2
58.	314	70	78	2.2	22.6	19.5
59.	370	52	95	0.9	28.9	23.7
60.	335	59	50	1	18.9	16.2
61.	444	93	87	1.3	32.8	28.5
62.	401	74	65	3.7	25.1	22.6
63.	350	67	101	5.6	33.8	28.4
64.	325	55	108	8.1	33.2	28.5
65.	359	71	112	1.5	35.1	29.3
66.	347	63	130	1.3	39.2	31.4

67.	405	68	111	2.2	33.7	27.9
68.	335	49	92	1.4	28.8	21.9
69.	351	68	122	0.2	39.5	33.5
70.	345	61	124	0.3	35.5	30.8

ANEXO 6. CAPTURA Y MANIPULACIÓN DE LOS DATOS EXPERIMENTALES

```
clear all, clc, close all;
```

```
%PROCESAMIENTO DE LOS PARÁMETROS DE LA MÁQUINA DESDE EXCEL
```

```
% INTENSIDADES DE ENTRADA
```

```
INTENCIDADES_ENT=xlsread('BASE DE DATOS PM.xlsx',1);
```

```
% Suma los valores de las columnas y deja una sola fila.
```

```
SUMAINTENCIDADES_ENT=sum(INTENCIDADES_ENT); VOLT=220;
```

```
% POTENCIA DE DESFIBRADO ENTRADA Pfe
```

```
Pfe=VOLT*SUMAINTENCIDADES_ENT*0.8/(1000*sqrt(3)); POTFECOLUMNA=Pfe;
```

```
% INTENSIDADES DE SALIDA
```

```
INTENCIDADES_SAL=xlsread('BASE DE DATOS PM.xlsx',7);
```

```
% Suma los valores de las columnasfilas y deja una sola fila.
```

```
SUMAINTENCIDADES_SAL=sum(INTENCIDADES_SAL); VOLT=220;
```

```
% POTENCIA DE DESFIBRADO SALIDA Pfs
```

```
Pfs=VOLT*SUMAINTENCIDADES_SAL*0.8/(1000*sqrt(3));
```

```
POTFSCOLUMNA=Pfs; % RPMDEF-REVOLUCIONES DEL ÓRGANO DESFIBRADOR
```

```
RPMDEF=xlsread('BASE DE DATOS PM.xlsx',2);
```

```
% VIMP-VELOCIDAD DE IMPACTO REAL
```

```
% RDEF- RADIO DEL ORGAO DESFIBRADOR
```

```
RDEF=0.173; Vir=RPMDEF*RDEF*pi/30;
```

```
% TENT TIEMPO DE ENTRADA
```

```
TENT=xlsread('BASE DE DATOS PM.xlsx',3);
```

```

% TENT TIEMPO DE ENTRADA

TSAL=xlsread('BASE DE DATOS PM.xlsx',4);

% VENT_VELOCIDAD DE ENTRADA DE LA HOJA

VENT=1./TENT; VENTCOLUMNA=VENT';

% VENT_VELOCIDAD DE SALIDA DE LA HOJA

VSAL=1./TSAL; VSALCOLUMNA=VSAL';

% IMPORTAR HOLGURA DE DESFIBRADO -DDEF-

Hf=xlsread('BASE DE DATOS PM.xlsx',5); HFCOLUMNA=Hf';

%ENERGIA ENTRADA

Eent=Pfe.*TENT;

%ENERGÍA SALIDA

Esal=Pfs.*TSAL; EentCOLUMNA=Eent'; EsalCOLUMNA=Esal'; SUMENERGIA=Eent+Esal;

SUMENERGIACOLUMNA=SUMENERGIA';

%OBTENCIÓN DE LOS PARÁMETROS DE LAS FIBRAS DESDE EXCEL

%IMPORTAR PESO DE HOLA ENTERAS PHOJENT;

PHOJENT=xlsread('BASE DE DATOS PF.xlsx',1);

%IMPORTAR PESO DE AGARRE PAGARRE;

PAGARRE=xlsread('BASE DE DATOS PF.xlsx',2);

PDEFIB=PHOJENT-PAGARRE; PDEFIBCOLUMNA=PDEFIB';

%IMPORTAR PESO DE FIBRAS ENTERAS Y RESIDUOS PFEYR;

PFIBRAENTERRASYRESIDUOS=xlsread('BASE DE DATOS PF.xlsx',3);

%IMPORTAR PESO DE FIBRAS ROTAS;

PFIBRAROTA=xlsread('BASE DE DATOS PF.xlsx',4);

```



```

%IMPORTAR PESO DE FIBRAS SECAS SUCIAS;

PFIBRASUCIA=xlswread('BASE DE DATOS PF.xlsx',5);

%IMPORTAR PESO DE FIBRAS SECAS LIMPIAS;

PFIFALIMPIA=xlswread('BASE DE DATOS PF.xlsx',6);

% LIMPIEZA DE LAS FIBRAS;

LIMPIEZAFIBRA=100*PFIFALIMPIA./PFIBRAENTERRASYRESIDUOS;

LIMPIEZACOLUMNA=LIMPIEZAFIBRA';

% Residuos en LAS FIBRAS;

RESIDUOENFIBRAS=100*(PFIBRAENTERRASYRESIDUOS-
    PFIFALIMPIA)./PFIBRAENTERRASYRESIDUOS;

RESIDUOENFIBRASCOLUMNA=RESIDUOENFIBRAS';

% PORCIENTO DE PESO DE FIBRAS ENTERAS;

FIBRAENTERA=100*PFIFALIMPIA./(PFIFALIMPIA+PFIBRAROTA);

FIBRAENTERACOLUMNA=FIBRAENTERA';

% PORCIENTO DE PESO DE FIBRAS ROTAS;

FIBRAROTA=100*PFIBRAROTA./(PFIFALIMPIA+PFIBRAROTA);

FIBRAROTACOLUMNA=FIBRAROTA';

```

ANEXO 7. RED NEURONAL ENTRENADA.

% RED NEURONAL

%E- Entradas

E=[Hf; VENT; VSAL]; % Holgura de desfibrado; Velocidad de entrada; Velocidad de salida.

% O- Objetivos

O=[FIBRAROTA; RESIDUOSENFIBRAS]; % **Fibras rotas; Residuos**

clear net tr

net = newff(E,O,[10, 5],{'tansig' 'purelin'}, 'trainrp','learnkd','mse');

net.divideParam.trainRatio = 70/100; % **Adjust as desired**

net.divideParam.valRatio = 15/100; % **Adjust as desired**

net.divideParam.testRatio = 15/100; % **Adjust as desired**

[net,tr,Y] = train(net,E,O);

salidas = sim(net,E);

plotperform(tr)

ANEXO 8. ALGORITMO GENÉTICO MULTI OBJETIVO.

% ALGORITMO GENÉTICO MULTI OBJETIVO

Restricciones

```
% HOLGURA DE DESFIBRADO 1.25 < Hf > 2.0 mm
% VELOCIDAD DE ENTRADA 0.4 < VENT > 0.6 m/s
% VELOCIDAD DE SALIDA 0.6 < VSAL > 0.8 m/s
clc

objFcn = @(E) sim(net,E'); % Función que simula a la red neuronal y calcula las salidas.

NVAR=3; % Número de variables

A = [-1 0 0; 1 0 0; 0 -1 0; 0 1 0; 0 0 -1; 0 0 1]; % Restricciones de desigualdad lineal.

b = [-1.25; 2; -0.4; 0.6; -0.5; 0.8]; % Valores de desigualdad lineal

Aeq = []; beq = []; % No existen restricciones de igualdades lineales

lb = []; % Límite inferior de la solución.

ub = []; % Límite superior de la solución.

options = gaoptimset('PlotFcns',@gaplotpareto); % Opciones

[X,FVAL] = gamultiobj(objFcn,NVAR,A,b,Aeq,beq,lb,ub,options);

% Fin de la minimización de objFcn con 3 entradas.
```



SOCIEDAD MEXICANA DE INGENIERÍA MECÁNICA A.C.

**Raudel Perez Del Rio
Presente.**

CONSEJO DIRECTIVO

VICENTE BORJA RAMIREZ
Presidente

SIMÓN MARTÍNEZ MARTÍNEZ
Vicepresidente de Termofluidos

ELÍAS RIGOBERTO LEDESMA OROZCO
Vicepresidente de Mecánica Teórica

PEDRO ALBERTO PÉREZ OLIVAS
Vicepresidente de Diseño Mecánico

HÉCTOR PLASCENCIA MORA
Vicepresidente de Manufactura y Materiales

MAGDALENA TRUJILLO BARRAGÁN
Secretario

LEOPOLDO GONZÁLEZ GONZÁLEZ
Tesorero

ARTURO BARBA PINGARRÓN
Vocal de Educación

JUAN ANTONIO CÁRDENAS GALINDO
Vocal de Asuntos Estudiantiles

A la vez de saludarlo sirva este medio para informar a usted que el Comité Evaluador del 18 Congreso Internacional Anual de la SOMIM ha decidido aceptar para su presentación y publicación el trabajo titulado:

SIMULACIÓN DEL CORTE POR CIZALLAMIENTO DE LAS HOJAS DE AGAVE ANGUSTIFOLIA HAW MEDIANTE EL MEF.

Con clave de registro: A6_213

Asimismo confirmamos el cumplimiento de todos los lineamientos para incorporar su ponencia en la publicación de las memorias del Congreso de la SOMIM y presentación dentro del Congreso que se llevará a cabo los días 19, 20 y 21 de Septiembre del 2012 en Salamanca, Guanajuato, México.

En breve le enviaremos la información turística, ubicación de la sede, y en semanas próximas al evento el Programa General con la fecha, hora y lugar de la presentación de su artículo durante el Congreso.

A nombre de la SOMIM lo felicito por haber enviado un trabajo digno de ser publicado en las memorias del 18 Congreso Internacional Anual de la SOMIM.

En espera de que en el futuro podamos seguir contando con su decidida participación, reciba un cordial saludo.

Para cualquier duda que pudiera surgir me pongo a sus órdenes en la siguiente dirección de correo electrónico webmaster@somim.org.mx.


Reciba un cordial saludo.

Atentamente,

Dr. Vicente Borja Ramírez
PRESIDENTE DE LA SOMIM

México D.F. a 23 de Agosto del 2012

e-mail: webmaster@somim.org.mx



XV Congreso Nacional y I Internacional de Ciencias Agronómicas

del 24 al 26 de Abril del 2013



Otorga la presente

CONSTANCIA

A

MARTIN HIDALGO REYES

por su participación como
PONENTE

de la exposición

DISEÑO Y PRUEBA DE UN DISPOSITIVO MECANICO PARA DETERMINAR
LA RESISTENCIA AL CORTE, POR CIZALLAMIENTO, EN PROBETAS DE
Agave angustifolia Haw.

cuyos autores son

Pérez del R., R.; Hidalgo R., M.; Montes B., J. L.; Caballero C., M.

Chapingo, México. 24 al 26 de abril de 2013

Dr. Juan Martínez Solís
Presidente

Dra. María del Rosario García Mateos
Secretaria



San José de las Lajas, 31 de mayo de 2013
“Año 55 de la Revolución”

A QUIEN CORRESPONDA:

Asunto: autoría de artículo

Por la presente se hace constar que los profesores: **M.Sc. Raudel Pérez del Río, Dr.C. Magdaleno Caballero Caballero, Dr.C. Luís Héctor Hernández Gómez e Ing. José Luis Montes Bernabé**, son autores del artículo titulado: “**Diseño y construcción de una desfibradora de hojas de Agave Angustifolia Haw**”, el mismo fue aceptado por el Comité Editorial y saldrá publicado en la *Revista Ciencias Técnicas Agropecuarias*, 22(4), 2013.

La Revista Ciencias Técnicas Agropecuarias (RCTA) está inscrita con el código 0483107 en el Sistema de Certificación de Publicaciones Seriadas Científico-Tecnológicas del Ministerio de Ciencia Tecnología y Medio Ambiente (CITMA) de la República de Cuba. Algunos de los repertorios internacionales donde es procesada: SciELO; AGRIS (FAO); EBSCO Information Services; THOMSON GALE (Gale Group); CISTI; ACADEMIC ONE FILE; INFOTRAC CUSTOM; PERÍODICA; LATINDEX; REDALYC; ACTUALIDAD IBEROAMERICANA y CUBACIENCIAS.

Me coloco a su disposición para otras informaciones que sean necesarias y extendiendo la presente para los fines que a los mismos convengan, en San José de las Lajas, Mayabeque, Cuba, el treinta y uno de mayo del año dos mil trece.

Cordialmente


PEDRO P. PANEQUE RONDÓN
DIRECTOR DE LA REVISTA
CIENCIAS TÉCNICAS AGROPECUARIAS.



Universidad Agraria de La Habana, Centro de Mecanización Agropecuaria (CEMA)

P-☎: Carretera de Tapaste y Autopista Nacional San José de las Lajas, Mayabeque, Cuba

☎: at work (53) (47) 86-4346 E-✉: rcta@unah.edu.cu url: <http://www.unah.edu.cu>