

**UNIVERSIDAD AUTONOMA DE NUEVO LEON
FACULTAD DE INGENIERIA MECANICA Y ELECTRICA
DIVISION DE ESTUDIOS DE POSGRADO**



**CLASIFICACION DE FALLAS Y OSCILACIONES EN UN
SISTEMA ELECTRICO UTILIZANDO EL ALGORITMO
DE PERCEPTRON DIFUSO**

TESIS

**EN OPCION AL GRADO DE MAESTRO EN CIENCIAS DE
LA ADMINISTRACION CON ESPECIALIDAD EN SISTEMAS**

PRESENTA:

ING. VALERIA PAOLA GONZALEZ DUEÑEZ

CD. UNIVERSITARIA

ABRIL DE 2004

22

27

30

35

40

45

50

55

60

65

70

75

80

85

CLASIFICACION DE FALLAS Y OSCILACIONES EN UN

SERVO MOTOR

UTILIZANDO EL ALGORITMO

DE PERCEPTRON DIFUSO



1020146698



UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

DIRECCIÓN GENERAL DE BIBLIOTECAS



UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA
DIVISIÓN DE ESTUDIOS DE POSGRADO



CLASIFICACIÓN DE FALLAS Y OSCILACIONES EN UN
SISTEMA ELÉCTRICO UTILIZANDO EL ALGORITMO
DE PERCEPTRON DIFUSO

U A N L
T E S I S

EN OPCIÓN AL GRADO DE MAESTRO EN CIENCIAS DE
LA ADMINISTRACIÓN CON ESPECIALIDAD EN SISTEMAS

DIRECCIÓN GENERAL DE BIBLIOTECAS

PRESENTA:
ING. VALERIA PAOLA GONZALEZ DUEÑEZ

CD. UNIVERSITARIA

ABRIL DE 2004

979 966

TM
Z 5853
.M2
F14E
200 1
.E6



UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

®

DIRECCIÓN GENERAL DE BIBLIOTECAS



FONDO
TESIS

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA
DIVISIÓN DE ESTUDIOS DE POSGRADO



CLASIFICACIÓN DE FALLAS Y OSCILACIONES EN UN
SISTEMA ELÉCTRICO UTILIZANDO EL ALGORITMO
DE PERCEPTRON DIFUSO

UANL
TESIS

EN OPCIÓN AL GRADO DE MAESTRO EN CIENCIAS DE
LA ADMINISTRACIÓN CON ESPECIALIDAD EN SISTEMAS

DIRECCIÓN GENERAL DE BIBLIOTECAS

PRESENTA:
ING. VALERIA PAOLA GONZALEZ DUEÑEZ

CD. UNIVERSITARIA

ABRIL DE 2004

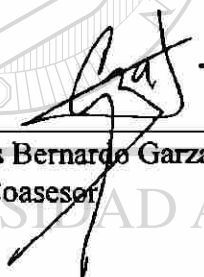

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA
DIVISIÓN DE ESTUDIOS DE POSGRADO

Los miembros del comité de tesis recomendamos que la tesis "Clasificación de Fallas y Oscilaciones en un Sistema Eléctrico utilizando el Algoritmo de Perceptrón Difuso" realizada por la alumna Ing. Valeria Paola González Duéñez sea aceptada para su defensa como opción al grado de Maestro en Ciencias de la Administración con Especialidad en Sistemas.

El comité de Tesis



Dr. Oscar Leonel Chacón Mondragón
Asesor

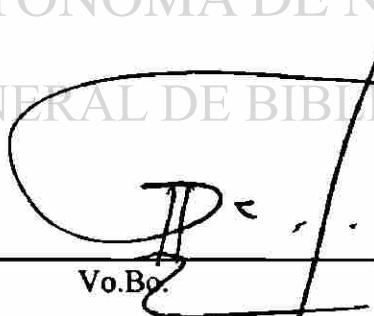


M.C. Carlos Bernardo Garza Treviño
Coasesor



Dr. Ernesto Vázquez Martínez
Coasesor

DIRECCIÓN GENERAL DE BIBLIOTECAS



Vo.Bo.

Dr. Guadalupe Alan Castillo Rodríguez
División de Estudios de Posgrado

San Nicolás de los Garza, N. L., a Abril de 2004.

DEDICO ESTE TRABAJO ESPECIALMENTE

...a **DIOS**,
y a ti Lupita.

Gracias una vez mas, y en realidad, espero que sean mas, a...

Tomás González Gutiérrez

y

Olga Duéñez Galván

... por ser motivo principal de llevar a cabo un posgrado y así demostrarles que los amo sobre todas las cosas, gracias por la educación que he recibido aun con las dificultades que hemos vivido, porque aunque ha sido poco, lo he valorado demasiado ... nuevamente, lo prometido es deuda!

De una manera especial en esta ocasión voy a agradecer a *Pedro Fabián Carrola Medina* y a *Paolita*, él por ser el compañero que Dios puso en mi camino, gracias por estar a mi lado en este momento tan importante y para siempre, gracias por hacerme tan feliz, y a ella por ser mi luz y ganas de vivir, a los dos gracias por haber llegado...


También, para todos los que han estado conmigo de alguna manera, GRACIAS.

AGRADECIMIENTOS

Gracias, a la Universidad Autónoma de Nuevo León y a la Facultad de Ingeniería Mecánica y Eléctrica, por darme la oportunidad de formar parte de ella.

Primeramente al Dr. Oscar Leonel Chacón Mondragón, quisiera agradecerle todo su apoyo, académico y emocional para la terminación de este trabajo, así como por todo el trayecto de mi maestría.

Quiero agradecer al Dr. Ernesto Vázquez Martínez y al M.C. Carlos Bernardo Garza Treviño por colaborar en la revisión de este trabajo de tesis, agradezco sus puntos de vista ya que ayudaron a fortalecer el presente estudio.



UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN



DIRECCIÓN GENERAL DE BIBLIOTECAS

...a todos gracias.

ÍNDICE

Página

1. INTRODUCCIÓN

| | | |
|-----|---------------------------|---|
| 1.1 | Objetivo del estudio | 1 |
| 1.2 | Justificación del trabajo | 1 |
| 1.3 | Descripción del problema | 2 |
| 1.4 | Hipótesis | 2 |
| 1.5 | Límites del estudio | 2 |
| 1.6 | Metodología | 3 |
| 1.7 | Revisión bibliográfica | 3 |

2. CLASIFICACIÓN Y RECONOCIMIENTO

| | | |
|------|-----------------------------------------------------------|---|
| 2.1. | Introducción | 4 |
| 2.2. | Conceptos de clasificación y reconocimiento | 5 |
| 2.3. | Separación de clases o agrupamientos | 6 |
| 2.4. | Concepto de agrupamientos con aprendizaje sin supervisión | 8 |
| 2.5. | Métodos útiles en el reconocimiento de patrones | 8 |

3. TEORÍA DE CONJUNTOS DIFUSOS

| | | |
|------|-------------------------------------------------------------|----|
| 3.1. | Introducción | 15 |
| 3.2. | Operaciones básicas con agrupamientos | 16 |
| 3.3. | Propiedades de los agrupamientos | 17 |
| 3.4. | Representación de funciones para los agrupamientos clásicos | 18 |
| 3.5. | Agrupamientos difusos | 19 |
| 3.6. | Operaciones con agrupamientos difusos | 20 |
| 3.7. | Propiedades de los agrupamientos difusos | 21 |
| 3.8. | Funciones de Membresía | 21 |
| 3.9. | Algoritmo difuso de C-Medias(FCM-Fussy C Means) | 26 |

4. ALGORITMO DE PERCEPTRÓN DIFUSO

| | |
|----------------------------------------------------------|----|
| 4.1 Introducción | 31 |
| 4.2 Aprendizaje supervisado y no supervisado | 32 |
| 4.3 Clases linealmente separables | 33 |
| 4.4 Procedimiento para el algoritmo de perceptrón difuso | 36 |
| 4.5 Separación lineal de clases difusas | 37 |
| 4.6 Algoritmo de Perceptrón difuso | 39 |
| 4.7 Modelo del Perceptrón difuso de Keller y Hunt | 41 |

5. RESULTADOS

| | |
|-----------------------------------------------------------------------------------------|----|
| 5.1 Introducción | 45 |
| 5.2 Herramientas utilizadas para estudiar el comportamiento de las variables eléctricas | 46 |
| 5.3 Oscilaciones y falla en un sistema de potencia | 47 |
| 5.4 Generación y clasificación de los datos | 49 |

6. CONCLUSIONES

| | |
|------------------------------------|----|
| 6.1 Conclusiones y recomendaciones | 58 |
|------------------------------------|----|

| | |
|--------------|----|
| Bibliografía | 60 |
|--------------|----|

| | |
|---------------------------|----|
| Lista de tablas y figuras | 62 |
|---------------------------|----|

| | |
|----------|----|
| Glosario | 64 |
|----------|----|

| | |
|-----------------------------------------------|----|
| Apéndice A. Pasos para la aplicación del APD. | 67 |
|-----------------------------------------------|----|

| | |
|----------------------------|----|
| Apéndice B. Código Fuente. | 68 |
|----------------------------|----|

| | |
|------------------------|----|
| Resumen autobiográfico | 71 |
|------------------------|----|

PROLOGO

El reconocimiento es una de las habilidades más destacables del ser humano. En la actualidad se ha tratado de que las computadoras representen tal habilidad, pero hasta hoy, aún con la tecnología existente ha sido muy complicado.

La Inteligencia Artificial es una de las áreas más avanzadas de la tecnología de la información, que nació en 1956 con el objeto de estudiar actividades humanas para las que hace tiempo, no se podía representar mediante métodos desarrollados de forma convencional.

La evolución de la inteligencia artificial ha sido tal que en la actualidad se han desarrollado múltiples aplicaciones en diversos campos de la investigación. En el presente estudio se utiliza una técnica de ésta área para simular un proceso de reconocimiento de patrones (señales eléctricas) para discriminar entre fallas y oscilaciones de potencia de un sistema de potencia eléctrico.

Para iniciar en el capítulo uno se muestra el objetivo, la descripción del problema, la justificación del trabajo, límites del estudio, metodología y revisión bibliográfica.

Se presentará, en el capítulo dos, una introducción al área de reconocimiento desde el punto de vista de la inteligencia artificial.

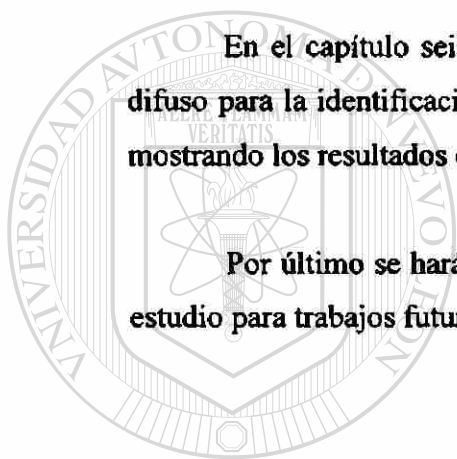
Se mostrará en el capítulo tres, como el proceso de reconocimiento ha ido evolucionando dentro del área de inteligencia artificial, mostrando conceptos básicos de este tema.

Se aplicarán conceptos básicos de lógica difusa considerados al hablar de teoría de conjuntos convencionales y conjuntos difusos en el capítulo cuatro.

Se demostrará en el capítulo cinco que al mezclar las herramientas de los capítulos anteriores es posible la implementación del algoritmo de perceptrón difuso.

En el capítulo seis se hará énfasis en la aplicación del algoritmo de perceptrón difuso para la identificación de fallas y oscilaciones en un sistema eléctrico de potencia mostrando los resultados obtenidos.

Por último se harán las conclusiones y recomendaciones pertinentes del presente estudio para trabajos futuros.



UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

DIRECCIÓN GENERAL DE BIBLIOTECAS



RESUMEN

Publicación No.

Valeria Paola González Duéñez, M.C.: En Ingeniería de Sistemas
Universidad Autónoma de Nuevo León, 2004


El reconocimiento es una de las habilidades más destacables del ser humano. Desde el nacimiento de la Inteligencia Artificial se ha propuesto que las computadoras representen la habilidad de clasificación y reconocimiento; en esa época la tecnología necesaria para desarrollar tal habilidad era muy básica, actualmente contamos con adelantos tecnológicos que permiten una visión positiva para lograr futuros estudios.

En la actualidad existe un gran problema de clasificación en el área de Ingeniería Eléctrica ya que al hablar de situaciones problemáticas, se presentan dos casos muy semejantes: a) fallas en el sistema, b) oscilaciones en el sistema. Para cada caso (muy particular uno de otro) es necesario realizar una toma de decisiones, pero hasta ahora resulta difícil por el hecho de que se presentan características semejantes en las dos situaciones.

En el presente trabajo se muestran distintas técnicas mediante las cuales es posible realizar el proceso de reconocimiento, haciendo énfasis en el empleo del algoritmo de perceptrón difuso cuando los datos a clasificar son linealmente separables. Para el problema de clasificación, los datos fueron tomados a partir de un estudio de estabilidad en un sistema eléctrico de potencia.

Los datos a clasificar contienen mediciones de variables eléctricas entre ellas, resistencia, reactancia, impedancia de la línea, voltaje, corriente y ángulo de defasamiento, para los cuales se tomó una muestra proporcional en cantidades para la situación de falla y oscilación. Cuando se tienen los datos en cantidades proporcionales, se utilizan otras herramientas para iniciar con el proceso de aprendizaje, el cual ocurre en un mínimo de tiempo requerido para tal proceso, generándose una función lineal de

separación en el hiperplano de representación de los datos, confirmándose la gran utilidad de ésta herramienta para la clasificación de datos linealmente separables.




UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN



DIRECCIÓN GENERAL DE BIBLIOTECAS

CAPÍTULO 1



INTRODUCCIÓN

1.1 Objetivo del estudio

Actualmente existe una gran problemática al momento de realizar estudios de estabilidad en los sistemas eléctricos de potencia, ya que el comportamiento es muy similar para situaciones muy diferentes. Las situaciones estudiadas en el presente estudio muestran que cuando existe una situación de falla y cuando ocurre una oscilación el comportamiento es similar en el sistema eléctrico de potencia, sin embargo las consecuencias no son las mismas, por lo tanto es necesario precisar la situación existente.

1.2 Justificación del trabajo

El objetivo del presente estudio consiste en aplicar técnicas de inteligencia artificial cuando se tienen que tomar decisiones según la situación presente en el

momento. Para llevar a cabo una buena clasificación o identificación de la situación en los sistemas eléctricos de potencia es necesario estudiar el comportamiento de las variables eléctricas, ya que éstas son muy semejantes para cada situación en particular. Es necesario hacer una eficiente distinción entre el comportamiento de las variables para que no pueda ocasionar problemas en el sistema y por consiguiente más gasto en la industria que trabaja para el área de ingeniería eléctrica.

1.3 Descripción del problema

Para iniciar el presente trabajo de tesis fue necesario utilizar una muestra tomada de un estudio de estabilidad realizado con anterioridad para evaluar un sistema eléctrico de potencia, estos datos formaban parte de un trabajo de tesis anterior. Posteriormente, en el presente estudio, se implementan técnicas de inteligencia artificial para lograr una adecuada clasificación de los datos. Los grupos de datos son tomados al medir el comportamiento de las variables para situaciones de falla y oscilación en un sistema eléctrico de potencia. La implementación del algoritmo muestra como se realiza una efectiva clasificación de una condición de falla y una oscilación del sistema.

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

1.4 Hipótesis

DIRECCIÓN GENERAL DE BIBLIOTECAS

Para realizar un proceso de clasificación de los datos es necesario representar el comportamiento de éstos, ya que de esta información se decide implementar un tipo de técnica en particular.

1.5 Límites del Estudio

El presente estudio muestra la aplicación de técnicas de inteligencia artificial para realizar un proceso denominado clasificación o reconocimiento. Para realizar este

proceso es necesario tomar características propias de algún patrón (es todo elemento, grupo o clase que posee características en común las cuales son necesarias para realizar un proceso de reconocimiento); dicho proceso se aplica a datos o características que son linealmente separables, de tal manera que es interesante continuar con el diseño de técnicas o procedimientos que se apliquen cuando se tengan datos considerados como linealmente no separables.

1.6 Metodología

1. Búsqueda bibliográfica

2. Selección del material bibliográfico a utilizar

3. Definición del problema para realizar el estudio

a) Establecer comunicación con asesor de un proyecto realizado con anterioridad.

b) Solicitar muestras de datos obtenidos al realizar un estudio de estabilidad.

4. Elección del problema

5. Definir técnicas o alternativas de solución

6. Diseñar el proyecto


7. Realizar pruebas con muestras de datos

8. Definir conclusiones

1.7 Revisión bibliográfica

Josué R. Coutiño Ozuna. "Aplicación de redes neuronales en la discriminación entre fallas y oscilaciones de potencia".

CAPÍTULO 2



CLASIFICACIÓN Y RECONOCIMIENTO

UANL

2.1 INTRODUCCION

Actualmente el área de Inteligencia Artificial estudia el comportamiento inteligente del ser humano representando y simulando la habilidad humana mediante la creación de modelos y algoritmos computacionales a fin de aplicarlo en la solución de problemas en la industria [10][14]. La industria actualmente se ha apoyado para el área de toma de decisiones, principalmente con la creación de sistemas expertos, robótica, redes neuronales artificiales, lógica difusa, reconocimiento de patrones, etc..

El presente trabajo está enfocado al área de Reconocimiento de Patrones. Es importante mencionar que el reconocimiento de un objeto como miembro de una clase o grupo se denomina identificación. A su vez, la clasificación es el proceso de agrupamiento de objetos en clases de acuerdo a su similitud. El área de reconocimiento de patrones incluye ambas: clasificación e identificación [3].

2.2 CONCEPTOS DE CLASIFICACIÓN Y RECONOCIMIENTO

El aprendizaje se utiliza en aquellos sistemas en los cuales el registro de sus experiencias, dentro de un sistema interno, cambia de acuerdo a su comportamiento. La clasificación es una forma de aprendizaje, en el cual se induce de los antecedentes de las clases, las cuales se constituyen de los subsecuentes. El razonamiento es un proceso en el que se aplican reglas generales, ecuaciones, relaciones y también una colección inicial de datos, hechos para deducir resultados o tomar decisiones. La lógica difusa utiliza el concepto de incertidumbre y mapeo de rasgos distintivos para la formación de agrupamientos denominándolos grupos difusos o agrupamientos difusos [11][12][15][16]. En el proceso de reconocimiento de patrones, al objeto se le asigna un grado característico o grado de membresía, identificando cada agrupamiento, de forma única, la similitud entre los atributos del objeto y los atributos de los agrupamientos o clases [15].

Quando hablamos de problemas de discriminación de fallas y oscilaciones de potencia en los procesos industriales, podemos mencionar que existen estados de operación considerados como anormales, y éstos, a su vez, conducen a situaciones no óptimas que ocasionan problemas. El problema en este caso, no es la presencia de situaciones no óptimas, sino, de que haya ausencia de equipos que ayuden a evaluar tal situación de una forma efectiva. Es por eso en el presente estudio se diseñará un instrumento de evaluación, donde las señales obtenidas por este sistema serán un elemento importante para poder aplicar las técnicas de reconocimiento, clasificación o identificación de los estados normales y anormales de operación.

El analizar las señales obtenidas por parte del sistema, llevará a realizar un proceso fundamental en el reconocimiento que es el obtener rasgos distintivos característicos, ya que éstos determinarán si son características o datos de normalidad o anormalidad; después se procesarán cada uno de ellos, para finalmente clasificar la operación(normalidad o anormalidad).

Los problemas de diagnóstico, detección de fallas y reconocimiento de patrones serán estudiados en el presente trabajo y éstos son considerados como problemas de clasificación. Las redes neuronales, los sistemas expertos, los mecanismos de soporte vectorial (mecanismos de aprendizaje que realizan tareas de clasificación), son técnicas de inteligencia artificial que son útiles para el proceso de clasificación. Así que el presente estudio está enfocado a realizar clasificación de fallas y oscilaciones en los sistemas eléctricos de potencia mediante técnicas de IA como las antes mencionadas.


Es importante mencionar que el presente estudio es continuación de una serie de trabajos elaborados anteriormente donde distintas técnicas de inteligencia artificial han contribuido para obtener los datos necesarios para el actual proyecto [17].

2.3 SEPARACIÓN DE CLASES O AGRUPAMIENTOS


El concepto de patrón puede establecerse como un grupo de datos que contienen rasgos distintivos asociados a una clase, éstos los hacen únicos e irrepetibles. Un objeto contiene atributos que son medidos para producir un patrón (vector), para asignar un grado de membresía respecto a las clases en consideración o para definir un espacio característico que se utilizará para efectuar el proceso de reconocimiento. En general, los atributos de los objetos producen un grupo de características, a las cuales se les aplican técnicas de similaridad para su reconocimiento [15].

Un diseño reconocedor de objetos o patrones es un sistema en el cual el vector que contiene las características dadas del patrón actúa como entrada al sistema, que opera sobre dicha entrada para producir una salida, que es una identificación única asociada con la clase del objeto a la cual pertenece. El reconocimiento está basado en la medida de los atributos físicos o mapeo de los mismos.

Las N características de una población de objetos pueden ser tomadas como dimensiones dentro de un espacio vectorial, según se ilustra en la figura 2.1, para el caso de $N = 2$.



a)



b)

Fig. 2.1 a) Separación lineal de clases y
b) Separación no lineal de clases

Existen diferentes técnicas que pueden utilizarse en el sistema de reconocimiento de patrones siempre y cuando se tenga definido un espacio de rasgos distintivos o características asociadas a una población de objetos. El modo operacional del reconocimiento es un sistema de mapeo, donde cada vector de entrada a través de un proceso, particiona o asocia los rasgos distintivos en un vector, para cada grupo de objetos. La acción que determina la región de aceptación se conoce como proceso de reconocimiento. Esta clasificación que se involucra en el proceso de entrenamiento es

conocido como mecanismo de aprendizaje. Las categorías de un mecanismo de aprendizaje se conocen como: entrenamiento supervisado y entrenamiento no supervisado. En el entrenamiento supervisado cada vector de entrada del sistema se identifica con un vector asociado de salida, el sistema aprende con cada vector presentado al sistema asociándolo a la salida correspondiente. En el entrenamiento no supervisado el sistema incluye ambos procesos entrenamiento y clasificación para cualquier entrada, asociando un prototipo para cada clase de objetos [3].

2.4 CONCEPTO DE AGRUPAMIENTOS CON APRENDIZAJE SIN SUPERVISIÓN

En el aprendizaje sin supervisión, el proceso de agrupamiento de un vector de rasgos distintivos dentro de clases es llamado “clustering”. Cuando un vector de rasgos distintivos es una entrada en el sistema, se determinan las distancias a los centros de todos los agrupamientos generando una identificación del grupo al que pertenece, basado en la distancia mínima [8].

2.5 MÉTODOS ÚTILES EN EL RECONOCIMIENTO DE PATRONES

Existen diferentes metodologías para el reconocimiento y la clasificación de patrones, las cuales, pueden categorizarse, conforme al siguiente listado [3]:

1. Decisión-Teórico
 - (a) Estadístico
 - i. Paramétrico
 - ii. No Paramétrico
 - iii. Estimación Bayesiana
 - (b) Gráfico-Teórico

(c) Basado en Reglas

- i. Reglas Lógicas Booleanas
- ii. Reglas Lógicas Difusas

2. Estructural Sintáctico**(a) Automata**

- i. Determinístico y Sintáctico
- ii. Estocástico

(b) Redes Neuronales tipo Hopfield**(c) Mapeo Asociativo Bidireccional****3. Mapeo Neuronal y Difuso****(a) Redes Neuronales de Alimentación hacia delante**

- i. Capas Múltiples de Perceptrones
- ii. Redes de base Radial

(b) Redes Neuronales de Auto-organización

- i. Mapeo con Auto-organización de Rasgos Distintivos
- ii. Algoritmos de Agrupamientos Difusos
- iii. Mapeo Difuso con Auto-organización
- iv. Teoría de Resonancia Adaptativa

4. Redes Híbridas**(a) Redes con Aprendizaje de Vectores Cuantitativos****(b) Redes Neuronales Probabilísticas****(c) Mapeos Asociativos Difusos****(d) Redes con Aprendizaje de Vectores Cuantitativos Difusos**

La primera categoría en el área, históricamente llamada Reconocimiento Estadístico de Patrones, está enfocada a clasificar objetos dentro de subpoblaciones. Es usado para medir atributos y así clasificar los patrones por decisiones estadísticas. El Reconocimiento Estadístico de Patrones es una sub-área de las decisiones-teóricas.

Las ventajas de los procedimientos estadísticos y decisiones teóricas es la eficiencia computacional y el alto nivel de autoorganización. La principal desventaja es

que su aplicación es válida solamente para datos que son linealmente separables, y el grupo o clase a la cual pertenecen depende del orden en el que se presentan las características.

Para la estimación Bayesiana se selecciona un valor perteneciente a algún parámetro desconocido basado en una medida que contiene errores generados en forma aleatoria, se toma una distribución empírica de la probabilidad de ocurrencia de los resultados, y de ésta forma se procede a la clasificación. El objetivo que se persigue es conocer con que probabilidad, dado un vector de datos de entrada, se determina la clase a la cual pertenece. La regla de clasificación Bayesiana es como sigue: los valores pueden ser estimados por muestras al azar, determinando la clase en función de la frecuencia de los registros y de la ocurrencia de los datos.

Una de las principales ventajas del método de Estimación Bayesiana es que se determina la probabilidad del error que se puede encontrar en cada decisión. Una desventaja es la necesidad de información o suposiciones que no pueden ser disponibles como las distribuciones de las clases, así como las probabilidades condicionales que deben ser reconocidas, estimadas o asumidas [3].

Recientemente se ha estudiado una forma de tomar decisiones basado en el concepto de "strings", que son cadenas de símbolos seleccionados de un alfabeto en particular. Tales "strings" son estatutos que se utilizan en la gramática del alfabeto, para estructurar frases o lenguajes adecuadamente, y donde, su construcción, se realiza por un grupo de reglas. Las frases se toman de estructuras internas de los patrones. Si un objeto tiene una estructura de atributos, pueden ser transformados a sentencias de una gramática, entonces éste reconocimiento pertenecería a la clase de la gramática, en otro caso, pertenece a una segunda clase. Tal clasificación está denominada como Reconocimiento Sintáctico de Patrones [7][13].

Para formular el problema del reconocimiento sintáctico de patrones, se debe suponer que los objetos de una población tienen características que pueden asignarse,

una a una, a letras o terminales de algún alfabeto en particular. Cuando un objeto es procesado y convertido dentro de una sentencia representativa de las terminales, éstas estructuras, formadas en función de las características, son comprobadas. Una forma de medir las sentencias es usando una máquina de estados finitos, es decir una automatización finita.

La máquina de estados finitos inicia con el estado q_0 , y cada vez que se actualice, la letra cambia de estado. Después se lee una secuencia o cadena, la máquina la compara con el estado final, para ser aceptada o rechazada. La máquina puede aceptar la sentencia o cadena siempre y cuando al analizar la secuencia de estados generados por ésta el último deberá ser el estado final que marca la máquina como el de aceptación y ahí deberá terminar la secuencia, en caso contrario la cadena será rechazada. Si la máquina acepta la sentencia, entonces identifica lo perteneciente a la clase que la propia máquina reconoce.

Una automatización finita es una máquina con memoria que almacena un estado que recibe letras de entrada, cambia éste estado en función del estado actual, así como las letras de entrada y de salida (transiciones). La función abstracta de la máquina consiste en una tabla $(\Sigma Q \delta \sigma q_0 Q_f)$ donde Σ son las letras del alfabeto para entrada/salida, Q es el grupo de estados, q_0 es el estado inicial, donde $Q_f \subset Q$ es el grupo de estado final Q_f , δ es la función de transición $\delta : \Sigma \times Q \rightarrow Q$, en el que la tabla contiene la letra de entrada y el estado actual generando así un nuevo estado, σ es la función de salida, la cual es dependiente del estado actual y de la letra de entrada. Cuando la salida es omitida se denomina Reconocedor Automático de Estados Finitos. Si la entrada es omitida, la máquina es llamada Generador de Estados Finitos [3].

El Reconocimiento Automatizado de Patrones es un sistema operacional donde, en base al mínimo número de datos o entradas que se presentan al sub-sistema, éste acepta una parte de ellos, asignándolos a un vector de rasgos distintivos para tomar la decisión de la clase a la cual pertenece cada dato. El Reconocimiento Automatizado de

Patrones es un sistema que se utiliza para ejecutar instrucciones en programas computacionales, y así implementar algoritmos matemáticos. Algunas de las aplicaciones incluyen: Reconocimiento Óptico de Caracteres, Reconocimiento de Imágenes Impresas, Reconocimiento de Palabras utilizando Señales de la voz, Reconocimiento de Bioquímicos con características extraídas de la sangre, cabello, etc.; Reconocimiento de Partes Defectuosas en una línea de producción, Reconocimiento de Señales Fisiológicas tales como electrocardiogramas, etc..

La inferencia gramatical es el proceso que sirve para determinar la gramática adecuada de un grupo o clase. El aprendizaje de las clases de una muestra de patrones es la parte más difícil del Reconocimiento Sintáctico de Patrones.

Otra de las modalidades utilizadas en el Reconocimiento de Patrones es el empleo de una herramienta denominada Redes Neuronales Artificiales.




Fig. 2.2 Modelo de una neurona biológica.

Las redes neuronales pueden ampliar su capacidad potencial usando múltiples entradas en una arquitectura conexionista, la cual es llamada así, porque trabaja de igual manera en que el cerebro realiza el intercambio de información de una célula a otra (múltiples conexiones), según el modelo biológico que se muestra en la fig. 2.2. El soma, que es el núcleo de la célula, las dendritas que son ramificaciones encargadas de conectar esa célula hacia neuronas vecinas para formar la red; la sinápsis, es también llamada memoria y el axón, es el conducto por el cual fluye la información de salida

hacia otra neurona. Las conexiones entre cada unidad de procesamiento que forman una Red Neuronal Artificial (RNA), tienen asociado un peso o sinápsis, lo cual hace que la red adquiera conocimiento. Una neurona artificial recibe un conjunto de señales que le dan información acerca del estado de activación de todas las entradas con las que se encuentra conectado, de tal manera que la entrada total que recibe una red neuronal es la suma del producto de cada señal individual por el valor de la sinápsis con la cual están asociadas [1][3][5][6].

La distribución de las neuronas dentro de la red se realiza formando niveles o capas de un número determinado de neuronas cada una. Se pueden distinguir tres tipos de capas: de entrada, salida y ocultas, tal como lo muestra la fig. 2.3. La capa de entrada recibe directamente la información proveniente de las fuentes externas de la red. La capa de salida transfiere la información de la red neuronal hacia al exterior, y las capas ocultas son internas a la red neuronal y no tienen contacto directo con el entorno exterior, éstas pueden estar interconectadas de distinta manera para formar su arquitectura.




Fig. 2.3 Modelo de redes neuronales artificiales con capa de entrada, oculta y de salida.

Una red neuronal tipo Hopfield es recurrente ya que contiene una sola capa de neuronas, donde la alimentación es hacia atrás y por lo tanto asemeja a un número ilimitado de capas. En este modelo cada neurona recibe las entradas con alimentación hacia atrás simultáneamente en modo síncrono. Las interacciones entre las neuronas se

realizan en un tiempo, en el cual la alimentación se da hacia atrás para formar nodos y, cada una de ellas registra la siguiente salida por medio de un grupo de pesos sinápticos (memoria), un grupo de valores umbrales y la función umbral (signo). Las redes neuronales artificiales recurrentes operan de una forma muy diferente de las redes con alimentación hacia delante, ya que realizan el proceso de entrenamiento utilizando un vector de rasgos distintivos relacionado con cada una de las entradas para identificarlo por medio de una salida esperada que esté asociada con cada entrada. Las redes recurrentes normalmente no son entrenadas ya que solamente se utilizan para probar si el estado inicial asignado a los vectores de entrada separa correctamente los datos. El proceso es tomar los pesos sinápticos del vector de entrada correlacionados con las entradas iniciales para obtener una matriz de pesos simétrica, probándolos para determinar el estado en el cual cada entrada converge. La recurrencia convergente se presenta cuando todas las neuronas cambian el estado de la red.

Otra red neuronal muy particular es el perceptrón multicapas llamado también red neuronal con alimentación hacia delante. La modalidad con alimentación hacia delante, nos da una arquitectura con capas de entrada, ocultas y salida, donde cada una contiene un determinado número de neuronas. Las redes neuronales pueden tener muchas capas ocultas con un alto poder de aprendizaje para la separación de clases no lineales. Un perceptrón multicapas puede utilizarse en el proceso de reconocimiento cuando existan uno o más datos de entrada asociados a un valor esperado de salida, donde al comparar éstos datos se puede determinar si se ha logrado realizar una identificación [5].

Un caso especial de redes neuronales de autoorganización es la tipo Kohonen, éste modelo contiene una capa de neuronas de entrada que contiene neuronas interconectadas. La capa de neuronas tiene asociado un peso sináptico, el cual se inicializa con valores al azar y las dimensiones de éste dependen de las dimensiones de los datos de entrada [3].

CAPÍTULO 3

TEORÍA DE CONJUNTOS DIFUSOS

3.1 INTRODUCCIÓN

Un conjunto se define como una colección de objetos con características en común [7]. Un agrupamiento o conjunto difuso es aquel que tiene las mismas características entre sí, y es tomado a partir de un conjunto universo. A la colección de elementos tomados a partir de un conjunto universo, se le denomina agrupamiento completo o total.

Para un conjunto de agrupamientos, son válidas las siguientes representaciones:

| | |
|--------------|------------------------|
| $x \in A$ | x pertenece a A |
| $x \in X$ | x pertenece a X |
| $x \notin A$ | x no pertenece a A |

Para los agrupamientos se pueden expresar éstos términos así,

| | |
|-----------------|-------------------------------------------|
| $A \subset B$ | A está contenido en B |
| $A \subseteq B$ | A está contenido o es equivalente a B |
| $A = B$ | $A \subseteq B$ y $B \subseteq A$ |

El agrupamiento nulo se representa por \emptyset , y es aquel que no contiene elementos y es posible mencionarlo de forma análoga a un evento que no es posible que ocurra.

Todos los posibles agrupamientos constituidos o formados de una manera especial, a partir de un conjunto se les denomina potencias del grupo. La cardinalidad de este conjunto está dado por

$$n_{P(X)} = 2^{n_x} \quad (3.1)$$

donde n_x es el número de elementos tomados a partir de algún conjunto universo.

3.2 OPERACIONES BÁSICAS CON AGRUPAMIENTOS

Algunas de las operaciones básicas de los agrupamientos son: la unión, intersección, complemento y diferencia.

La unión entre dos agrupamientos se representa por $A \cup B$, ésta representa al total de elementos pertenecientes al grupo A o al grupo B .

$$A \cup B = \{x \mid x \in A \text{ o } x \in B\} \quad (3.2)$$

La intersección entre dos agrupamientos se representa por $A \cap B$, ésta representa al total de elementos que pertenecen al grupo A y al grupo B .

$$A \cap B = \{x \mid x \in A \text{ y } x \in B\} \quad (3.3)$$

El complemento de un agrupamiento es aquel que está definido por la colección de elementos del conjunto universo U , que no se encuentran en el conjunto A , el complemento se representa por A^c .

$$A^c = \{x \mid x \notin A, x \in X\} \quad (3.4)$$

La diferencia de un agrupamiento A con respecto a otro B , se representa por $A \setminus B$, y está definida por la colección de todos los elementos del conjunto universo U , que pertenecen al grupo A y no pertenecen al grupo B .

$$A \setminus B = \{x \mid x \in A \text{ y } x \notin B\} \quad (3.5)$$

3.3 PROPIEDADES DE LOS AGRUPAMIENTOS

Algunas de las propiedades de los conjuntos son válidas para los agrupamientos difusos, las más comunes son [7]:

| | | |
|--------------------|-----------------------|-------|
| Conmutativa | $A \cup B = B \cup A$ | |
| | $A \cap B = B \cap A$ | (3.6) |

| | | |
|-------------------|-----------------------------------------|-------|
| Asociativa | $A \cup (B \cap C) = (A \cup B) \cap C$ | |
| | $A \cap (B \cup C) = (A \cap B) \cup C$ | (3.7) |

| | | |
|---------------------|--------------------------------------------------|-------|
| Distributiva | $A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$ | |
| | $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$ | (3.8) |

| | | |
|------------------|------------------------|-------|
| Identidad | $A \cup \emptyset = A$ | (3.9) |
|------------------|------------------------|-------|

| | | |
|--|----------------|--------|
| | $A \cap U = A$ | (3.10) |
|--|----------------|--------|

| | | |
|------------------------|-----------------------------------------------------------|--------|
| Idempotencia | $A \cup A = A$ | (3.11) |
| | $A \cap A = A$ | (3.12) |
| Ley de D'Morgan | $A \cap B = \overline{A \cup B}$ | |
| | $A \cup B = \overline{A \cap B}$ | (3.13) |
| Transitividad | Si $A \subseteq B \subseteq C$, entonces $A \subseteq C$ | (3.14) |

3.4 REPRESENTACIÓN DE FUNCIONES PARA LOS AGRUPAMIENTOS CLÁSICOS

Para relacionar agrupamientos de teóricos hacia una función teórica, es necesario mapear o trazar la información, es decir, usar un mapa para trazar elementos o subconjuntos en un universo en discurso a elementos o grupos en otro universo distinto.

Si un elemento x está contenido en un conjunto X y es correspondiente a un elemento y del conjunto Y , generalmente termina trazando de X a Y , o $f: X \rightarrow Y$.

En un trazado la función característica (el indicador) χ_A está definida por

$$\chi_A(x) = \begin{cases} 1 & x \in A \\ 0 & x \notin A \end{cases} \quad (3.15)$$

donde ésta representa la membresía para un elemento del grupo A , perteneciente al universo.

Definiendo dos agrupamientos A y B dentro de algún universo, la unión de estos grupos está dada en términos de una función teórica expresada por el símbolo \vee , el cual es el operador máximo y \wedge es el operador mínimo. Así se tienen las siguientes propiedades:

Unión

$$A \cup B \rightarrow x_{A \cup B(x)} = x_{A(x)} \vee x_{B(x)} = \max \{x_{A(x)}, x_{B(x)}\} \quad (3.16)$$

Intersección

$$A \cap B \rightarrow x_{A \cap B(x)} = x_{A(x)} \wedge x_{B(x)} = \min \{x_{A(x)}, x_{B(x)}\} \quad (3.17)$$

Complemento

$$A \rightarrow x_{A(x)} = 1 - x_{A(x)} \quad (3.18)$$

3.5 AGRUPAMIENTOS DIFUSOS

Un agrupamiento difuso es aquel que puede contener diferentes grados de membresía. Esta idea está en contraste con respecto a los agrupamientos clásicos, porque los miembros de un grupo no serían miembros a menos de que su membresía fuera completa (en este caso tendría asignado un valor de 1). Los elementos de un agrupamiento difuso deben ser trazados en el universo por los valores de membresía, usando una especie de función teórica. Esta función traza los elementos de un grupo difuso a valores reales en el intervalo de 0 a 1.

Para agrupamientos difusos, cuando el universo en discurso es discreto y finito, se representa por:

$$\mathbf{A} = \left\{ \frac{\mu_A(x_1)}{x_1} + \frac{\mu_A(x_2)}{x_2} + \Lambda \right\} = \left\{ \sum_i \frac{\mu_A(x_i)}{x_i} \right\} \quad (3.19)$$

Cuando el universo es continuo e infinito el agrupamiento difuso se representa por

$$\mathbf{A} = \left\{ \int \frac{\mu_{\mathbf{A}}(x_i)}{x_i} \right\} \quad (3.20)$$

Para ambas expresiones, la barra horizontal no es el cociente sino más bien el delimitador. El numerador en cada expresión es el valor de membresía asociado con el elemento del universo representado por el denominador. En la primera expresión, el símbolo de la sumatoria no es una suma algebraica, más bien representa el agregar cada elemento: de la primera expresión el signo “+” no es una suma algebraica pero representa la función teórica de unión. En la segunda expresión el signo de la integral no es algebraica sino una función teórica continua o unión de variables continuas [2][4].

3.6 OPERACIONES CON AGRUPAMIENTOS DIFUSOS

Considerando a \mathbf{A} y \mathbf{B} como agrupamientos difusos en un universo, para cada elemento x del universo, la unión, intersección y complemento son:

Unión

$$\mu_{\mathbf{A} \cup \mathbf{B}}(x) = \mu_{\mathbf{A}}(x) \vee \mu_{\mathbf{B}}(x) \quad (3.21)$$

Intersección

$$\mu_{\mathbf{A} \cap \mathbf{B}}(x) = \mu_{\mathbf{A}}(x) \wedge \mu_{\mathbf{B}}(x) \quad (3.22)$$

Complemento

$$\mu_{\mathbf{A}^c}(x) = 1 - \mu_{\mathbf{A}}(x) \quad (3.23)$$

3.7 PROPIEDADES DE LOS AGRUPAMIENTOS DIFUSOS

Algunas de las propiedades de los agrupamientos difusos son [2][4][15]:

| | | |
|--------------------|-----------------------|--------|
| Conmutativa | $A \cup B = B \cup A$ | |
| | $A \cap B = B \cap A$ | (3.24) |

| | | |
|-------------------|-----------------------------------------|--------|
| Asociativa | $A \cup (B \cap C) = (A \cup B) \cap C$ | |
| | $A \cap (B \cup C) = (A \cap B) \cup C$ | (3.25) |

| | | |
|---------------------|--------------------------------------------------|--------|
| Distributiva | $A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$ | |
| | $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$ | (3.26) |

| | | |
|---------------------|----------------|--------|
| Idempotencia | $A \cup A = A$ | (3.27) |
|---------------------|----------------|--------|

| | | |
|--|----------------|--------|
| | $A \cap A = A$ | (3.28) |
|--|----------------|--------|

| | | |
|------------------|------------------------|--------|
| Identidad | $A \cup \emptyset = A$ | (3.29) |
|------------------|------------------------|--------|

| | | |
|--|----------------|--------|
| | $A \cap U = A$ | (3.30) |
|--|----------------|--------|

| | | |
|------------------------|-----------------------|--|
| Ley de D'Morgan | $A \cap B = A \cup B$ | |
|------------------------|-----------------------|--|

| | | |
|--|-----------------------|--------|
| | $A \cup B = A \cap B$ | (3.31) |
|--|-----------------------|--------|

| | | |
|----------------------|-----------------------------------------------------------|--------|
| Transitividad | Si $A \subseteq B \subseteq C$, entonces $A \subseteq C$ | (3.32) |
|----------------------|-----------------------------------------------------------|--------|

| | | |
|-------------------|---------------|--------|
| Involución | $(A^c)^c = A$ | (3.33) |
|-------------------|---------------|--------|

DIRECCIÓN GENERAL DE BIBLIOTECAS

3.8 FUNCIONES DE MEMBRESÍA

La difusividad es el proceso utilizado para construir cantidades difusas. Las funciones de membresía representan la difusividad de un agrupamiento difuso, cuando los elementos en el grupo son discretos y continuos.

La función de membresía se caracteriza en dependencia del conocimiento que se disponga sobre los rasgos distintivos de los elementos del conjunto difuso: (1) El

conocimiento del dominio de rasgos distintivos (entradas) y (2) El conocimiento de la pertenencia de patrones a agrupamientos difusos.

(1). Conocimiento del dominio de rasgos distintivos. Para que la información contenida en los rasgos distintivos de los elementos de un agrupamiento difuso sea representada por una función de membresía es útil desarrollar léxicos para describir características especiales de cada función.

El núcleo de una función de membresía, para algunos agrupamientos difusos está definida como la región del universo, caracterizada de forma completa en el agrupamiento A , ver figura 3.1. Este núcleo compara los elementos x del universo tal

que, $\mu_{A(x)} = 1$.

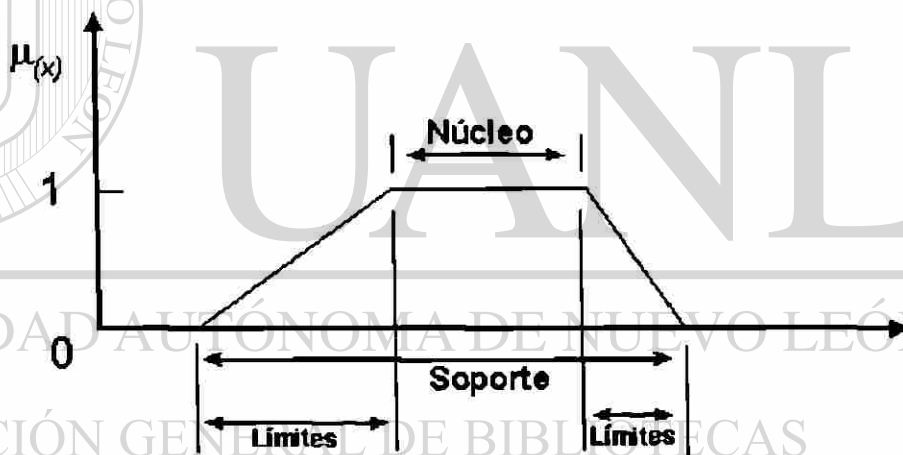


Fig. 3.1 Núcleo, soporte y límites de un agrupamiento difuso.

El apoyo o soporte de una función de membresía para algunos agrupamientos difusos, está definido por la región del universo que es caracterizado por una membresía diferente a cero. El soporte de la función compara los elementos x del universo tal que,

$$\mu_{A(x)} > 0.$$

Los límites de la función de membresía para algunos agrupamientos difusos, está definida como la región del universo que contiene los elementos que poseen membresía diferente a cero pero no alcanzan membresía completa. Los límites de la función de membresía comparan los elementos x del universo, tales que $0 < \mu_{A(x)} < 1$ [2][4].

Un agrupamiento difuso convexo está representado por una función de membresía cuyo valor se incrementa o decrementa de forma monótona.

El peso de un agrupamiento difuso es el valor máximo de la función de membresía. Si el peso del agrupamiento difuso es menor que la unidad, se dice que es subnormal.

Las funciones de membresía pueden ser simétricas y asimétricas. Son comúnmente definidas en una dimensión del universo, pero pueden ser descritas por multidimensiones del universo.

(2). Conocimiento de la pertenencia de patrones a agrupamientos difusos. En estos casos la función de membresía está basada en la medida de similitud entre los individuos de cada agrupamiento difuso (clases) y la separación existente entre las clases. Consideraremos en este caso la función de membresía sugerida por Keller y Hunt [8].

Sea m_i la media de la clase A_i . Denotemos por d_{ki} la distancia entre el patrón x_k y la media m_i de la clase A_i . La función de membresía se define como:

i). Si x_k pertenece a la clase A_1 entonces

$$\mu_{A_1}(x) = 0.5 + \frac{\exp\left[\frac{f(d_{k2} - d_{k1})}{d(m_1 - m_2)}\right] - \exp(-f)}{2[\exp(f) - \exp(-f)]} \quad (3.34)$$

$$\mu_{A_2}(x) = 1 - \mu_{A_1}(x)$$

ii). Si x_k pertenece a la clase A_2 entonces

$$\mu_{A_2}(x) = 0.5 + \frac{\exp\left[\frac{f(d_{k1} - d_{k2})}{d(m_1 - m_2)}\right] - \exp(-f)}{2[\exp(f) - \exp(-f)]} \quad (3.35)$$

$$\mu_{A_1}(x) = 1 - \mu_{A_2}(x)$$

Se observa que, en esta forma de función de membresía, se cumplen las siguientes propiedades:

- (a). $\mu_{A_i}(x_k) = 1$ si $x_k = m_i$,
 (b). $\mu_{A_i}(x_k) = 0.5$ si $x_k = m_j, j \neq i$,
 (c). Si x_k pertenece a la clase A_i entonces $\mu_{A_i}(x_k) \geq 0.5$

Aunque existen otras formas de funciones de membresía [2], la descrita en esta sección es la que se utiliza en este proyecto para el diseño del algoritmo de perceptrón difuso.

Para problemas en los cuales se desconoce el número de agrupamientos difusos contenidos en el conjunto de patrones disponibles, es necesario disponer de un método que logre establecer los centros del número de agrupamientos difusos que se establezcan para el estudio así como el grado de pertenencia a cada uno de los agrupamientos encontrados del conjunto de patrones disponibles.

Para formular el problema anterior, consideremos el conjunto disponible, finito de patrones

$$X = \{x_1, x_2, x_3, \dots, x_n\}, \quad x_i \in \mathbb{R}^n, \quad i = 1, 2, 3, \dots, n \quad (3.36)$$

Se debe realizar una partición de este conjunto en un número c (información proporcionada por el analista) de agrupamientos o clases. Deberá desarrollarse una función objetivo cuyo valor mínimo servirá como una medida o índice de calidad de la partición deseada (c subconjuntos o agrupamientos). El resultado final del agrupamiento en c subconjuntos se puede expresar como una matriz M de partición

$$M = [\mu_{ij}], \quad i = 1, \dots, c, \quad j = 1, \dots, n \quad (3.37)$$

donde μ_{ij} representa el grado de membresía del dato x_j en el i -ésimo agrupamiento de c_i , con las siguientes propiedades:

$$(1) \quad \sum_{i=1}^c \mu_{ij} = 1; \quad j = 1, \dots, n \quad (3.38)$$

$$(2) \quad 0 < \sum_{j=1}^n \mu_{ij} < n; \quad \forall i, i = 1, \dots, c \quad (3.39)$$

La función objetivo tiene una estructura general del tipo

$$J(\mu_{ij}, v_k) = \sum_{i=1}^c \sum_{j=1}^n \sum_{k=1}^c g[\omega(x_j), \mu_{ij}] d(x_j, v_k) \quad (3.40)$$

DIRECCIÓN GENERAL DE BIBLIOTECAS

donde $g(\bullet)$ es una función continua, $w(\bullet)$ es el peso a priori para cada dato, v_k es el centro del k -ésimo agrupamiento, y $d(x_i, v_k)$ es una medida de similaridad que satisface los siguientes axiomas

$$(1) \quad d(x_i, v_k) \geq 0 \quad (3.41)$$

$$(2) \quad d(x_i, v_k) = d(v_k, x_i) \quad (3.42)$$

En base a lo anterior, el agrupamiento difuso se puede representar como el siguiente problema

$$\text{Minimizar } J(\mu_{ij}, v_k) \quad (3.43)$$

$$\text{Sujeto a : } \sum_{i=1}^c \mu_{ij} = 1; \quad j = 1, \dots, n \quad (3.44)$$

$$0 < \sum_{j=1}^n \mu_{ij} < n; \quad i = 1, \dots, c \quad (3.45)$$

3.9 ALGORITMO DIFUSO DE C-MEDIAS (FCM-Fussy C Means)

Este algoritmo fue desarrollado por Bezdek (1981) y utiliza una función objetivo como se muestra a continuación:

$$J(\mu_{ij}, v_k) = \sum_{i=1}^c \sum_{j=1}^n \mu_{ij}^m \|x_j - v_k\|_2^2, \quad m > 1 \quad (3.46)$$

siendo el peso exponencial m con influencia sobre el grado de difusividad de la matriz de partición M . Al aplicar la condición necesaria de optimalidad al langrangiano formado por la función objetivo, y la penalización de las restricciones, se encuentra que

$$\sum_{i=1}^c \mu_{ij} = 1; \quad j = 1, \dots, n \quad (3.47)$$

$$0 \leq \mu_{ij} \leq 1; \quad \forall i, j \quad (3.48)$$

$$v_i = \frac{\sum_{j=1}^n \mu_{ij}^m x_j}{\sum_{j=1}^n \mu_{ij}^m}, \quad i = 1, \dots, c \quad (3.49)$$

$$\mu_{ij} = \frac{\left[\frac{1}{\|x_j - v_i\|_2^2} \right]^{\frac{1}{m-1}}}{\sum_{k=1}^c \left[\frac{1}{\|x_j - v_k\|_2^2} \right]^{\frac{1}{m-1}}}; \quad i=1, \dots, c; \quad j=1, \dots, n \quad (3.50)$$

El algoritmo FCM se presenta a continuación:

- a) Seleccionar el número de agrupamientos c ($2 \leq c \leq n$), el peso exponencial m ($1 < m < \infty$). Seleccione una matriz de partición inicial $M^{(0)}$ y un criterio de terminación ϵ . Inicializar el índice de iteraciones $t=0$.
- b) Calcular los centros v_i , $i=1, \dots, c$ utilizando $M^{(t)}$ y la ecuación 4.49.
- c) Calcular la matriz de partición $M^{(t+1)}$ con los valores de v_i calculados en el paso (b) y la ecuación 4.50.
- d) Calcular

$$\Delta = |M^{(t+1)} - M^{(t)}| = \max_j |\mu_{ij}^{(t+1)} - \mu_{ij}^{(t)}| \quad (3.51)$$

Si $\Delta > \epsilon$, hacer $t = t + 1$ y regresar al paso 2. Si $\Delta \leq \epsilon$, el algoritmo termina dando como resultado la matriz de partición $M^{(t)}$.

Para establecer la validez del número de agrupamientos, se utilizan índices sintéticos llamados indicadores de validez tales como: (1) Entropía de partición, (2) Coeficiente de partición, (3) Exponente de proporción. Estos indicadores de validez se determinan de la siguiente forma:

1. Entropía de partición

$$E(M, c) = \frac{1}{n} \sum_{j=1}^n \sum_{i=1}^c |\mu_{ij} \ln \mu_{ij}|; \quad (3.52)$$

2. Coeficientes de partición

$$P(M, c) = \frac{1}{n} \sum_{j=1}^n \sum_{i=1}^c \mu_{ij}^2; \quad (3.53)$$

3. Exponente de proporción

$$Q(M, c) = - \ln \left\{ \prod_{j=1}^n \left[\sum_{k=1}^{\mu_j-1} (-1)^{k+1} \binom{c}{k} (1 - k\mu_j)^{(c-1)} \right] \right\}; \quad (3.54)$$

donde $\mu_j = \max(1 \leq i \leq c \mu_{ij})$ y $[\mu_j - 1] = \text{mayor entero} \leq \left(\frac{1}{\mu_j} \right)$ y tienen las siguientes propiedades

1. $E = 0$, y $P = 1$ si $\mu_{ij} \in \{0,1\}$ (partición no difusa)

2. $0 \leq E \leq \ln c$ y $1/c \leq P \leq 1$

3. E y P dependen de los c_n elementos

4. $0 \leq P \leq \infty$ y depende del máximo grado de membresía de los n elementos

Para determinar el número apropiado de c grupos se considera que la estructura más apropiada del agrupamiento es aquella en la cual los elementos se concentran en su centro; esto es, cuando la matriz de partición es menos difusa. Con esta consideración se puede establecer reglas heurísticas para seleccionar el mejor número de grupos, tales como:

$$\min_{c=2, \dots, n-1} \{ \min_{M \in c} [E(M, c)] \}; \quad (3.55)$$

$$\max_{c=2, \dots, n-1} \{ \max_{M \in c} [P(M, c)] \}; \quad (3.56)$$

$$\max_{c=2, \dots, n-1} \{ \max_{M \in c} [Q(M, c)] \}; \quad (3.57)$$

Para mostrar una aplicación del algoritmo difuso de c-medias para el grupo de datos mostrado en la fig. 3.2, y decidir sobre el número de agrupamientos adecuado, se calculó la entropía de partición (3.52), el coeficiente de proporción (3.53) y el exponente de proporción (3.54), dando los resultados que se muestran en la tabla 3.1.





Fig. 3.2 Agrupamientos de prueba

De donde en base a los resultados obtenidos confirman que es óptimo formar 4 agrupamientos basándose en los resultados mostrados a continuación:

Tabla 3.1 Resultados obtenidos al aplicar el algoritmo difuso de C-Medias

| Agrupamientos a formar | Entropía de Partición | Coefficiente de partición | Exponente de proporción |
|------------------------|-----------------------|---------------------------|-------------------------|
| 2 | 0.00374514605063 | 0.00776171100014 | 0.33529832293906 |
| 3 | 0.00294384019122 | 0.00850321598183 | 1.36811501078222 |
| 4 | 0.00254052662028 | 0.00882261395927 | 2.20284953340360 |
| 5 | 0.00311177369647 | 0.00863268333297 | 2.74001500691919 |

La entropía de partición y el coeficiente de partición nos muestran que el número óptimo de agrupamientos es de 4, mientras que para el exponente de proporción el número de agrupamientos óptimos es de 5 como máximo.



UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

DIRECCIÓN GENERAL DE BIBLIOTECAS



CAPÍTULO 4



ALGORITMO DE PERCEPTRÓN DIFUSO

UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

4.1 INTRODUCCIÓN

®

DIRECCIÓN GENERAL DE BIBLIOTECAS

Una regla de aprendizaje o entrenamiento es el proceso mediante el cual se adquiere un conocimiento, o se realiza la modificación de la memoria de un sistema; posteriormente esta memoria se utiliza para la identificación de características o elementos pertenecientes a un grupo u otro, y este se denomina reconocimiento [5].

El proceso de aprendizaje se realiza de la siguiente manera: si se tiene un conjunto de características o rasgos que distinguen de manera única grupos o regiones pertenecientes a un sistema, es posible describir una función que identifique por medio de etiquetas o claves esas características de los datos. De esta forma al presentar un

nuevo dato esta función es capaz de identificarlo plenamente o asociarlo al grupo o región a la que pertenece, a través de sus rasgos distintivos.

El proceso de aprendizaje tiene dos fases: la primera fase es la más importante ya que es donde se almacena conocimiento, y el sistema debe ser capaz de identificar características pertenecientes a cada grupo o región; se denomina fase operacional. La segunda fase es de prueba, en ésta se presentan las características o rasgos de nuevos datos que al ser clasificados correctamente se comprueba si se efectuó un buen proceso de entrenamiento o aprendizaje; es decir, se comprueba que el conocimiento adquirido es apropiado.

Para iniciar la etapa de entrenamiento, las regiones o grupos deben estar definidos para el sistema, asociando un valor único para cada grupo; posteriormente se realiza el proceso de clasificación o entrenamiento en la fase operacional (clasificación), y finalmente se presentan al clasificador los datos de prueba, para así terminar el proceso de reconocimiento.

4.2 APRENDIZAJE SUPERVISADO Y APRENDIZAJE NO SUPERVISADO

Existen dos tipos de aprendizaje, el aprendizaje supervisado y aprendizaje no supervisado. En el aprendizaje supervisado los rasgos o características están asociados o identificados con respecto a un grupo o región. Por el contrario, en el entrenamiento no supervisado no se tienen asociaciones por parte de las características o rasgos y el propio sistema clasificador tiene que descubrir y aprender a entrenar el grupo para ser reconocido posteriormente.

Normalmente los sistemas clasificadores con aprendizaje supervisado siguen una regla de identificación de cada grupo o región. Los sistemas clasificadores no

supervisados generalmente construyen un prototipo de identificación para cada grupo o región de datos [3][8].

4.3 CLASES LINEALMENTE SEPARABLES

Teniendo en cuenta que dentro de un espacio existen características o rasgos distintivos, un sistema clasificador puede describirse por una función discriminante, la cual identifica de manera única cada grupo.

Para realizar la etapa de entrenamiento los datos pueden o no estar etiquetados, es decir, identificados según el grado de membresía asignado a cada grupo o clase. Este grado de membresía se asigna de manera única a cada grupo o región para ser fácilmente identificado posteriormente. Cuando un conjunto de datos tiene asociado un grado de membresía, y es por medio de este dato que se realiza más rápido el proceso de identificación o clasificación, aquí es cuando ocurre un entrenamiento supervisado. Por el contrario en el entrenamiento no supervisado no se tienen etiquetas o características definidas que identifican de manera única a cada grupo, de tal manera que el sistema clasificador generalmente construye un prototipo para cada grupo de datos, es decir, tiene que aprender a identificar el grupo por sí solo.

La presencia de grupos, regiones o clases etiquetadas distingue la clasificación supervisada de la no supervisada. Un aprendizaje o entrenamiento clasificador es un sistema que contiene un mecanismo que separa o particiona el espacio de los datos en regiones de decisión. En este caso, se concluye que el sistema clasificador aprende en la etapa de entrenamiento a identificar y decidir a que agrupamiento o región de decisión pertenece.

El caso más simple de un mecanismo de entrenamiento es el que utiliza datos linealmente separables. Por ejemplo consideremos a X como un grupo de datos de entrenamiento $X = \{x^1, x^2, x^3, \dots, x^p\}$, $x^j \in \mathbb{R}^s$. A partir de este conjunto se forman dos

grupos (conjunto de vectores) \mathbf{A}_1 y \mathbf{A}_2 , que contienen los datos que serán identificados de acuerdo a su grado de membresía. Cuando ocurre el proceso de identificación se deberá obtener un vector que separe linealmente a éstos grupos. El resultado de la etapa de aprendizaje está representado en el siguiente planteamiento: encontrar un vector W y un escalar b , tal que, todos los datos x^j , satisfagan las siguientes condiciones:

$$(a) \quad W^t x^j + b > 0, \quad \text{si } x^j \in \mathbf{A}_1 \quad (4.1)$$

$$(b) \quad W^t x^j + b < 0, \quad \text{si } x^j \in \mathbf{A}_2 \quad (4.2)$$

donde t representa transposición del vector W . Por lo tanto, si W y b existen, se puede decir que \mathbf{A}_1 y \mathbf{A}_2 son grupos o regiones linealmente separables; W es llamado también vector de separación y es el encargado de separar (identificar) los datos o elementos pertenecientes a los grupos \mathbf{A}_1 y \mathbf{A}_2 .

La región de decisión \mathcal{R}_1 correspondiente al entrenamiento de la clase \mathbf{A}_1 , se representa como:

$$\mathcal{R}_1 = \{x \mid x \in \mathcal{R}^t, x^t W + b > 0\} \quad (4.3)$$

Dos clases linealmente separables con sus correspondientes regiones de decisión[®] son mostradas en la figura 4.1.




Fig. 4.1 Clases linealmente separables.

Al utilizar el aprendizaje supervisado, se pueden obtener $\{A_1, A_2\}$ como clases o grupos para ser identificados a partir de cualquier espacio, denominadas regiones de decisión en el espacio \mathfrak{R}^s .

Para representar los vectores aumentados, se deberá añadir el $(s+1)$ -ésimo componente igual a 1, a los valores de X , tal que:

$$y^j = \begin{bmatrix} x^j \\ 1 \end{bmatrix}, \quad j=1, \dots, p \quad (4.4)$$

donde como resultado se obtiene a $Y = \{y^1, \dots, y^p\}$. Sea $g: Y \rightarrow \mathfrak{R}$ una función lineal discriminante,

$$g(v) = v^T y \quad (4.5)$$

donde

$$v = \begin{bmatrix} w \\ b \end{bmatrix} \quad (4.6)$$

siendo $v \in \mathfrak{R}^{s+1}$, el vector de pesos (separación). De esta manera, el clasificador representado por una neurona contiene el parámetro de pesos y el bias del hiperplano.

Se puede asumir que en el entrenamiento de las clases A_1 y A_2 , será posible representar una partición de Y . El objetivo es obtener el vector v de separación, tal que

$$v^T y > 0, \quad \text{si } x \in A_1, \quad (4.7)$$

$$v^T y < 0, \quad \text{si } x \in A_2 \quad (4.8)$$

En este caso la ecuación, $v^T y = 0$ representa una separación de la superficie en 2 regiones de decisión. Se puede decir que el clasificador aprendió en la etapa de entrenamiento a identificar los grupos o clases A_1 y A_2 . Considerando la normalización del signo,

$$z = \begin{cases} -y, & \text{si } x \in A_2 \\ y, & \text{si } x \in A_1 \end{cases} \quad (4.9)$$

donde, la condición de separación está dada por $v^T z > 0, \forall z$

4.4 PROCEDIMIENTO PARA EL ALGORITMO DE PERCEPTRÓN DIFUSO (APD)

El procedimiento de perceptrón difuso es útil en el entrenamiento de clases que son linealmente separables. Es un método para desarrollar técnicas de entrenamiento más flexibles que ayudan a descartar una clasificación o identificación de los datos en forma incorrecta, en una representación gráfica, una mala identificación o clasificación sería como la figura 4.2. Esta técnica satisface la separabilidad del hiperplano en la etapa de entrenamiento de los grupos [8].

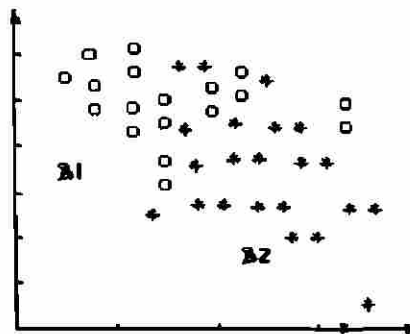


Fig. 4.2 Puntos contenidos de una forma no típica.

El método más sencillo para obtener la separación de vectores es un procedimiento iterativo en línea que utiliza la siguiente regla de entrenamiento:

$$v^{t+1} = v^t + \Delta v^t \quad (4.10)$$

$$\Delta v^k = \begin{cases} v^k + c z^k, & \text{si } v^{kT} z^k \leq 0 \\ 0, & \text{en otro caso} \end{cases} \quad (4.11)$$

donde $c > 0$ es la razón de aprendizaje. Este procedimiento corresponde al Algoritmo de Perceptrón(AP)[8].

4.5 SEPARACIÓN LINEAL DE CLASES DIFUSAS

La condición para llevar a cabo la separación de clases difusas es considerar a los grupos A_1 , A_2 como una partición difusa de Y .

Las clases difusas A_1 y A_2 serán linealmente separables si existe un vector $v \in \mathcal{R}^{s+1}$, válido para cada $y \in Y$, tal que:

$$\mu_1(y) > 0.5 \Leftrightarrow v^T y > 0 \quad (4.12)$$

$$\mu_2(y) > 0.5 \Leftrightarrow v^T y < 0 \quad (4.13)$$

donde $\mu_1(y)$ y $\mu_2(y)$ representan una función equivalente a $v^T y = 0$, mostrado en la figura 4.3.




Fig.4.3 Representación del espacio de los datos.

Si no se cumplen las condiciones anteriores, \mathbf{A}_1 y \mathbf{A}_2 serán considerados grupos difusos no lineales. Las condiciones 4.12 y 4.13 no son equivalentes entre sí, ya que la expresión es equivalente a la que se muestra a continuación

$$\mu_2(y) \geq 0.5 \Leftrightarrow \mathbf{v}^T \mathbf{y} \leq 0 \quad (4.14)$$

Cuando se consideren datos no lineales, la normalización se toma de la siguiente manera,

$$\mathbf{z} = \begin{cases} \mathbf{y}, & \text{si } \mu_1(\mathbf{y}) \geq 0.5 \\ -\mathbf{y}, & \text{si } \mu_2(\mathbf{y}) > 0.5 \end{cases} \quad (4.15)$$

De esta manera los agrupamientos difusos \mathbf{A}_1 y \mathbf{A}_2 serán linealmente separables, si existe un vector de pesos \mathbf{v} que satisfaga las siguientes condiciones

$$\mathbf{v}^T \mathbf{z} > 0 \quad \text{si } \mu_1(\mathbf{z}) > 0.5 \quad \text{o} \quad \mu_2(\mathbf{z}) > 0.5 \quad (4.16)$$

donde para cada valor de \mathbf{z} se satisface que $\mu_1(\mathbf{z}) = \mu_1(\mathbf{y})$. La condición de separación 4.16 también se puede establecer de la siguiente manera,

$$v^T z > 0 \text{ si } \mu_1(z) \neq \mu_2(z) \quad (4.17)$$

De acuerdo con la definición, los puntos que contienen igual grado de membresía tienden a ser clases linealmente separables representando su separación en un hiperplano. Si A_1 y A_2 son agrupamientos difusos linealmente separables, entonces existe un vector $v \in \mathcal{R}^{s+1}$ tal que

$$\mu_1(y) = \mu_2(y) \Leftrightarrow v^T y = 0 \quad (4.18)$$

el cual se encuentra representado en la figura 4.3.

4.6 ALGORITMO DE PERCEPTRÓN DIFUSO

Es posible mencionar el modelo más simple de redes neuronales difusas; en este caso, el algoritmo de perceptrón difuso. Este algoritmo es similar al no difuso, solamente que la función utilizada se obtiene por medio de distancias locales en la etapa de entrenamiento de los agrupamientos difusos, tal como lo muestra la figura 4.4.




Fig. 4.4 Modelo del perceptrón difuso.

Un perceptrón difuso puede ser entrenado a partir de clases difusas donde v_k son los pesos de la red para la k -ésima entrada y v_{s+1} es el valor umbral de la neurona (ver definición (4.6)).

Dado $X = \{x^1, x^2, x^3, \dots, x^p\}$, $x^j \in \mathbb{R}^s$, cada entrada x se conecta en el perceptrón difuso, donde cada una de ellas (para la etapa de entrenamiento) debe estar etiquetada con el grado de membresía correspondiente, según el agrupamiento A_1 y A_2 . La salida considerada por el perceptrón difuso es

$$y^j = \begin{bmatrix} x^j \\ 1 \end{bmatrix}, \quad j = 1, \dots, p \quad (4.19)$$

Tomando la normalización del signo,

$$z^j = \begin{cases} -y^j, & \text{si } \mu_2(y^j) > 0.5 \\ y, & \text{por el contrario} \end{cases} \quad (4.20)$$

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
Representando con Z al grupo de datos normalizados

DIRECCIÓN GENERAL DE BIBLIOTECAS

$$Z = \{z^1, z^2, z^3, \dots, z^p\} \quad (4.21)$$

se puede definir que los agrupamientos difusos A_1 , A_2 son linealmente separables, si existe un vector $v \in \mathbb{R}^{s+1}$ un espacio Z tal que

$$v^T z^j > 0, \quad j = 1, \dots, p \quad (4.22)$$

El algoritmo de perceptrón difuso genera dos regiones de decisión, si v^* es el vector solución obtenido entonces las regiones de decisión son \mathfrak{R}_1 y \mathfrak{R}_2 , donde


$$\mathfrak{R}_1 = \left\{ x \mid v^{*T} \begin{bmatrix} x \\ 1 \end{bmatrix} > 0 \right\} \quad (4.23)$$

y

$$\mathfrak{R}_2 = \left\{ x \mid v^{*T} \begin{bmatrix} x \\ 1 \end{bmatrix} < 0 \right\} \quad (4.24)$$

Por lo tanto, el hiperplano de separación en el espacio original de los datos en \mathfrak{R}^* , está dado por:

$$v^{*T} \begin{bmatrix} x \\ 1 \end{bmatrix} = 0 \quad (4.25)$$



U A N L

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN (4.26)

donde w es el vector que contiene los componentes de los pesos de la red. Cuando la red ha sido entrenada, es decir, que la memoria ha sido modificada, se presentan nuevos vectores de entrada x , y la red deberá asociar las salidas con las clases etiquetadas (1 o 2).

4.7 MODELO DEL PERCEPTRÓN DIFUSO DE KELLER Y HUNT

Un perceptrón con diferente entrenamiento difuso es el propuesto por Keller y Hunt. Ellos establecen que para un grupo de vectores simples X , donde cada clase

difusa se encuentra etiquetada como clase 1 y clase 2, los vectores de la clase 2 están multiplicados por -1 . Siendo estos un grupo de vectores normalizados, Keller y Hunt proponen un modelo diferente al de perceptrón difuso, haciendo la siguiente corrección:

$$v^{k+1} = v^k + \mu_1(z^k) - \mu_2(z^k) \cdot m \cdot cz^k \quad (4.27)$$

donde m es un número real $m > 1$.

El algoritmo propuesto por Keller y Hunt está basado en formulaciones lógicas considerado como un entrenamiento clásico:

$$\mu_1(z^k) = 0.5 + \frac{\exp\left(\frac{f(d_{k2} - d_{k1})}{d(u^1, u^2)}\right) - \exp(-f)}{2[\exp(f) - \exp(-f)]} \quad (4.29)$$

$$\mu_2(z^k) = 1 - A_1(z^k) \quad (4.30)$$

donde $d(u^1, u^2)$ es la distancia entre dos vectores y f es una constante positiva. Si z^k es la clase 2 tenemos que

$$\mu_2(z^k) = 0.5 + \frac{\exp\left(\frac{f(d_{k1} - d_{k2})}{d(u^1, u^2)}\right) - \exp(-f)}{2[\exp(f) - \exp(-f)]} \quad (4.31)$$

y

$$\mu_1(z^k) = 1 - A_2(z^k) \quad (4.32)$$

donde la constante f controla el rango en el cual el grado de membresía decrementa a 0.5. Es importante señalar que el grado de membresía asignado tiene las siguientes propiedades:

- a) $\mu_i(z^k) = 1$ si $z^k = u_i$,
- b) $\mu_i(z^k) = 0.5$ si $z^k = u_j$, $j \neq i$
- c) Si z^k es de la clase i entonces $\mu_i(z^k) \geq 0.5$

Si el vector z^k es considerado de la clase 1 y es equidistante de los 2 prototipos,

$d_{k1} = d_{k2}$, entonces el grado de membresía para A_1 es

$$\mu_1(z^k) = 0.5 + B \quad (4.33)$$

donde

$$B = \frac{1 - e^{-f}}{2(e^f - e^{-f})} \quad (4.34)$$

De otro modo, si z^k es considerado de la clase 2, el grado de membresía para A_2

es:

$$\mu_2(z^k) = 0.5 + B \quad (4.35)$$

La clasificación incorrecta de un punto depende de la clase que se desee considerar teniendo en cuenta la siguiente condición:

$$v^{kT} z^k \leq 0 \quad y \quad (\mu_1(z^k) \geq 0.5 + B \quad o \quad \mu_1(z^k) \leq 0.5 - B) \quad (4.36)$$

De manera que para eliminar algunos puntos atípicos, la constante B debería ser reemplazada por $B + e$, donde e es un margen positivo. El modelo de perceptrón difuso de Keller y Hunt utiliza la siguiente regla:

$$v^{k+1} = \begin{cases} v^k + c |\mu_1(z^k) - (\mu_2(z^k))|^m z^k, & \text{si } v^{kT}(z^k) \leq 0 \\ & \text{y } (\mu_1(z^k) \geq 0.5 + BETA) \text{ ó } (\mu_1(z^k) \leq 0.5 - BETA) \\ v^k, & \text{en otro caso} \end{cases} \quad (4.37)$$

donde $BETA = B + e$

Si las clases son linealmente separables, este procedimiento converge a la separación de los vectores [8].



UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN



DIRECCIÓN GENERAL DE BIBLIOTECAS

CAPÍTULO 5



RESULTADOS

UANL

5.1 INTRODUCCIÓN

En este trabajo se pretende implementar una herramienta que servirá para detectar problemas en el área de ingeniería eléctrica, donde los relevadores de distancia tienen tendencia a operar incorrectamente cuando ocurren oscilaciones de potencia, originadas por disturbios en la red eléctrica. Cuando se presentan situaciones donde la operación de los sistemas no es normal o está fuera de control, éstas pueden conducir a situaciones no deseadas como, por ejemplo, una baja calidad del suministro de energía eléctrica a los clientes, a equipos en las subestaciones, disminución de la seguridad para los usuarios, etc.. Cuando no se cuenta con algún instrumento de evaluación de la operación (ya sea normal o fallas en el sistema), es necesario desarrollar técnicas que lleven a mejorar el control del sistema desde su etapa de diseño. El objetivo principal que es el poder discriminar o distinguir entre los estados de operación, normales y anormales (fallas, oscilaciones, etc.).

5.2 HERRAMIENTAS UTILIZADAS PARA ESTUDIAR EL COMPORTAMIENTO DE LAS VARIABLES ELÉCTRICAS

Los fenómenos transitorios en sistemas eléctricos de potencia son altamente complejos y se requieren herramientas para su análisis, como es el Análisis de Componente Principal (ACP), Redes Neuronales Artificiales, etc., que ya han sido utilizados.

Una de las herramientas anteriormente mencionadas es el Análisis de Componente Principal (ACP), la cual fue empleada por ser una herramienta estadística útil cuando se tiene un conjunto de datos evaluados en función de su varianza. Esta técnica transforma un conjunto de variables correlacionadas en un conjunto de variables no correlacionadas. Encuentra los componentes más cercanos a las variables originales, pero ordenados en forma decreciente de su varianza. La principal ventaja de utilizar esta herramienta es comprobar el comportamiento de las variables eléctricas en la ubicación de un relevador de distancia para cada uno de sus componentes principales. Para tal transformación resultó evidente el tipo de disturbio que ocurre en el sistema eléctrico, lo cual hace posible diseñar un sistema de bloqueo para las oscilaciones del sistema de potencia.

Otra herramienta son las redes neuronales artificiales (RNA), las cuales son sistemas cuya estructura está basada en el sistema nervioso biológico. En un reporte de investigación se muestra la aplicación de las RNA en la discriminación entre cortocircuitos y oscilaciones de potencia [17].

Esta herramienta fue útil aplicarla de manera previa al presente estudio, ya que la discriminación entre un cortocircuito y una oscilación de potencia, se logró mediante identificación de patrones. Fue necesario construir para tal fin una red de neuronas artificiales utilizando como información de entrada cada una de las variables eléctricas correspondientes a las oscilaciones de potencia y a un cortocircuito, la salida de +1 de la

red neuronal, como una condición de bloqueo (para oscilación de potencia) y de -1 para una condición de no bloqueo (para cortocircuito) en el sistema eléctrico de potencia.

Al procesar las señales eléctricas se establecieron dos etapas: la primera etapa llamada de preprocesamiento, en la cual se eliminó todo el ruido presente (generalmente consiste en alta frecuencia) y se obtuvo cada uno de los rasgos distintivos característicos, que servirán para la etapa de clasificación; la segunda etapa consiste ahora en el procesamiento de estos rasgos distintivos para el entrenamiento o aprendizaje de la red, en relación al estado del sistema

5.3 OSCILACIONES Y FALLA EN UN SISTEMA DE POTENCIA

Es necesario mencionar el comportamiento eléctrico, de una oscilación de potencia, así como una falla (o cortocircuito) en el sistema eléctrico; la oscilación de potencia. Se origina de la variación con respecto al tiempo, del ángulo de defasaje, entre las fuerzas electromotrices, donde la corriente y el voltaje adquieren un carácter pulsante. La frecuencia de las oscilaciones está en un rango de 0.1 a 5 Hz, donde las frecuencias bajas son características de sistemas eléctricos fuertes y también de los primeros instantes de oscilación, mientras que las frecuencias altas son típicas de sistemas débiles y también de ciclos de oscilación posteriores al primero. Además es importante mencionar que en las oscilaciones de potencia varía la frecuencia.

Las oscilaciones de potencia entre máquinas síncronas de un sistema eléctrico de potencia se originan, por lo general, como consecuencia de la eliminación tardía de un cortocircuito, o por la desconexión de una línea de enlace o una planta generadora por cualquier causa. En casos más graves puede llegarse a la pérdida de sincronismo entre las máquinas del sistema. La oscilación de potencia consiste en una variación con el tiempo del ángulo de defasaje entre las máquinas, y la corriente adquiere un carácter pulsante. Su valor máximo ocurre en valores cercanos a 180° , en cuyo caso puede ser mayor que la corriente de cortocircuito, y su valor mínimo ocurre para valores cercanos

a 0°. Los voltajes del sistema adquieren también un carácter pulsante, y sus oscilaciones mayores ocurren en el denominado centro eléctrico del sistema, el cual es el punto en que el voltaje toma el valor mínimo.

Durante un cortocircuito, la impedancia medida por los relevadores de distancia coincide con la impedancia de la sección de la línea comprendida entre el punto de ubicación del relevador y el cortocircuito. En general, la impedancia es proporcional a la longitud de la sección de la línea comprendida desde el punto de ubicación del relevador hasta el punto del cortocircuito, es decir, es proporcional a la distancia eléctrica hasta la falla. Al ocurrir un cortocircuito, la corriente aumenta y el voltaje disminuye, por lo que la impedancia disminuye, según la siguiente expresión,

$$Z_r = \frac{V_r}{I_r} \quad (5.1)$$

Este fenómeno puede hacer que el relevador de distancia opere inadecuadamente, debido a que en las oscilaciones de potencia se presentan los mismos efectos, que son reducciones de voltaje e incrementos de corriente; en la figura 5.1 se muestra el comportamiento de las variables eléctricas durante una oscilación de potencia.

Las protecciones contra cortocircuitos tienen por lo general tendencia a operar durante las oscilaciones de potencia, ya que éstas provocan (al igual que los cortocircuitos) elevaciones de la corriente y reducciones del voltaje. Tal operación de las protecciones no es aceptable, pues puede provocar afectaciones en el sistema en situaciones que no necesariamente son críticas. Por ejemplo, la operación incorrecta de protecciones de distancia de líneas de transmisión durante oscilaciones de potencia es inadmisibles, ya que la desconexión de una línea en estas circunstancias aumentaría el efecto de la oscilación, pudiendo llegar a una condición de pérdida de sincronismo.

A fin de evitar la operación incorrecta de las protecciones contra cortocircuitos por efecto de las oscilaciones de potencia se utilizan esquemas de bloqueo; la función de

éstos esquemas es impedir la operación de la protección durante las oscilaciones de potencia y permitir la durante cortocircuitos. Para que la función de bloqueo sea llevada a cabo en forma apropiada, es necesario discriminar el comportamiento de las variables eléctricas (voltaje, corriente, impedancia, etc.) durante oscilaciones de potencia y durante fallas. Actualmente existen distintos esquemas de bloqueo, basados en los siguientes criterios:

1. Medición de la razón de cambio de la impedancia aparente,
2. Medición de la razón de cambio de la resistencia aparente,
3. Medición de la razón de cambio de incremento en la corriente,
4. Medición de la razón de cambio de una componente del voltaje,
5. Estimación del ángulo del voltaje.

No obstante, debido a que la oscilación de potencia es un fenómeno que depende del comportamiento dinámico de los generadores del sistema eléctrico de potencia, la razón de cambio de las variables eléctricas asociadas no es constante, y puede presentar amplios intervalos de variación, dependiendo de diversos factores; éste comportamiento constituye un problema en la selección del principio de funcionamiento y de los parámetros de ajuste del esquema de bloqueo.

5.4 GENERACIÓN Y CLASIFICACIÓN DE LOS DATOS

En este trabajo se propone una alternativa de solución con técnicas de inteligencia artificial como la lógica difusa y conceptos de redes neuronales artificiales, para obtener una clasificación lineal eficiente, es decir, realizar una buena identificación de las oscilaciones y fallas presentes en el sistema de potencia.

Los datos registrados se obtuvieron por simulación digital, los cuales median el comportamiento de las diferentes variables eléctricas a la vez, como lo son la

resistencia(R), reactancia(X), corriente(I), voltaje(V), impedancia(Z) y ángulo de defasamiento, según lo muestra la figura 5.1.




Fig. 5.1 Comportamiento de las variables eléctricas: Corriente(I), Voltaje(V) e Impedancia(Z).

Después de haber obtenido los datos se determinó el subespacio de los dos mayores componentes principales para los datos iniciales de oscilación, así como los datos de no oscilación para determinar la razón de cambio de las proyecciones de los datos iniciales (oscilación y no oscilación), todo esto realizado en el trabajo de preprocesamiento de los datos.

Después del preprocesamiento, los datos se clasifican en base a su comportamiento puesto que se encuentran distribuidos en cantidad no proporcional entre la prefalla, la falla y la oscilación de potencia, según muestra la figura 5.2. Los datos de esta figura no contienen un preprocesamiento para el ACP. Puede observarse que la cantidad total de los datos no es proporcional en cantidad, ya que los datos son en total

2746, de donde 80 son de la etapa de prefalla, 174 datos de falla y 2491 datos de oscilación. Después de haber clasificado los datos según el comportamiento de las variables (I , V y Z), se tomó una muestra proporcional en cantidad de datos para la situación de falla y de oscilación descartando los datos de la situación de prefalla.




Fig. 5.2 Comportamiento de las variables eléctricas en un instante de tiempo tomados en un estudio de estabilidad en el sistema.

Se seleccionaron muestras de tamaño semejante para llevar a cabo una mejor clasificación de cada situación. En total se consideraron 350 datos donde 170 pertenecen a la situación de falla y 180 datos pertenecen a la situación de oscilación, ver figura 5.3. Después de haber seleccionado la cantidad proporcional de datos se realizó una transformación a componente principal quedando para cada situación el espacio representado por la figura 5.4.

0146698




Fig. 5.3 Representación de los datos para las diferentes situaciones: Prefalla, Falla y Oscilación antes del preprocesamiento para el ACP.

Para cada caso, ya sea falla u oscilación se obtuvo el centro medio de cada agrupamiento, llamados u_1 y u_2 respectivamente.

$$u_1 = \sum_{j=1}^{170} \left[\frac{(Y_{ij})^T}{170} \right]^T \quad (5.2)$$

$$u_2 = \sum_{j=171}^{350} \left[\frac{(Y_{ij})^T}{180} \right]^T \quad (5.3)$$

Con la finalidad de encontrar las distancias promedio entre los centros medios de cada agrupamiento, se utilizó la siguiente expresión,

$$d_{u_1, u_2} = \sqrt{(u_1 - u_2)^T (u_1 - u_2)} \quad (5.4)$$

Al vector Y , el cual contiene el total de los datos de falla y oscilación, se le realizó la normalización del signo, para lo cual se agregó una nueva fila de 350 columnas con valores iguales a la unidad que llamamos r , el cual se anexa al vector de los datos originales(Y) para obtener un nuevo vector, llamado Y_m , representado por la siguiente expresión,

$$Y_m = \begin{bmatrix} Y \\ r \end{bmatrix} \quad (5.5)$$

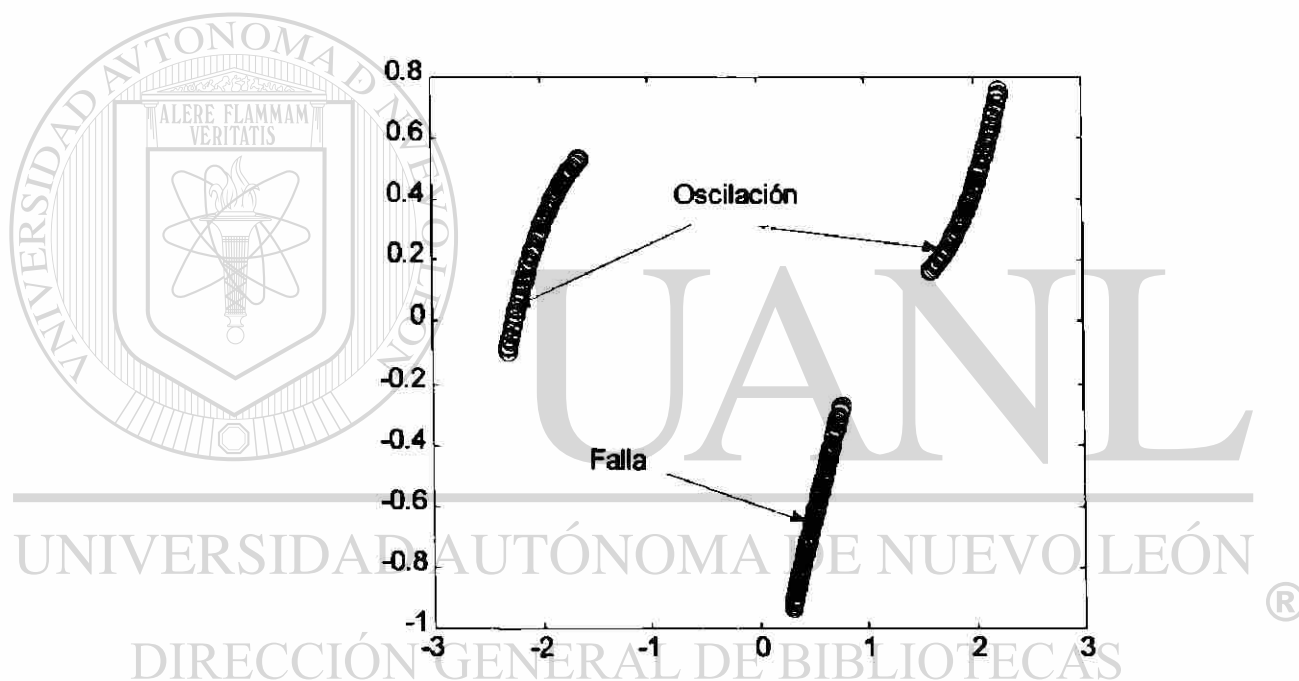


Fig. 5.4 Representación gráfica de los valores correspondientes a la situación de falla y de oscilación del sistema de potencia después de la transformación de los datos.

Cuando se realizó la normalización del signo se formó un nuevo vector de datos. El nuevo vector normalizado tiene para los primeros 170 datos correspondientes a falla, asociado un valor de +1, , mientras que un valor de -1, para los 180 datos siguientes correspondientes a oscilación.

Es importante mencionar que la simulación del algoritmo se realizó en Matlab. Después de haber tomado los datos según su representación gráfica, se inicializaron las variables para implementar el algoritmo de Perceptrón Difuso. Las variables necesarias para definirse se muestran en la Tabla 5.1.

Tabla 5.1 Tabla que contiene los valores necesarios antes de implementar el algoritmo de perceptrón difuso

| Expresión | Descripción de la expresión |
|-----------|----------------------------------------------------------------------------------------------------------------------|
| f | Esta constante es positiva y controla el rango en el cual el grado de membresía se decrementa, se inicializó como 3. |
| efp | $efp = e^f$ |
| efm | $efm = e^{-f}$ |
| ef_den= | $ef_den = 2 * e^f - e^{-f}$ |
| B | $B = \frac{1 - e^{-f}}{2(e^f - e^{-f})} + e$ |
| e | Este valor es un margen positivo, el cual se inicializó como 0.001 |

Para efectuar la identificación, se hará uso del concepto de grado de membresía asignado, el cual representará una situación diferente del sistema de potencia (falla y oscilación). Para calcular los grados de membresía de cada agrupamiento, antes se deben calcular las distancias de los datos con respecto a cada uno de los centros, mediante las siguientes expresiones:

$$dk_1 = \sqrt{(Yk - u_1)^T (Yk - u_1)} \quad (5.6)$$

$$dk_2 = \sqrt{(Yk - u_2)^T (Yk - u_2)} \quad (5.7)$$

Para tomar en cuenta la discriminación entre falla y oscilaciones del sistema como un problema de clasificación, se utilizaron los datos identificándolos previamente según su grado de membresía. Al igual que las redes de neuronas artificiales, los algoritmos de aprendizaje supervisados, en este caso el algoritmo de perceptrón difuso, pueden realizar la discriminación o clasificación y para eso se necesitaron datos (los cuales son rasgos distintivos para cada situación diferente) asociados con la caracterización de la operación (+1 o -1, para falla u oscilación respectivamente) y así poder aprender a identificarlos. Después de haber encontrado las distancias se calcularon los grados de membresía para el primer agrupamiento, que son la base de casos falla (ver cap. 4 (4.29), (4.30)), y del segundo agrupamiento, base de casos para oscilación en el sistema de potencia, (ver cap. 4 (4.31), (4.32)).

Posteriormente se define el vector inicial normalizado v^k , al cual llamaremos C ; así mismo es necesario tener la diferencia entre los centros de cada agrupamiento (c_d) y la distancia media o promedio entre ellos (c_m).

$$c_d = u_1 - u_2 \quad (5.8)$$

$$c_m = \frac{u_1 + u_2}{2} \quad (5.9)$$

Para formar el vector inicial v^k , se obtuvo un vector normalizado,

$$W = \frac{c_d}{|c_d|} \quad (5.10)$$

$$b = \left(\frac{(c_d)^T}{|c_d|} \right) (c_m) \quad (5.11)$$

$$C = \begin{bmatrix} W \\ b \end{bmatrix} \quad (5.12)$$

Cuando se aplica a los datos el algoritmo de perceptrón difuso, éstos serán plenamente identificados obteniendo una función lineal para la separación de los datos, donde esta separación representará el proceso de identificación. Los resultados obtenidos al aplicar esta técnica de inteligencia artificial, nos dará un grado de error mínimo en la etapa de clasificación o identificación.

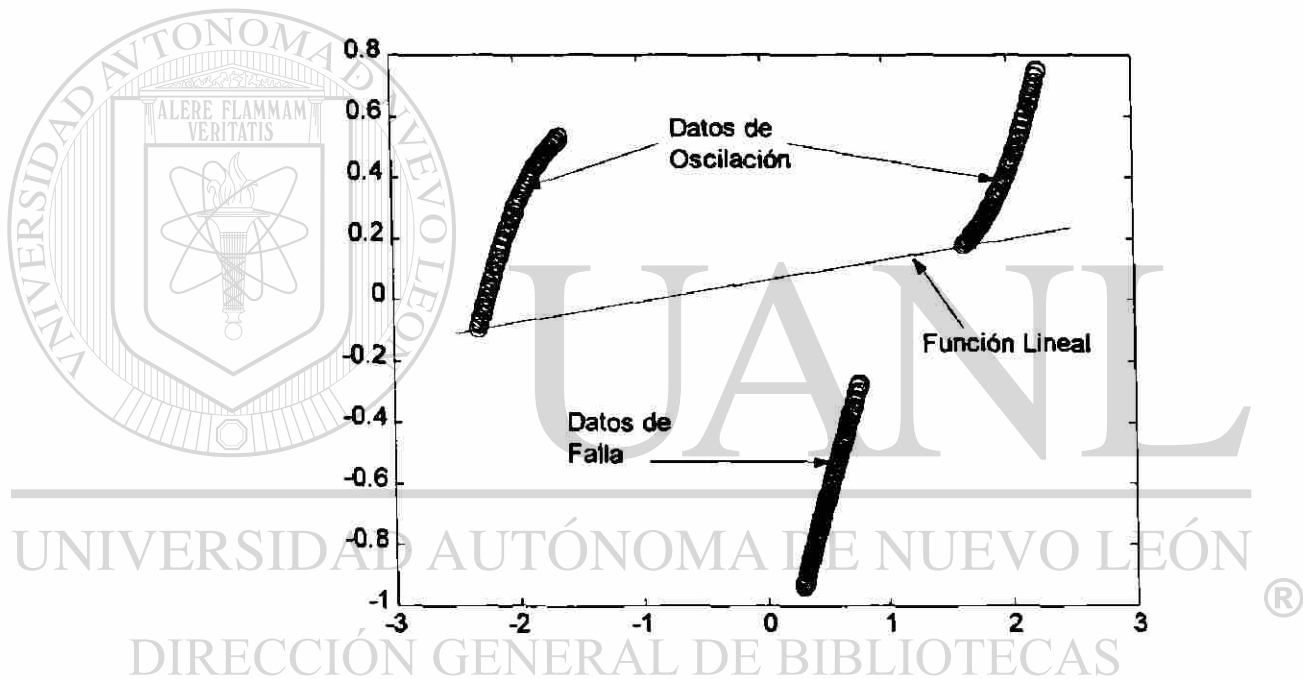


Fig. 5.5 Representación gráfica del proceso de aprendizaje y la generación de una función lineal de separación (identificación) por medio del algoritmo de perceptrón difuso.

Cuando se haya encontrado una separación lineal dentro de su fase de aprendizaje, la aplicación del algoritmo se detendrá. En consecuencia al terminar el proceso de aprendizaje, se determina la función lineal que representará al hiperplano de separación que realiza el proceso de identificación. La función lineal es obtenida a partir

de los datos transformados por ACP y son representados gráficamente en un período de -2.5 a 2.5 en las ordenadas, tal como lo muestra la figura 5.5.

La función lineal obtenida es representada por los valores del vector C mostrados a continuación:

$$C = \begin{bmatrix} W \\ b \end{bmatrix} = \begin{bmatrix} 0.0682 \\ -0.9964 \\ 0.0592 \end{bmatrix}$$

Para confirmar la adaptación de una función lineal se tomaron datos de forma aleatoria a partir de la muestra considerada en la fig. 5.5, de donde se tomaron solo los datos impares para la etapa de falla y oscilación, encontrándose una nueva función lineal para el mismo período tomado con anterioridad, tal como lo muestra la figura 5.6.

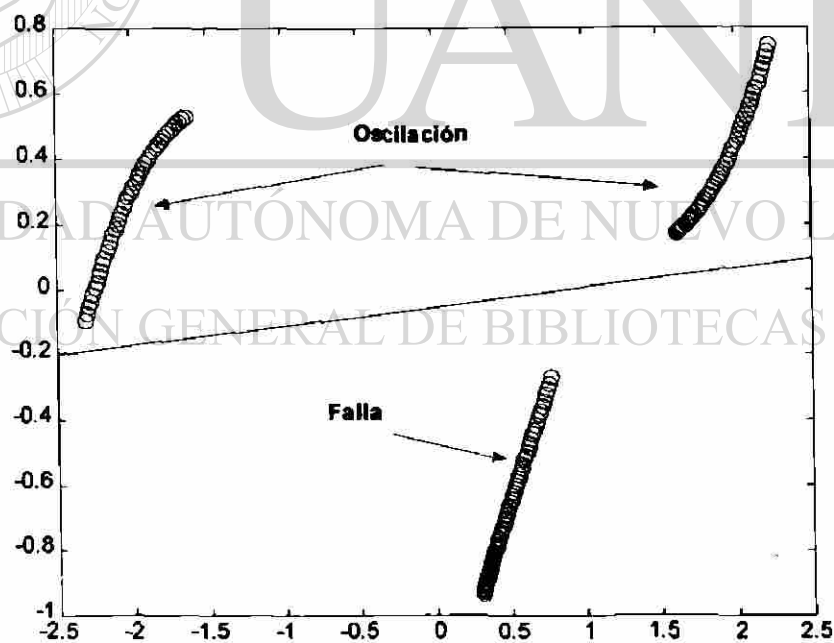



Fig. 5.6 Representación de los datos impares tomados para realizar una prueba

CAPÍTULO 6



CONCLUSIONES

6.1 CONCLUSIONES Y RECOMENDACIONES

La hipótesis inicial y objetivo del presente estudio es demostrar que el algoritmo de perceptrón difuso es útil en la separación o clasificación lineal de los datos. Además de manejar datos linealmente separables es posible demostrar las otras ventajas que se presentan al realizar un reconocimiento inteligente, además de que es factible su implementación tanto a nivel hardware como en software.

Es importante mencionar que los datos utilizados fueron obtenidos a partir de un estudio de estabilidad desarrollado en proyectos anteriores, por esta razón fue posible implementar este algoritmo para la clasificación de fallas y oscilaciones en un sistema eléctrico de potencia.

Al hablar del proceso de aprendizaje se observa que el algoritmo de perceptrón difuso es de gran eficiencia por mostrar un rápido aprendizaje o entrenamiento de los

datos, sin embargo es necesario mencionar que pueden presentarse casos en los que la aproximación de los datos resulta un poco ambigua cuando se tienen datos pertenecientes a un grupo, por lo que será necesario aplicar otras herramientas para precisar su pertenencia.

La finalidad de la aplicación del algoritmo en el proceso de aprendizaje es ajustar los parámetros del clasificador, de tal manera que éstos se adecúen para lograr una clasificación correcta, o separación lineal de el total de los datos pertenecientes a cada grupo a clasificar o identificar. Cuando se haya encontrado una separación lineal dentro de su fase de aprendizaje, la aplicación del algoritmo se detendrá logrando representar la función lineal que genera la separación del hiperplano logrando así el proceso de identificación.

Es importante mencionar que el presente estudio es una continuación de trabajos anteriores donde en esta ocasión fue necesario aplicar el algoritmo de Perceptrón Difuso con otras herramientas pertenecientes al área de Inteligencia Artificial, inclusive desde proyectos realizados con anterioridad, de donde se demuestra que ésta sigue siendo un área de trabajo sumamente útil para la automatización de procesos, siempre y cuando se den resultados satisfactorios y de la más completa calidad u optimalidad en un mínimo de tiempo requerido.


Es necesario continuar con el estudio de la evaluación de la membresía de los patrones de entrenamiento, principalmente por la forma de agrupamiento que se tiene en las oscilaciones. La consideración de la distancia euclidiana en la función de recurrencia del vector de parámetros v del clasificador, a través de la función de pertenencia o membresía, puede mejorarse si consideramos un nuevo procedimiento en el cual una de las clases se constituye a la vez en un conjunto de agrupamientos.

Se requiere continuar con el estudio de casos considerando etapas de procesamiento digital de señales que se llevan a cabo en los actuales relevadores digitales para así lograr nuevos y excelentes resultados.

BIBLIOGRAFÍA

- [1] Chin-Teng Lin; C.S. George Lee "Neural Fuzzy Systems. A Neuro-Fuzzy Synergism to Intelligent Systems," Prentice Hall 1996.
- [2] Sankar K. Pal, Sushmita Mitra "Neuro-Fuzzy Pattern Recognition. Methods in Soft Computing," John Willey & Sons 1999.
- [3] Carl G. Looney, "Pattern Recognition Using Neural Networks. Theory and Algorithms for Engineers and Scientists," Oxford University Press 1997.
- [4] Timothy J. Ross, "Fuzzy Logic With Engineering Applications," McGraw-Hill 1995.
- [5] Simon Haykin, "Neural Networks. A comprehensive foundation," Prentice Hall 1999.
- [6] Christopher M. Bishop, "Neural Network for Pattern Recognition," Oxford University Press 1998.
-
- [7] Richard Johnsonbaugh, "Matemáticas Discretas," Prentice Hall 2000.
- [8] D. Dumitrescu, B. Lazzerini, L. C. Jain, "Fuzzy Sets and Their Application to Clustering and Training," CRC 2000.
- [9] Aeshond J. Higham, Nicholas J. Higham, "Matlab Guide," 2000.
- [10] Elaine Rich, "Artificial Intelligence," McGraw-Hill, 1983.
- [11] R. R. Yager, R.M. Tong, H. T. Nguyen, S. Ouchinnikov, "Fuzzy Sets and Applications," John Willey & Sons 1987.
- [12] Kevin M. Passino, Stephen Yurkovich, "Fuzzy Control," Addison-Wesley 1998.
- [13] Dean Kelly, "Teoría de Automatas y Lenguajes Formales," Prentice-Hall 1995.

- [14] Stuart Russell, Peter Norving, "Inteligencia Artificial. Un enfoque moderno," Prentice-Hall 1996.
- [15] Tina A. Folger, "Fuzzy Sets, Uncertainty and Information," Prentice-Hall 1988.
- [16] A. Kaufmann, "Theory of fuzzy subsets," Academic Press 1975.
- [17] Josue Coutiño Ozuna, "Aplicación de redes neuronales en la discriminación entre fallas y oscilaciones de potencia," 2001.



UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

DIRECCIÓN GENERAL DE BIBLIOTECAS




LISTA DE TABLAS Y FIGURAS

- Tabla 3.1 Resultados obtenidos al aplicar el algoritmo difuso de C-Medias
- Tabla 5.1 Tabla que contiene los valores necesarios antes de implementar el algoritmo de perceptrón difuso
- Fig. 2.1 a) Separación lineal de clases y b) Separación no lineal de clases.
- Fig. 2.2 Modelo de una neurona biológica.
- Fig. 2.3 Modelo de redes neuronales artificiales con capa de entrada, oculta y de salida.
- Fig. 3.1 Núcleo, soporte y límites de un agrupamiento difuso.
- Fig. 3.2 Agrupamientos de prueba
- Fig. 4.1 Clases linealmente separables.
- Fig. 4.2 Puntos contenidos de una forma no típica.
- Fig. 4.3 Representación del espacio de los datos.
- Fig. 4.4 Modelo del perceptrón difuso.
- Fig. 5.1 Comportamiento de las variables eléctricas: Corriente(I), Voltaje(V) e Impedancia(Z).
- Fig. 5.2 Comportamiento de las variables eléctricas en un instante de tiempo tomados en un estudio de estabilidad en el sistema.
- Fig. 5.3 Rerepresentación de los datos para las diferentes situaciones: Prefalla, Falla y Oscilación antes del preprocesamiento para el ACP.
- Fig. 5.4 Representación gráfica de los valores correspondientes a la situación de falla y de oscilación del sistema de potencia después de la transformación de los datos.

Fig. 5.5 Representación gráfica del proceso de aprendizaje y la generación de una función lineal de separación(identificación) por medio del algoritmo de perceptrón difuso.

Fig. 5.6 Representación de los datos impares tomados para realizar una prueba



UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

DIRECCIÓN GENERAL DE BIBLIOTECAS



GLOSARIO

Inteligencia artificial

Estudia el comportamiento inteligente del ser humano representando y simulando la habilidad humana mediante la creación de modelos y algoritmos computacionales a fin de aplicarlo en la solución de problemas

Clustering

Es el proceso de agrupamiento de un vector de rasgos distintivos dentro de clases.

Strings

Son cadenas de símbolos seleccionados de un alfabeto en particular.

Máquina de estado finito

Es una máquina con memoria que almacena un estado que recibe letras de entrada, cambia éste estado en función del estado actual.

La inferencia gramatical

Es el proceso que sirve para determinar la gramática adecuada de un grupo o clase.

Red neuronal artificial

Es un sistema altamente interconectado formado por múltiples elementos denominados neuronas artificiales.

Conjunto

Es una colección de objetos con características en común.

Agrupamiento difuso

Es aquel que puede contener diferentes grados de membresía.

Regla de aprendizaje o entrenamiento

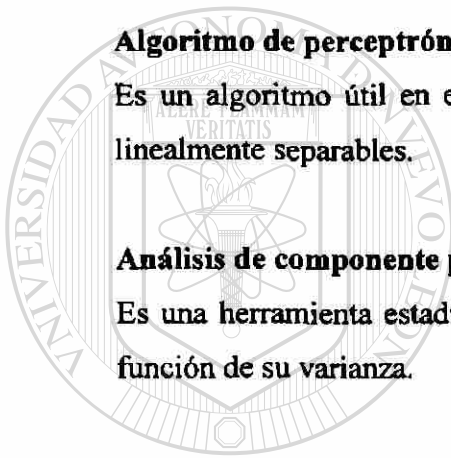
Es el proceso mediante el cual adquirimos conocimiento, o modificamos la memoria de un sistema; esta memoria se utiliza para la identificación de características o elementos pertenecientes a un grupo u otro. Existen dos tipos de aprendizaje, el aprendizaje supervisado y aprendizaje no supervisado.

Algoritmo de perceptrón difuso

Es un algoritmo útil en el entrenamiento o proceso de aprendizaje de clases que son linealmente separables.

Análisis de componente principal

Es una herramienta estadística útil cuando se tiene un conjunto de datos evaluados en función de su varianza.

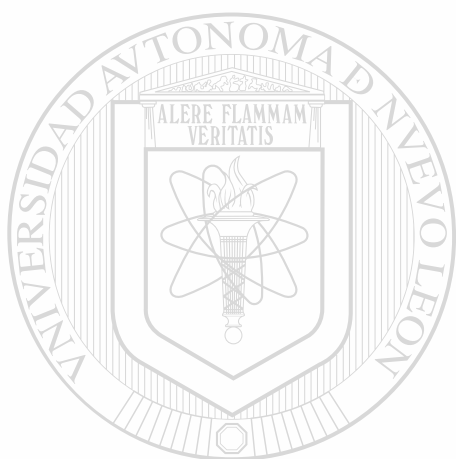


UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

DIRECCIÓN GENERAL DE BIBLIOTECAS





APÉNDICES

UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

®

DIRECCIÓN GENERAL DE BIBLIOTECAS

APÉNDICE A: PASOS PARA LA APLICACIÓN DEL ALGORITMO DE PERCEPTRÓN DIFUSO

Paso 1. Inicializar las variables $f > 0.5$, $c > 0$ y $e > 0$.

Paso 2 Definir el vector de separación lineal, v^k .

Paso 3. Repetir el paso 4 hasta que no se ajuste un vector v^k que separe linealmente los agrupamientos.

Paso 4. Transformar la separación del vector de acuerdo a la siguiente regla:

$$v^{k+1} = \begin{cases} v^k + cA_i(z^k)z^k, & \text{si } A_i(z^k) > 0.5 \text{ y } v^{kT}z^k \leq 0 \\ v^k, & \text{si } v^{kT}z^k > 0 \end{cases}$$

$$k = k + 1$$

DIRECCIÓN GENERAL DE BIBLIOTECAS

APÉNDICE B: CÓDIGO FUENTE

```

%programa impl
load neto2 % Resultado estudio de estabilidad
Zlinea=0.6; % Impedancia de la línea
%
for k=1:3001 % Tiempo total de simulación = 3 s
    t(k)=0.001*k;
    fi(k)=atan(Qijor(3,k)/Pijor(3,k));
    V(k)=abs(bus_v(3,k));
    I(k)=Pijor(3,k)/(abs(bus_v(3,k))*cos(fi(k)));
    Z(k)=abs(bus_v(3,k))/I(k);
    R(k)=Z(k)*cos(fi(k));
    X(k)=Z(k)*sin(fi(k));
end
%
% t = Tiempo de simulación en ms
% fi= Angulo de defasamiento
% V = Voltaje en el punto del relevador
% I = Corriente por la ubicación de relevador
% Z = Impedancia medida por el relevador, normalizada
%     con respecto a impedancia de la línea (Zlinea)
% R = Resistencia (normalizada)
% X = Reactancia (normalizada)
%
save var_ele t fi V I Z R X
%
%
L=[R;X;I;V;Z;fi];
%
%NOTA: Se tomaron los datos desde la columna 81 hasta la
%430
%porque los datos del 1 hasta el 80 son datos de prefalla.
%del 81 al 255 son datos de falla.
%del 256 al 3001, pero tomaremos hasta el 430 para tener la
%misma cantidad de datos, de falla(170) y de los que son
%de oscilación(180).

```

```

%
%Para el estudio consideraremos 170 datos de fallas y 180
%datos de oscilaciones, total=350 datos.
T=L(:,81:430);
mT=(mean(T'))';
[Val D U]=svd(cov(T'));
W=Val(:,[1 2])';
Y=W*T;
%L(:,1:3001);
%
%Observe que en T hay (255-81+1=) 175 datos de fallas y
%(3001-256+1)=2746 datos de oscilaciones.
%media de las fallas
%
u1=(sum(Y(:,1:170)')/170)';
u2=(sum(Y(:,171:350)')/180)';
dulu2=sqrt((u1-u2)'*(u1-u2));
%
N=350;
f=3;
efp=exp(f);
efm=exp(-f);
ef_den=2*(efp-efm);
B=(1-efm)/(2*(efp-efm))+0.001;
%
for k=1:N
    dk1=sqrt((Y(:,k)-u1)'*(Y(:,k)-u1));
    dk2=sqrt((Y(:,k)-u2)'*(Y(:,k)-u2));
    %ma1=0.5+(exp(f*(dk2-dk1)/dulu2)-efm)/ef_den;
    %mb1=1-ma1;
    %ma2=0.5+(exp(f*(dk1-dk2)/dulu2)-efm)/ef_den;
    %mb2=1-ma2;
    if k<=170
        m(1,k)=0.5+(exp(f*(dk2-dk1)/dulu2)-efm)/ef_den;
        m(2,k)=1-m(1,k);
    else
        m(2,k)=0.5+(exp(f*(dk1-dk2)/dulu2)-efm)/ef_den;
        m(1,k)=1-m(2,k);
    end
end
end
%
%
%Formar un vector con la tercera fila para la normalizacion
%del signo de los datos
%
r=ones(1,350);
Ym=[Y;r];

```

```

%
% Normalizacion del signo
%
YY=[Ym(:,1:170) -Ym(:,171:350)];
%
%
% Definicion del vector inicial normalizado para vk
%(vector vk inicial)
%
% u1,u2: media de las fallas
%
cd=u1-u2;
cm=(u1+u2)/2;
%
W=(cd/norm(cd));
b=((cd)'/norm(cd))*cm;
%
% Vector Vk inicial
%
C=[W;b];
%
contador_fc=10000;
%
while contador_fc~=0
    contador_fc=0;
    for i=1:350
        if C'*YY(:,i)<=0 & ((m(1,i)<=0.5+B) | (m(1,i)>=0.5-
B))
            C=C+0.1*abs(m(1,i)-m(2,i))^2*YY(:,i);
            contador_fc=contador_fc+1;
        end
    end
end
end
%
MM=C'*YY;
WW=C'*Ym;
%
%
figure(1)
plot(Ym(1,1:170),Ym(2,1:170),'ro')
hold on
plot(Ym(1,176:350),Ym(2,176:350),'bo')
x=[-2.5 2.5];
y(1)=(-C(1)*x(1)-C(3))/C(2);
y(2)=(-C(1)*x(2)-C(3))/C(2);
plot(x,y,'g-')
hold off

```

RESUMEN AUTOBIOGRÁFICO

VALERIA PAOLA GONZALEZ DUÉÑEZ

Candidato para obtener el grado de

Maestro en Ciencias de la Administración con Especialidad en Sistemas

TESIS:

CLASIFICACIÓN DE FALLAS Y OSCILACIONES EN UN SISTEMA ELÉCTRICO UTILIZANDO EL ALGORITMO DE PERCEPTRÓN DIFUSO

BIOGRAFIA

Nacida en Monterrey, N.L., el 21 de Febrero de 1978, hija de Tomás González Gutiérrez y Olga Duéñez de González.

CAMPO DE Sistemas

ESTUDIO

EDUCACION

Egresada de la Facultad de Ingeniería Mecánica y Eléctrica de la Universidad Autónoma de Nuevo León, con el grado de Ingeniero Administrador de Sistemas en 1999.

EXPERIENCIA

Catedrático de la Facultad de Ingeniería Mecánica y Eléctrica de la Universidad Autónoma de Nuevo León, desde 1999 a la fecha.

PROFESIONAL

Jefatura del Área de Investigación de Procesos en Productividad Asesoría y Servicios, S.A., en 1999.

