

INSTITUTO POLITÉCNICO NACIONAL
UNIDAD PROFESIONAL INTERDISCIPLINARIA DE BIOTECNOLOGÍA

**NEUROIDENTIFICACIÓN DE LA DINÁMICA DE UNA
INCUBADORA NEONATAL MEDIANTE REDES
NEURONALES Y FILTROS DE KALMAN**

PROTOCOLO DE LA OPCIÓN CURRICULAR EN LA MODALIDAD DE:
PROYECTO DE INVESTIGACIÓN

PRESENTA:
DAVID VALDEZ ANGELES

DIRECTOR INTERNO:
Dr. AGUSTÍN I. CABRERA LLANOS

EVALUADORES:
M. en C. JORGE ISAAC CHAIREZ ORIA
M. en C. ALEJANDRO MUÑOZ DIOSDADO
M. en C. GONZALO GÁLVEZ COYT

México, D. F. 26 de mayo de 2006

Índice general

Índice de figuras	III
1. DESARROLLO FETAL	6
1.1. INTRODUCCIÓN	6
1.2. PREMATUREZ	7
1.2.1. CLASIFICACIÓN DEL RN SEGÚN PESO DE NACIMIENTO	9
1.2.2. CLASIFICACIÓN DEL RN SEGÚN EDAD GESTACIONAL	10
1.3. TERMORREGULACIÓN	10
1.4. LAS PÉRDIDAS DE CALOR EN EL RECIÉN NACIDO	11
2. SISTEMAS DE SOPORTE DE VIDA NEONATAL	13
2.1. INTRODUCCIÓN	13
2.2. CUNA DE CALOR RADIANTE	14
2.3. INCUBADORAS CON SERVO CONTROL	15
2.4. VARIABLES TERMO-FÍSICAS Y FISIOLÓGICAS DE IMPORTANCIA	16
2.5. TERMONEUTRALIDAD	17
2.6. GRADIENTE DE TEMPERATURA EXTERNO	18
3. FILTRO DE KALMAN Y EXTENSION DE LOS FILTROS DE KALMAN DISCRETOS	20
3.1. INTRODUCCIÓN	20
3.2. FILTROS DE KALMAN EN TIEMPO DISCRETO	21
3.2.1. FILTROS DE KALMAN CON PREDICCIÓN	24
3.2.2. FILTRO DE KALMAN CON FILTRADO	35
3.2.3. ELIPSE DE DISTRIBUCIÓN DEL ERROR	46
3.3. EL FILTRO DE KALMAN EXTENDIDO	52
3.4. ALGORITMO DE APRENDIZAJE BASADO EN LOS FILTROS DE KALMAN	55
4. LÓGICA DIFUSA	62
4.1. INTRODUCCIÓN	62
4.2. LÓGICA DIFUSA	64
4.2.1. CONTROLADOR DIFUSO	64

5. TÉCNICAS AVANZADAS DE IDENTIFICACIÓN	70
5.1. REDES NEURONALES	70
5.1.1. CONCEPTOS FUNDAMENTALES DE REDES NEURONALES ARTIFICIALES.	70
5.1.2. TIPOS DE CONEXIONES DE LAS REDES NEURONALES	73
5.1.3. ALGORITMO BACKPROPAGATION	75
5.2. SISTEMAS NEURODIFUSOS	78
5.2.1. ARQUITECTURA NEURODIFUSA.	78
5.2.2. TIPOS DE CONTROLADORES NEURODIFUSOS	79
6. METODOLOGÍA	82
6.1. PROTOTIPO DE UNA INCUBADORA NEONATAL	83
6.1.1. CHASIS	83
6.1.2. CAPACETE	84
6.1.3. PLATAFORMA Y SOPORTE PARA EL COLCHÓN	84
6.1.4. INTERCAMBIADOR DE CALOR	84
6.1.5. UNIDAD DE ACONDICIONAMIENTO TÉRMICO DEL AIRE	85
6.1.6. SISTEMA DE EXTRACCIÓN DE AIRE	85
6.1.7. SENSOR DE TEMPERATURA	86
6.2. DISEÑO DE LA RED NEURONAL CON EXTENSIÓN DE FILTROS DE KALMAN PARA LA IDENTIFICACIÓN DE LA TEMPERATURA	88
6.2.1. REGLAS DE APRENDIZAJE PARA LA RED NEURONAL	92
6.3. DISEÑO DEL SISTEMA NEURODIFUSO PARA LA IDENTIFICACIÓN DE LA TEMPERATURA	95
6.3.1. REGLAS DE APRENDIZAJE	97
6.4. ESTRUCTURA EN TIEMPO REAL	104
7. RESULTADOS	106
7.1. INTRODUCCIÓN	106
7.2. PRUEBAS DE SIMULACIÓN	107
7.2.1. IDENTIFICADOR DE LA TEMPERATURA CENTRAL UTILIZANDO LA RED NEURONAL	107
7.2.2. IDENTIFICADOR DE LA TEMPERATURA CENTRAL UTILIZANDO EL SISTEMA NEURODIFUSO	113
7.3. PRUEBAS EN TIEMPO REAL	117
7.3.1. IDENTIFICACIÓN DE LA TEMPERATURA CENTRAL DE LA INCUBADORA CON LA RED NEURONAL	120
7.3.2. IDENTIFICACIÓN DEL LA TEMPERATURA CENTRAL UTILIZANDO EL SISTEMA NEURODIFUSO	122
8. CONCLUSIONES	127
Bibliografía	129

Índice de figuras

1.1. Clasificación de la edad gestional	9
2.1. Relación de las variables térmicas de la incubadora con el metabolismo del infante	19
3.1. Diagrama de un sistema lineal con filtros de Kalman	23
3.2. Diagrama a bloques del filtro de Kalman	23
3.3. Diagrama a bloques de la estimación con filtros de Kalman	25
3.4. Elipse de distribución del error	48
4.1. Estructura del controlador difuso	66
5.1. Perceptrón simple	72
5.2. Conexión de las redes neuronales	74
5.3. Estructura ANFIPS de un sistema neurodifuso	80
6.1. Estructura de la red neuronal utilizada para la identificación de temperatura	90
6.2. Estructura del sistema neurodifuso	96
6.3. Diagrama a bloques del sistema para la identificación de la temperatura central en tiempo real	105
7.1. Gradiente de temperatura externo (GTE)	108
7.2. Cambio del gradiente de temperatura externo respecto a el tiempo (AGTE)	109
7.3. Salida de la red neuronal	110
7.4. Error obtenido en la identificación de la temperatura	111
7.5. Dinámica de los pesos durante la identificación de la temperatura	112
7.6. Varianza de los pesos, durante la identificación de la temperatura	113
7.7. Salida del sistema neurodifuso	115
7.8. Comportamiento del error del sistema neurodifuso	116
7.9. Dinámica de los centros de las funciones de membresia de tipo gaussiano	117
7.10. Varianza de los centros de las funciones de membresia de tipo gaussiano	118
7.11. Diagrama esquemático para la identificación en tiempo real	119
7.12. Comportamiento de la salida de la red neuronal	120

7.13. Error de Identificación de la temperatura central de la incubadora	121
7.14. Comportamiento de los pesos, durante la identificación de la temperatura .	122
7.15. Varianza de los pesos, durante la identificación de la temperatura	123
7.16. Identificación de la temperatura, mediante el sistema neurodifuso	124
7.17. Comportamiento del error de identificación del sistema neurodifuso	125
7.18. Comportamiento temporal de las desviaciones estandar de las funciones de membresía de tipo gaussiano	125
7.19. Comportamiento de las varianzas de las desviaciones estandar de las funciones de membresía	126

AGRADECIMIENTOS

- A mi mamá, por brindarme su amor, paciencia y apoyo, ya que ella es mi motivación para seguir adelante, y cambiar día a día.
- A mi hermano Alberto, por apoyarme y darme todo su cariño, ya que para mí él es como un padre, que me guió y me enseñó a ser un mejor hombre, muchas gracias.
- A mi hermana Lilia, por el apoyo que me ha brindado en estos momentos.
- A mi cuñada Beatriz, por brindarme su apoyo en esta etapa de mi vida, muchas gracias.
- A mis primos Jaime y Alfredo, por brindarme su comprensión y su apoyo por haber compartido momentos que fueron muy importantes para mí.
- Al maestro Isaac Chairez, por brindarme su paciencia, comprensión, amistad, así como por haber contribuido en mi desarrollo, para poder ser un hombre mejor cada día.
- Al Dr. Agustín, por haber contribuido en una parte de mi formación académica.
- A mis amigos de proyecto: Manuel, Pablo, Ramón, Erubiel, Johny, Víctor, Martín, Iván, por haberme aportado sus conocimientos en el laboratorio.
- A Eva, por haberme prestado parte de su tiempo para escucharme, comprenderme, y por ofrecerme su confianza y cariño.

RESUMEN

En el presente trabajo se describe el desarrollo de algoritmos para la identificación de la temperatura central en un prototipo de una incubadora neonatal, ya que esta variable es imprescindible para proveer un ambiente óptimo para la supervivencia del recién nacido prematuro. Para la identificación de la temperatura central, se utilizó el concepto de Gradiente de Temperatura Externo (GTE), ya que es un parámetro muy importante para la evaluación del desarrollo metabólico del recién nacido prematuro.

Para la identificación de la temperatura central en el microambiente de la incubadora, se utilizaron técnicas avanzadas, como son las redes neuronales, que tienen la capacidad de aprender por medio de un entrenamiento, a través de un set de entradas que son proporcionadas por las variables que son medibles, y los sistemas neurodifusos, que son una combinación de los sistemas difusos y las redes neuronales.

De este modo, con los dos sistemas propuestos se realizará una comparación para observar el comportamiento y la velocidad de convergencia entre el sistema neurodifuso y la red neuronal, utilizando como ley de aprendizaje de los pesos y de los parámetros de las funciones de membresía, la Extensión de los Filtros de Kalman (EKF), para la identificación de la temperatura central.

Para observar el comportamiento del sistema neurodifuso y de la red neuronal, se realizaron simulaciones de las dos técnicas y posteriormente se realizaron pruebas en tiempo real en un prototipo de una incubadora neonatal construida en base a la norma oficial (NOM-066-SSA1-1993), para equipos médicos en el cuidado de recién nacidos prematuros llamado "Sistemas de soporte de vida neonatal".

JUSTIFICACIÓN

Uno de los principales problemas que se tienen en la ingeniería Biomédica son las variables que no pueden medirse, de este modo, no es posible realizar un diagnóstico o un control, debido a la falta del sensor que nos muestre el comportamiento de la variable de interés. Por este motivo se requieren sistemas que describan el comportamiento de las variables que desconocemos, mediante variables que son medibles.

Debido a que no se conoce el modelo matemático que describe el comportamiento dinámico de la temperatura central dentro del microambiente de la incubadora, se deben de aplicar algoritmos que sean capaces de informarnos sobre el comportamiento de la temperatura central, por medio del gradiente de temperatura externa (GTE) y el cambio del GTE respecto al tiempo (AGTE). El GTE es la diferencia entre la temperatura de la piel del neonato y la temperatura del microambiente de la incubadora, además que es un parámetro que nos informa sobre el estado metabólico en el que se encuentra el neonato, y por lo tanto es un parámetro muy importante para el desarrollo del recién nacido prematuro, debido a que estos dos parámetros (GTE y AGTE) son medibles, se puede identificar la temperatura central del interior de la incubadora, con la finalidad de observar el comportamiento de estas, y de esta forma conocer si el equipo está listo para introducir al recién nacido prematuro.

Los algoritmos que se emplean para la identificación de variables son de distintas índoles y para poder aplicarlos, se necesita conocer si el sistema es lineal o no lineal. Los sistemas biológicos y principalmente, la temperatura, presentan un comportamiento no lineal, además la temperatura, presentan un tipo de ruido browniano y se pueden presentar perturbaciones, principalmente por la fabricación del sensor, por este motivo, se deben desarrollar algoritmos que sean capaces de identificar las variables de interés aún con las perturbaciones y ruidos que se mencionaron anteriormente.

Una de las propuestas para eliminar el ruido que se tiene en el microambiente de la incubadora son los filtros de Kalman, muy utilizado para sistemas con ruido estocástico. El motivo radica principalmente en su capacidad de selección paramétrica, junto con la inteligencia artificial, que son técnicas que se utilizan hoy en día, como son las redes neuronales que tienen la capacidad de identificar una o varias variables, mediante un set de entrenamiento que estime los pesos mediante el algoritmo de aprendizaje con la extensión de los filtros de Kalman (WEKF, Weigh Extended Kalman Filter, por sus siglas en inglés). Otra técnica utilizada son los sistemas neurodifusos, los cuales hay una combinación de la lógica difusa y las redes neuronales, para obtener un desempeño óptimo de la red neuronal utilizando el algoritmo WEKF para la estimación de los pesos y los parámetros de las funciones de membresía.

El sistema neurodifuso contiene un sistema experto regido por asociaciones lingüísticas (lógica difusa) que van a ser actualizadas por la red neuronal. Las dos técnicas antes descritas (sistemas neurodifuso y redes neuronales), se realizaron por separado para la identificación de la temperatura central, para hacer una comparación entre el sistema neurodifuso y la red neuronal, y así conocer cual converge más rápido a la temperatura central en el microambiente de la incubadora.

OBJETIVOS

OBJETIVOS GENERALES

- Identificar (conocer el comportamiento dinámico), de la temperatura del microambiente de un prototipo para un dispositivo de una incubadora neonatal, utilizando una red neuronal y un sistema neurodifuso con la ley de aprendizaje de la Extensión de Filtros de Kalman.
- Diseñar un algoritmo que sea capaz de informarnos sobre el comportamiento de la temperatura central en el interior de la incubadora, tanto pruebas de simulación, como pruebas en tiempo real.

OBJETIVOS PARTICULARES

- Desarrollar una red neuronal utilizando la regla de aprendizaje con la Extensión de Filtros de Kalman para la actualización de los pesos.
- Desarrollar un sistema neurodifuso utilizando la regla de aprendizaje con la Extensión de Filtros de Kalman para la actualización de los pesos y los parámetros de la funciones de membresía de tipo gaussiano, del sistema difuso.
- Diseñar una red neuronal y un sistema neurodifuso para las pruebas de simulación para la identificación de la temperatura central.
- Diseñar una red neuronal y un sistema neurodifuso en tiempo real para la identificación de la temperatura central, en el interior de un dispositivo de un prototipo de una incubadora neonatal.

Capítulo 1

DESARROLLO FETAL

1.1. INTRODUCCIÓN

El cuidado de la vida de un recién nacido en un hospital es de mucha importancia, ya que el recién nacido al pasar de un estado intrauterino a uno extrauterino no tiene la capacidad para adaptarse tan rápidamente a un ambiente nuevo. Los cambios fisiológicos que sufre un recién nacido pueden ser significativos primordialmente en la etapa neonatal que se extiende desde la gestación hasta los 30 días de nacimiento [1].

Existe también una subdivisión de esta etapa en dos periodos: el hebdomario, que corresponde a la primera semana, y el posthebdomario, que es del octavo día, hasta el término de la semana [5]. En esta etapa hay ajustes fisiológicos debido a los cambios que sufre el recién nacido de pasar del estado intrauterino al extrauterino, ya que en el interior del útero se tenían las condiciones ideales como puede ser la temperatura, la alimentación, que eran suministrada por la madre, además se encontraba un ambiente libre de microorganismos que puedan afectar el desarrollo del neonato, en tanto cuando surge el nacimiento,

las condiciones que se tenían en el útero de la madre cambian radicalmente y el neonato tiene que adaptarse a las condiciones que se tienen en el nuevo ambiente, en tanto que su metabolismo como sistema inmune debe de responder a tal cambio.

Son múltiples los peligros a los que se enfrenta cuando se encuentra en el útero (como pueden ser infecciones, tóxicos, hormonas, radiaciones, desnutrición , etc.), mientras que en el nacimiento corre peligro en el parto (ruptura prematura de las membranas, desprendimiento precoz de la placenta, maniobras externas al parto, etc.) [1].

En la actualidad, el nacimiento de un niño antes de las 25 semanas de edad gestacional que pesa menos de 750g presenta una variedad de complejas decisiones médicas, sociales y éticas. Aunque la prevalencia de tales nacimientos es baja, el impacto sobre los niños, sus familias, los sistemas de salud y la sociedad es importante [6].

Las causas de muerte de los recién nacidos en México son debidos a los siguientes factores que pueden ser por: prematuridad, las infecciones, la anóxia, los traumatismos de parto y las malformaciones congénitas. Para la eliminación de mortalidad para el caso de la prematuridad, se efectúan programas de prevención, principalmente para enfatizar la identificación precoz de las mujeres con embarazos de alto riesgo, educación concerniente a las causas de prematuridad, diagnóstico precoz y terapia agresiva con tocolíticos (relajantes uterinos), de la amenaza de parto prematuro [6].

1.2. PREMATUREZ

En 1902 Pierre Budin [6], señaló que no todos los recién nacidos (RN) con un peso de nacimiento (PN) menor o igual a 2.500 g eran prematuros; él describió que aquellos recién

nacidos pequeños, muy vigorosos y maduros que aunque su peso era inferior, su estancia en el útero fue más prolongada".

Este hecho llevó más tarde a hablar del RN de bajo peso de nacimiento (BPN) en aquellos con PN menor o igual a 2.500 g. pero aún sin considerar su edad gestacional (EG). La categoría de BPN resultó importante y sirvió para identificar aproximadamente el 66 % de los RN fallecidos en período neonatal, pero la identificación de BPN incluía tanto a prematuros como a recién nacidos de término; luego se observó que casi la tercera parte de los recién nacidos de bajo peso de nacimiento (RNBPN) eran de término, por lo que era necesario otro tipo de clasificación, ya que en este grupo se incluía una población muy heterogénea de RN de diversos grados de madurez, que nacen con peso semejante, pero que tienen diferentes tiempos de gestación.

Recientemente la OMS define a un recién nacido pretérmino como a todo aquel nacido antes de las 37 semanas cumplidas (259 días). Sin embargo la Academia Americana de Pediatría propone el límite a aquel recién nacido menor de 38 semanas. Esto último por el reconocido mayor riesgo de patología entre las 37 y 38 semanas.

Para tener una clasificación del RN se agregó un parámetro el cual es la edad gestacional, la cual nos indica la clasificación correcta, así como la ubicación dentro de las curvas de crecimiento intrauterino y, en base a ello, realizar un pronóstico para prevenir y/o diagnosticar, y tratar algunas de las patologías más frecuentes en cada grupo de RN.

De acuerdo a estudios observados en la curva de edad gestacional, se estableció que un recién nacido prematuro es aquel que nace antes de las 38 semanas de gestación contando desde el último ciclo menstrual fig. 1.1, [4].

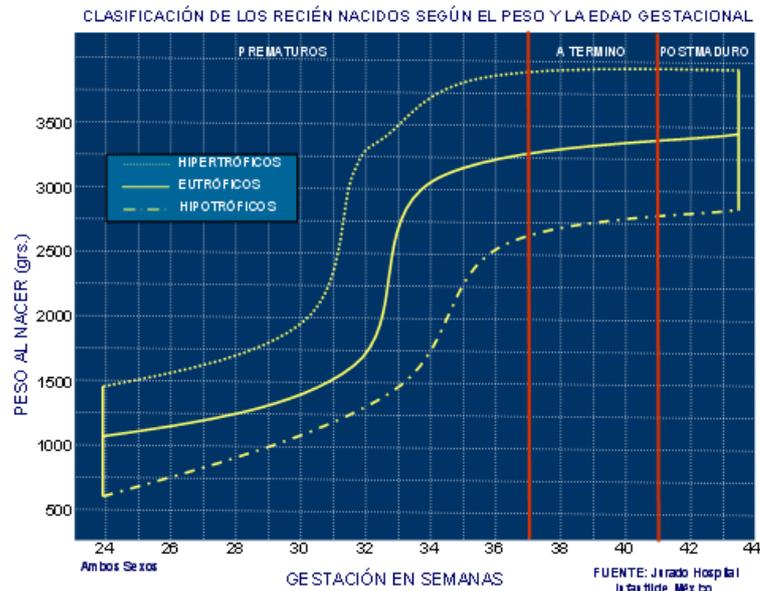


Figura 1.1: Clasificación de la edad gestacional

1.2.1. CLASIFICACIÓN DEL RN SEGÚN PESO DE NACIMIENTO

Considera solamente el peso y es totalmente independiente de la edad gestacional.

- RN macrosómico: aquel que pesa más de 4.000 g al nacer; algunos autores recomiendan límite en los 4.500g.
- RN de bajo peso nacimiento (RNBPN): peso al nacer menor de 2.500 g.
- RN de muy bajo peso nacimiento (RNMBPN): peso al nacer menor de 1.500g.
- RN diminuto: PN menor de 1.000 g.
- RN micronato o neonato fetal: RN con PN entre 500 y 750 g.

1.2.2. CLASIFICACIÓN DEL RN SEGÚN EDAD GESTACIONAL

Al recién nacido de acuerdo a la edad gestacional se le ha clasificado en tres categorías:

- Prematuro: aquel neonato nacido antes de las 38 semanas. (Criterio Academia Americana de Pediatría)

- Término: todo recién nacido de 38 a 41 semanas.

- Postérmino: 42 ó más semanas de EG.

Las características de un RN prematuro, que se distinguen al hacer un examen físico pueden ser las siguientes:

- El lactante prematuro es pequeño, (peso generalmente inferior a 2.5 Kg.).

- Piel fina, brillante y rosada, a través de la cual se ven bien las venas subyacentes.

- La cantidad de grasa subcutánea, pelo y cartílago auditivo externo suelen ser escasas.

- Su actividad espontánea y su tono son menores, las extremidades no mantienen su posición flexionada

- En varones, el escroto puede tener pocas arrugas y es posible que los testículos no hayan descendido.

- En las niñas, los labios mayores no cubren todavía los menores.

1.3. TERMORREGULACIÓN

En la termoregulación intervienen dos mecanismos: por un lado la producción endógena de calor que, aunque en nuestro prematuro tiene deficiencias, es bastante efectiva;

y por el otro la pérdida de calor.

La capacidad de mantener la temperatura corporal estable por mecanismos que regulen la pérdida y ganancia de calor es la llamada termorregulación.

El prematuro presenta una menor capacidad de conservar calor debido al escaso tejido adiposo subcutáneo, además es incapaz de generar calor por actividad motora propia y limitada la termogénesis química ya que el tejido encargado de esto, la grasa parda (tejido vascularizado de gran inervación simpática, que produce calor por reacción exotérmica), se diferencia alrededor de las 26 semanas y aumenta el porcentaje con el avance de la gestación. Por estos motivos, en el prematuro de menos de 33-34 semanas deben evitarse las pérdidas de calor y manejarse en incubadora neonatal.

1.4. LAS PÉRDIDAS DE CALOR EN EL RECIÉN NACIDO

El neonato tiene mayores pérdidas de calor que en etapas posteriores de la vida. Este hecho se debe a los siguientes factores:

- Alta relación superficie/volumen: Esta relación depende del tamaño del recién nacido y de su forma. Mientras más pequeño sea el recién nacido, más alta es esta relación y mayor es la superficie expuesta al ambiente externo por la cual se pierde calor. Este efecto se magnifica en el neonato prematuro debido a su anatomía más plana.

- Menor aislamiento cutáneo: La piel y el tejido subcutáneo son también más escasos en el recién nacido, lo que es más notorio dada su inmadurez. Los niños de muy bajo peso (menor a 1500 g.) tienen además piel muy delgada que facilita las pérdidas por evaporación.

- Control vasomotor: El organismo se aísla del frío externo por medio de la vasoconstricción cutánea. Este mecanismo está bien desarrollado en los recién nacidos a los pocos días de vida. En el caso de los prematuros este mecanismo no es tan efectivo.

- Postura corporal: La postura es un mecanismo de defensa frente al frío. Es la tendencia a "acurrucarse" que tienen todos los mamíferos de manera de disminuir la exposición de superficie corporal al medio ambiente. El recién nacido normalmente no puede cambiar su posición en flexión de las 4 extremidades. El prematuro tiene una posición con todos sus miembros extendidos y después de las 4 semanas con sus extremidades inferiores en flexión.

Los procesos físicos que determinan el intercambio calórico del neonato con el medio ambiente que le rodea son cuatro [7]:

- Conducción: Es la pérdida de calor a través de dos cuerpos en contacto con diferente temperatura. En el recién nacido es la pérdida de calor hacia las superficies que están en contacto directo con su piel: ropa, colchón, sábanas, etc.

- Radiación: Se da entre cuerpos a distancia por ondas del espectro electromagnético. El recién nacido perderá calor hacia cualquier objeto más frío que lo rodee: paredes de la incubadora, ventanas, etc. Ganará calor de objetos calientes a los que esté expuesto: rayos solares, radiadores de calefacción, fototerapia, etc.

- Convección: Es propia de los fluidos. El recién nacido pierde calor hacia el aire que lo rodea o que respira.

- Evaporación: Es la pérdida de calor por el gasto energético del paso del agua líquida a vapor de agua.

Capítulo 2

SISTEMAS DE SOPORTE DE VIDA NEONATAL

2.1. INTRODUCCIÓN

Los soportes de vida neonatal llamados también incubadoras neonatales, son el elemento más utilizado para aislar a un recién nacido prematuro o enfermo con la finalidad de brindarle una mayor oportunidad de supervivencia, ya que las nuevas condiciones ambientales que lo rodean (fuera del útero materno) no son óptimas para su desarrollo y crecimiento, debido a esto se le debe de brindar un ambiente que sustituya las condiciones que es incapaz de mantener por si mismo el neonato prematuro, de este modo se deben de diseñar contruir y desarrollar, sistemas artificiales que sustituyan las operaciones de regulación fisiológica en una forma eficiente [1].

Las incubadoras son equipos electromédicos utilizados para el mantenimiento de

la vida del recién nacido prematuro. Su función es proporcionar un ambiente termoneutral; ésto es alcanzado guardando la temperatura y la humedad relativa del aire dentro de niveles adecuados, permitiendo que el bebé mantenga la temperatura del cuerpo normal sin pérdidas metabólicas.

El ambiente controlado contribuye a un desarrollo rápido del infante y a una incidencia menor de enfermedades. Al pasar el recién nacido pretérmino del ambiente intrauterino al extrauterino, está expuesto a una diferencia de temperatura ambiental de por lo menos 10°C . El recién nacido pretérmino tiene, además, una relación superficie corporal/peso elevada, menor producción de calor mientras menor es la edad gestacional, control vasomotor deficiente, gran conductancia térmica y mínimo aislamiento térmico graso. Además las incubadoras conservan el calor corporal gracias a un ambiente cálido y a determinadas condiciones de humedad. Proporciona, además, un suministro regulable de oxígeno y reduce la contaminación del microambiente que rodea al niño.

2.2. CUNA DE CALOR RADIANTE

Los calefactores radiantes son también de uso común. La principal ventaja de este elemento es la accesibilidad al paciente para procedimientos de enfermería, médicos y de diagnóstico, sin interrumpir la fuente de calor directa al niño. Son útiles por lo tanto, en sala de parto y unidades de terapia intensiva. Los calentadores radiantes son fuentes de alta energía, por lo que requieren el uso de un servo control de piel para asegurar que el niño no es sobre calentado. La única excepción es cuando se utilizan por un tiempo breve en el período de recién nacido inmediato y con asistencia permanente. La superficie

del colchón de la cuna de calor radiante se demorará en calentarse completamente, por lo que el equipo debe encenderse anticipadamente. Con la tecnología actual, gracias al modo de precalentamiento incorporado a los equipos, es posible lograrlo sin ruido molesto de alarmas. Diversos autores han descrito aumento de las pérdidas insensibles de agua, [33], [34], [35] en niños que se mantienen en calentadores radiantes. Se debe considerar el uso de cobertores plásticos como un medio consistente de controlar estas pérdidas, así como también para reducir las pérdidas por convección. Las pérdidas de agua deben considerarse en el manejo total de un neonato que se mantiene en un calefactor radiante por un período más prolongado.

2.3. INCUBADORAS CON SERVO CONTROL

Es un mecanismo que consiste en un control automático de la temperatura de acuerdo a un punto set, fijado por el operador. Actualmente, tanto las incubadoras como los calefactores radiantes pueden ser servo controlados. Lo que significa que un sensor de temperatura envía una señal al equipo que proporciona el calor necesario para mantener la temperatura pre-fijada. El servo control, por lo tanto, puede ser de aire o de piel, dependiendo de si el lector que envía la señal es un sensor de temperatura del aire o un sensor localizado en la piel del niño. Generalmente, nos referimos a servo control cuando hablamos de un sensor en la piel. La temperatura a fijar y el sitio de ubicación de los sensores, son dos puntos críticos a considerar cuando se usa un mecanismo servocontrolado de piel. Para mantener al niño en el rango de termoneutralidad, se recomienda una temperatura abdominal de 36.2° - 36.5° C. No hay datos disponibles para prematuros de bajo peso extremo, pero

se debe considerar el uso de puntos de set más altos dado que, por las características anatómicas y fisiológicas de este recién nacido, la lectura de la temperatura cutánea está muy próxima a la temperatura central. Los sensores deben estar bien adheridos a la piel, sobre una superficie lisa, no ósea y alejada de las áreas donde hay grasa parda. El sitio recomendado es línea media abdominal, entre apéndice xifoides y el ombligo. No se debe cubrir el sensor con ropa o pañal, tampoco recostar al niño sobre el sensor. Se recomienda cubrirlo con un cobertor de aluminio que refleje las ondas infrarojas emitidas por la fuente de calor. Es importante evaluar en conjunto la temperatura de la piel del niño y la cantidad de energía requerida, para detectar cualquier problema .

2.4. VARIABLES TERMO-FÍSICAS Y FISIOLÓGICAS DE IMPORTANCIA

Las variables fisiológicas más importantes para un diagnóstico clínico de los recién nacidos son variados, principalmente las variables que más interesan a los médicos son las siguientes:

1. **Temperatura:** Establece el estado metabólico en el que se ubica el paciente. Esto se debe a que la producción y pérdida de calor está relacionada estrechamente con el empleo de las sustancias nutritivas, el nivel de hormonas que están regulando las funciones normales del organismo, etc.
2. **Frecuencia Cardíaca y Respiratoria:** El establecimiento de la periodicidad en la función pulmonar (20 ciclos por minuto) y en el ciclo de trabajo del corazón (110 latidos por minuto), demuestran el funcionamiento correcto de los sistemas fisiológicos denominados de

sostenimiento de vida (el respiratorio y el cardiovascular).

3. Humedad: Otro elemento importante en el monitoreo del neonato es la humedad, se ha encontrado que los niños prematuros atendidos en incubadoras servocontroladas con baja humedad son propensos a sufrir caídas de temperatura central y apneas más severas y frecuentes, se incrementa la pérdida de calor por evaporación y eventualmente se genera un ciclo de eventos que resulta en un decremento paradójico de la temperatura corporal cuando la de la incubadora se incrementa. Por esta razón se recomienda una humedad relativa que se encuentre en un rango del 45 al 70 % [8].

2.5. TERMONEUTRALIDAD

Un ambiente térmico neutro se define como el rango de temperatura del ambiente en la cual la tasa metabólica (consumo de oxígeno) es mínima y la termorregulación se logra sin control vasomotor. Dentro de este rango el niño está en equilibrio con el ambiente. Las investigaciones que definen la temperatura corporal normal del niño, implican el registro de la temperatura cuando se logra el estado de termoneutralidad. Aún cuando las definiciones de temperatura normal varían [6], [37].

La zona de termoneutralidad se encuentra delimitada por una temperatura crítica superior y otra inferior. La temperatura crítica superior es la temperatura del ambiente, la cual es la pérdida de calor por medio de la evaporación, mientras que la temperatura inferior es el calor metabólico máximo dentro del equilibrio térmico.

En un ambiente térmico neutro, el calor almacenado es nulo y la pérdida de calor es igual a la producción de calor metabólico.

Si un neonato prematuro se encuentra por debajo de su zona de neutralidad térmica como consecuencia de un mal control de su ambiente térmico, experimentará un incremento en el consumo de oxígeno a tasas de 2 a 3 veces mayores al requerimiento normal. En consecuencia, puede desarrollar acidosis, hipoglicemia, estado de choque y apnea, entre otras complicaciones. Por ello, es fundamental el control adecuado de la temperatura corporal en estos niños, lo cual puede lograrse con el uso de incubadoras.

2.6. GRADIENTE DE TEMPERATURA EXTERNO

Para establecer un parámetro en cuanto a la relación metabólica en el neonato se realizaron estudios [8] en los que se relacionan los comportamientos de la temperatura rectal, la temperatura de la piel, la ambiental y la diferencia entre estas dos últimas, fig. 2.1. Tales estudios mostraron que no existe ninguna correlación entre la medición de la temperatura rectal y la de la piel de los neonatos y el gasto metabólico que realizan, en tanto que la temperatura ambiental mostró una mejor correlación entre los dos parámetros pero depende de donde se ubique al neonato. En el gradiente de temperatura externo formado por la diferencia entre la temperatura de la piel y la temperatura ambiente existe una muy buena relación con el gasto metabólico representado por el volumen de oxígeno consumido. Con tales estudios y observaciones que hicieron “Se asegura que un infante de bajo peso se encuentra en la zona de termoneutralidad si la diferencia entre la temperatura superficial y la temperatura ambiente (Gradiente de Temperatura Externo) es menor que 1.5°C ”.

Basados en esta interpretación del gradiente de temperatura externo (GTE), se estableció también que la diferencia entre la temperatura subcutánea y la temperatura de

la piel (Gradiente de Temperatura Interno) tiene relación con el proceso de conducción por el cual el neonato pierde calor [14].

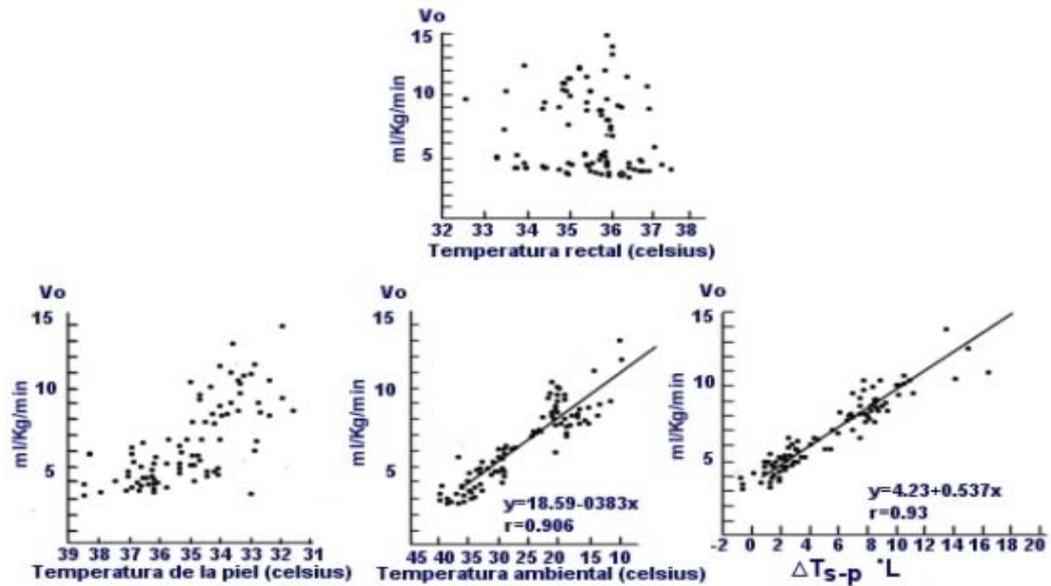


Figura 2.1: Relación de las variables térmicas de la incubadora con el metabolismo del infante

Se estableció que: “Sí el gradiente de temperatura interno (GTI) se encuentra entre 1.0° y 3.5° C, se garantiza una conductividad térmica de la piel relativamente constante.”

Un hecho importante en cuanto al GTI, es que si este es menor o igual que 0.68° C comienza la diafóresis activa en el infante a término, y se pierde la condición de termoneutralidad [9].

Capítulo 3

FILTRO DE KALMAN Y EXTENSION DE LOS FILTROS DE KALMAN DISCRETOS

3.1. INTRODUCCIÓN

El filtro de Kalman, aparecido a principios de la década de los 60's, es comparable a los trabajos realizados por Nyquist y Bode, en la década de los veinte, los cuales realizó investigaciones en el area de las comunicaciones, así como en el área de control automático. Y a los filtros de Wiener en los años treinta, que consideró el problema de estimar una señal deseada en presencia de un ruido aditivo, basándose en la señal recibida. El filtro de Wiener está limitado a sistemas lineales, con una sola variable y con sistemas estacionarios, es decir las propiedades estadísticas de la señal y el ruido se mantienen constantes, mientras que

el filtro de Kalman posibilita la estimación (predicción de una variable que no es conocida) de sistemas de muchas variables y ruidos no estacionarios, es decir, no presentan un comportamiento bien definido. Además, el filtro de Kalman fue desarrollado directamente para sistemas muestreados (en tiempo discreto), lo que permite de forma natural su implementación en una pc. Posteriormente se observó que el filtro de Kalman era una herramienta importante para sistemas lineales, de este modo surgió la necesidad de desarrollar un algoritmo con la misma capacidad de estimación que los filtros de Kalman pero para sistemas no lineales llamados Filtro de Kalman Extendido (FKE). Estos son muy empleados, ya que mayoría de las variables de la naturaleza pertenecen a sistemas no lineales, en este caso una incubadora neonatal presenta este tipo de comportamiento, además que contiene ruido browniano.

3.2. FILTROS DE KALMAN EN TIEMPO DISCRETO

Consideremos la ecuación de estado y de salida de un sistema no estacionario, con ruido de la forma:

$$x(k+1) = A(k)x(k) + B(k)u(k) + v(k)$$

$$y(k) = C(k)x(k) + \omega(k)$$

Donde las matrices $A(k)$, $B(k)$ y $C(k)$ son determinísticas y en general serán variables en los sistemas lineales variantes con el tiempo, y $v(k)$ y $\omega(k)$ son los procesos estocásticos de los ruidos del sistema y de medida respectivamente, que se consideran ruidos blancos de media

ceros e independientes y que por lo tanto cumplen:

$$\begin{aligned}
 E\{v(k)\} &= E\{\omega(k)\} = 0 & (3.1) \\
 E\{v(k)\omega^T(k)\} &= E\{\omega(k)v^T(k)\} = 0 \\
 E\{v(k)v^T(k)\} &= Q(k) \\
 E\{v(k)v^T(j)\} &= 0 \quad \forall k \neq j \\
 E\{\omega(k)\omega^T(j)\} &= R(k) \\
 E\{\omega(k)\omega^T(j)\} &= 0 \quad \forall k \neq j
 \end{aligned}$$

Las matrices de covarianza, diagonales y por lo tanto simétricas, de los ruidos del sistema $Q(k)$ (positiva semidefinida) y de medida $R(k)$ (positiva definida), son conocidas.

El ruido del sistema puede considerarse que se genera en su interior o bien que se introduce a la entrada del sistema, y el ruido de medida es el error que se comete al medir la salida, es decir, será el error que cometen los sensores al medir. La fig. 3.1 aclara estos dos conceptos:

El problema consiste en estimar el valor óptimo del vector de estado $x(k)$, basándose en las medidas ruidosas $y(0), y(1), \dots, y(k)$ que serán conocidas, además de tener en cuenta que el vector de estado estará contaminado con el ruido del sistema. Esta problemática puede abordarse de tres formas diferentes:

Predicción: Se obtiene la estimación $x(k+1)$ conociendo las medidas: $y(0), \dots, y(k)$

Filtrado: Se obtiene la estimación $x(k)$ conociendo las medidas: $y(0), y(1), \dots, y(k)$

Alisado: Se obtiene la estimación $x(k-1)$ conociendo las medidas: $y(0), y(2), \dots, y(k)$

El cual se puede observar en la fig. 3.2.

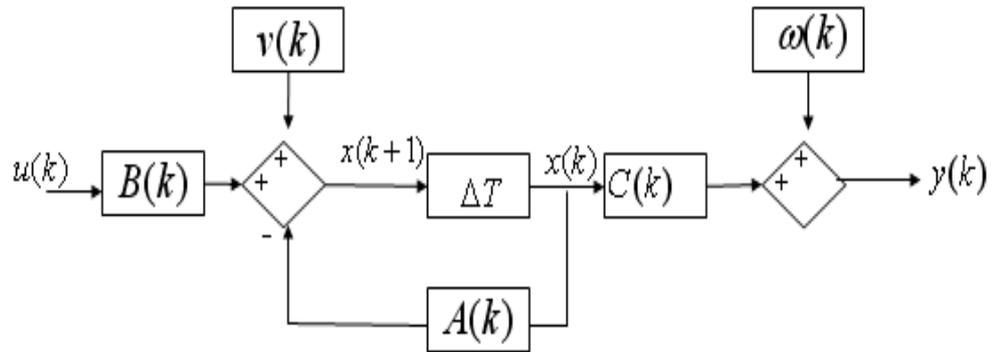


Figura 3.1: Diagrama de un sistema lineal con filtros de Kalman

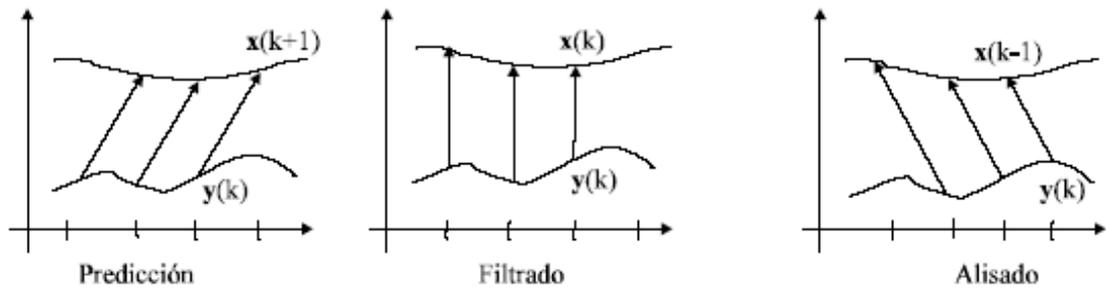


Figura 3.2: Diagrama a bloques del filtro de Kalman

El criterio para obtener el óptimo es minimizar el índice de comportamiento:

$$P(n) = E\{e(n)e^T(n)\} \quad (3.2)$$

con $n = k + 1$, $n = k$ o $n = k - 1$ según sea con predicción, filtrado o alisado. Es decir la matriz de covarianza del error $e(k)$ ha de ser mínima, estando el error definido como:

$$e(k) = x(k) - \hat{x}(k) \quad (3.3)$$

Si la matriz de covarianza $P(k)$ ha de ser mínima, cualquier forma cuadrática del tipo:

$$\alpha^T P(k) \alpha \quad (3.4)$$

también es mínima, siendo α un vector arbitrario de orden $n \times 1$. Se asume que del estado inicial $x(0)$ se conoce su esperanza matemática o valor medio:

$$E\{x(0)\} = \bar{x}(0) \quad (3.5)$$

que será un valor determinístico, y además también se conoce la matriz de covarianza del estado inicial (no del error):

$$E\{[x(0) - \bar{x}(0)][x(0) - \bar{x}(0)]^T\} = P_o \quad (3.6)$$

El estado inicial y el ruido cumplen:

$$\begin{aligned} E\{[x(0) - \bar{x}(0)]v(k)^T\} & \quad (3.7) \\ = E\{[x(0) - \bar{x}(0)]\omega(k)^T\} & = 0 \end{aligned}$$

al ser independientes y ser la media de los ruidos blancos cero.

3.2.1. FILTROS DE KALMAN CON PREDICCIÓN

Asumidas todas las condiciones anteriores, se trata aquí de determinar la estimación $\hat{x}(k+1)$, conociendo las medidas contaminadas de ruido $y(0), y(1), \dots, y(k)$, para que la matriz $P(k+1)$ de covarianza del error, en el instante $k+1$, sea mínima. La solución

encontrada por Kalman y Bucy, fue que el estimador óptimo del estado es un observador que, como ya se indicó en su momento, tiene por ecuación:

$$\begin{aligned}
 \hat{x}(k+1) &= A(k)\hat{x}(k) + B(k)u(k) \\
 &\quad + K(k) \left[y(k) - \hat{y}(k) \right] \\
 &= A(k)\hat{x}(k) + B(k)u(k) \\
 &\quad + K(k) \left[y(k) - C(k)\hat{x}(k) \right]
 \end{aligned}
 \tag{3.8}$$

El diagrama de bloques se muestra en la fig. 3.3:

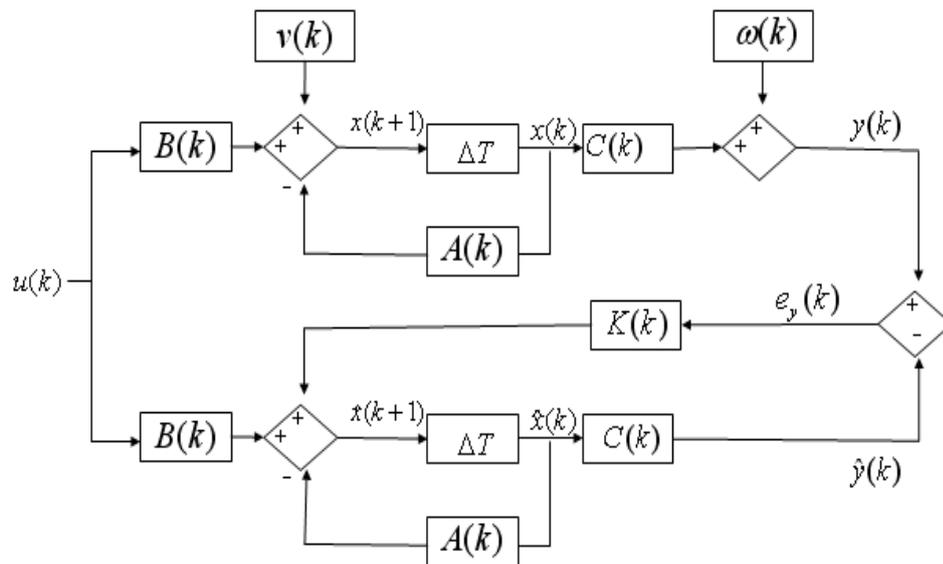


Figura 3.3: Diagrama a bloques de la estimación con filtros de Kalman

El error en el instante $k + 1$ será:

$$\begin{aligned}
e(k+1) &= x(k+1) - \hat{x}(k+1) & (3.9) \\
&= A(k)x(k) + v(k) - \{A(k)\hat{x}(k) \\
&\quad + K(k) [C(k)x(k) + \omega(k) - C(k)\hat{x}(k)]\} \\
&= A(k)x(k) + v(k) \\
&\quad - [A(k) + K(k)C(k)]\hat{x}(k) \\
&\quad - K(k) [C(k)x(k) + \omega(k)] \\
&= [A(k) - K(k)C(k)]e(k) - K(k)\omega(k) + v(k)
\end{aligned}$$

que puede sustituirse como:

$$e(k+1) = \hat{A}(k)e(k) - K(k)\omega(k) + v(k) \quad (3.10)$$

donde la matriz $\hat{A}(k)$ es determinística. El objetivo aquí es minimizar la matriz de covarianza del error $P(k+1) = E\{e(k+1)e^T(k+1)\}$ y no el índice escalar $J = \frac{1}{2}e^T(k+1)e(k+1)$ aunque posteriormente veremos que ambos están relacionados mediante la elipse de incertidumbre.

La matriz de covarianza será:

$$\begin{aligned}
P(k+1) &= E\{e(k+1)e^T(k+1)\} & (3.11) \\
&= E\{\hat{A}(k)e(k) - K(k)\omega(k) \\
&\quad + v(k)[e^T(k)\hat{A}^T(k) - \omega^T(k)K^T(k) + v^T(k)]\} \\
&= \hat{A}(k)E\{e(k)e^T(k)\}\hat{A}^T(k) \\
&\quad + E\{\hat{A}^T(k)e(k) [-\omega^T(k)K^T(k) + v^T(k)]\} \\
&\quad + E\{-K(k)\omega(k) + v(k)\}e(k)\hat{A}(k)\} \\
&\quad + K(k)E\{\omega(k)\omega^T(k)\}K^T(k) + E\{v(k)v^T(k)\} \\
&= \hat{A}(k)P(k)\hat{A}^T(k) + E\{v(k)e^T(k)\}\hat{A}^T(k) \\
&\quad + K(k)R(k)K^T(k) + Q(k)
\end{aligned}$$

y como:

$$E\{e(k)\omega^T(k)\} = E\left\{\left[\hat{A}(k-1)e(k-1) - K(k-1)\omega(k-1) + v(k-1)\right]\right\} \quad (3.12)$$

$$E\{\omega^T(k)\} \quad (3.13)$$

$$\begin{aligned}
&= \hat{A}(k-1)E\{e(k-1)\omega^T(k)\} \\
&\quad - K(k-1)E\{\omega(k)\omega^T(k)\} \\
&\quad + E\{v(k-1)\omega^T(k)\} \\
&= \hat{A}(k-1)E\{e(k-1)\omega^T(k)\}
\end{aligned}$$

y se puede colocar como:

$$\begin{aligned}
E\{e(k)\omega^T(k)\} &= \hat{A}(k-1)E\{e(k-1)\omega^T(k)\} \\
&= \hat{A}(k-1)\hat{A}(k-2)E\{e(k-2)\omega^T(k)\} \\
&= \hat{A}(k-1)\hat{A}(k-2)\dots\hat{A}(0)E\{e(0)\omega^T(k)\} \\
&= \hat{A}(k-1)\hat{A}(k-2)\dots\hat{A}(0)E\{[x(0) - \hat{x}(0)]\omega^T(k)\}
\end{aligned} \tag{3.14}$$

Escogiendo para la estimación inicial, el valor medio, es decir:

$$\hat{x}(0) = \bar{x}(0) \tag{3.15}$$

resulta:

$$E\{e(k)\omega^T(k)\} = \hat{A}(k-1)\hat{A}(k-2)\dots\hat{A}(0)E\{[x(0) - \bar{x}(0)]\omega^T(k)\} = 0 \tag{3.16}$$

ya que en las condiciones iniciales de partida habíamos supuesto:

$$E\{[x(0) - \hat{x}(0)]\omega^T(k)\} = 0 \tag{3.17}$$

Lo mismo ocurre para los términos:

$$E\{e(k)v^T(k)\} = E\{\omega(k)e^T(k)\} = 0 \tag{3.18}$$

Por lo que puede colocarse:

$$\begin{aligned}
P(k+1) &= \hat{A}(k)P(k)\hat{A}^T(k) \\
&\quad + K(k)R(k)K^T(k) + Q(k) \\
&= [A(k) + K(k)C(k)]P(k)[A(k) + K(k)C(k)]^T \\
&\quad + Q(k) + K(k)R(k)K(k)^T
\end{aligned} \tag{3.19}$$

Encontrada esta expresión pueden seguirse las técnicas de minimización:

$$\begin{aligned}
P(k+1) &= A(k)P(k)A^T(k) + A(k)P(k)C^T(k)K^T(k) \\
&\quad - K(k)C(k)P(k)A^T(k) \\
&\quad + K(k)C(k)P(k)C^T(k)K^T(k)
\end{aligned} \tag{3.20}$$

Para minimizar $P(k+1)$ su derivada con respecto a $K(k)$ se iguala a cero:

$$\begin{aligned}
\frac{dP(k+1)}{dK(k)} &= 0 = -2A(k)P(k)C^T(k) \\
&\quad + 2K(k)C(k)P(k)C^T(k) + 2K(k)R(k)
\end{aligned} \tag{3.21}$$

habiéndose tenido en cuenta que $P(k)$ y $R(k)$ son simétricas.

$$\begin{aligned}
K(k) [R(k) + C(k)P(k)C^T(k)] &= A(k)P(k)C^T(k) \\
K(k) &= A(k)P(k)C^T(k) \\
&\quad [R(k) + C(k)P(k)C^T(k)]^{-1}
\end{aligned} \tag{3.22}$$

Por medio del Hessiano puede comprobarse que este valor corresponde a un mínimo. Sustituyendo este valor en $P(k+1)$ se calcula el valor mínimo de la matriz de covarianza del error, que ha de ser positiva semidefinida:

$$P(k+1) = Q(k) + A(k)P(k)A^T(k) \quad (3.23)$$

$$-A(k)P(k)C^T(k) [R(k) + C(k)P(k)C^T(k)]^{-1}$$

$$C(k)P(k)A^T(k) \quad (3.24)$$

$$-A(k)P(k)C^T(k) [R(k) + C(k)P(k)C^T(k)]^{-1}$$

$$C(k)P(k)A^T(k) \quad (3.25)$$

$$+A(k)P(k)C^T(k) [R(k) + C(k)P(k)C^T(k)]^{-1}$$

$$C(k)P(k)C^T(k) [R(k) + C(k)P(k)C^T(k)]^{-1}$$

$$C(k)P(k)A^T(k) \quad (3.26)$$

$$+A(k)P(k)C^T(k) [R(k) + C(k)P(k)C^T(k)]^{-1}$$

$$R(k) [R(k) + C(k)P(k)C^T(k)]^{-1} C(k)P(k)A^T(k)$$

Continuando con las operaciones:

$$P(k+1) = Q(k) + A(k)P(k)A^T(k) \quad (3.27)$$

$$-2A(k)P(k)C^T(k) [R(k) + C(k)P(k)C^T(k)]^{-1}$$

$$C(k)P(k)A^T(k) \quad (3.28)$$

$$+A(k)P(k)C^T(k) [R(k) + C(k)P(k)C^T(k)]^{-1}$$

$$[R(k) + C(k)P(k)C^T(k)] [R(k) + C(k)P(k)C^T(k)]^{-1}$$

$$C(k)P(k)A^T(k) \quad (3.29)$$

$$= Q(k) + A(k)P(k)A^T(k) - 2A(k)P(k)C^T(k)$$

$$[R(k) + C(k)P(k)C^T(k)]^{-1} C(k)P(k)A^T(k)$$

$$+A(k)P(k)C^T(k) [R(k) + C(k)P(k)C^T(k)]^{-1}$$

$$C(k)P(k)A^T(k) \quad (3.30)$$

$$= Q(k) + A(k)P(k)A^T(k) - A(k)P(k)C^T(k)$$

$$[R(k) + C(k)P(k)C^T(k)]^{-1} C(k)P(k)A^T(k)$$

$$= Q(k) + A(k)P(k)A^T(k) - K(k)C(k)P(k)A^T(k)$$

Es decir:

$$P(k+1) = Q(k) + [A(k) - K(k)C(k)] P(k)A^T(k) \quad (3.31)$$

que es una ecuación del tipo Riccati. También se podrían haber seguido técnicas de poner $P(k+1)$ en forma cuadrática para obtener los mismos resultados, como se indica a continuación:

$$\begin{aligned}
P(k+1) &= [A(k) - K(k)C(k)]P(k)[A^T(k) - C^T(k)K^T(k)] & (3.32) \\
&\quad + Q(k) + K(k)R(k)K^T(k) \\
&= A(k)P(k)A^T(k) - A(k)P(k)C^T(k)K^T(k) \\
&\quad + K(k)C(k)P(k)A^T(k) \\
&\quad + K(k)C(k)P(k)C^T(k)P^T(k) \\
&= Q(k) + A(k)P(k)A^T(k) \\
&\quad + K(k)[R(k) + C(k)P(k)C^T(k)]K^T(k) \\
&\quad - K(k)C(k)P(k)A^T(k) \\
&\quad - A(k)P(k)C^T(k)K^T(k)
\end{aligned}$$

y definiendo:

$$D(k) = [R(k) + C(k)P(k)C^T(k)] \quad (3.33)$$

teniendo en cuenta que las matrices $R(k)$ y $P(k)$ son simétricas, la matriz $D(k)$ también lo es, ya que:

$$\begin{aligned}
D^T(k) &= [R(k) + C(k)P(k)C^T(k)]^T & (3.34) \\
&= R^T(k) + C(k)P^T(k)C^T(k) \\
&= R(k) + C(k)P(k)C^T(k) \\
&= D(k)
\end{aligned}$$

y sustituyendo:

$$\begin{aligned}
 P(k+1) &= Q(k) + A(k)P(k)A^T(k) & (3.35) \\
 &+ K(k)D(k)K^T(k) \\
 &- K(k)C(k)P(k)A^T(k) \\
 &- A(k)P(k)C^T(k)K^T(k)
 \end{aligned}$$

Esta expresión puede sustituirse en forma cuadrática como:

$$\begin{aligned}
 P(k+1) &= Q(k) + A(k)P(k)A^T(k) & (3.36) \\
 &+ [K(k) + A(k)P(k)C^T(k)D^{-1}(k)] \\
 &D(k) [K(k) + A(k)P(k)C^T(k)D^{-1}(k)]^T \\
 &- A(k)P(k)C^T(k)D^{-1}(k)C(k)P(k)A^T(k)
 \end{aligned}$$

lo que se comprueba desarrollando la expresión anterior:

$$P(k+1) = Q(k) + A(k)P(k)A^T(k) \quad (3.37)$$

$$\begin{aligned}
& + [K(k)D(k) - A(k)P(k)C^T(k)] \\
& [K^T(k) - D^{-1}(k)C(k)P(k)A^T(k)] \quad (3.38) \\
& - A(k)P(k)C^T(k)D^{-1}(k)C(k)P(k)A^T(k) \\
= & Q(k) + A(k)P(k)A^T(k) + K(k)D(k)K^T(k) \\
& - K(k)C(k)P(k)A^T(k) - A(k)P(k)C^T(k)K^T(k) \\
& - A(k)P(k)C^T(k)D^{-1}(k)C(k)P(k)A^T(k) \\
& - A(k)P(k)C^T(k)D^{-1}(k)C(k)P(k)A^T(k) \\
= & Q(k) + A(k)P(k)A^T(k) + K(k)D(k)K^T(k) \\
& - K(k)C(k)P(k)A^T(k) - A(k)P(k)C^T(k)K^T(k)
\end{aligned}$$

El valor $K(k)$ que hace mínima la forma cuadrática $\alpha^T P(k+1)\alpha$ cumplirá:

$$K(k) - A(k)P(k)C^T(k)D^{-1}(k) = 0 \quad (3.39)$$

$$\begin{aligned}
K(k) & = A(k)P(k)C^T(k) \\
& [R(k) + C(k)P(k)C^T(k)]^{-1}
\end{aligned}$$

Es importante notar que como:

$$\begin{aligned}
e(0) & = x(0) - \hat{x}(0) \quad (3.40) \\
& = x(0) - \bar{x}(0)
\end{aligned}$$

La matriz de covarianza del error en el instante inicial, coincide con la matriz de covarianza del vector de estado en el instante inicial, que habíamos denominado P_o ya que:

$$\begin{aligned}
 P_o &= E \{e(0)e^T(0)\} \\
 &= E \left\{ [x(0) - \bar{x}(0)] [x(0) - \bar{x}(0)]^T \right\} \\
 &= P_o
 \end{aligned} \tag{3.41}$$

3.2.2. FILTRO DE KALMAN CON FILTRADO

Se siguen asumiendo las condiciones iniciales del planteamiento del problema, que en este caso trata de determinar la estimación $\hat{x}(k)$, conociendo las medidas con ruido $y(0), y(1), y(2), \dots, y(k)$, para que la matriz $P(k)$ de covarianza del error en el instante k , sea mínima. O bien, determinar la estimación $\hat{x}(k+1)$, conociendo las medidas $y(0), y(1), y(2), \dots, y(k), y(k+1)$ para que la matriz $P(k+1)$ de covarianza del error en el instante $k+1$, sea mínima. Partiendo de la base de que el filtro de Kalman es un observador, en este caso con filtrado, la estimación óptima del vector de estado, que minimiza $P(k+1)$, está dada por las ecuaciones:

$$\begin{aligned}
 \hat{x}(k+1) &= \hat{z}(k+1) \\
 &\quad + K(k+1) \left[y(k+1) - C(k+1)\hat{z}(k+1) \right] \\
 \hat{z}(k+1) &= A(k)\hat{x}(k) \\
 &\quad + B(k)u(k) + K(k) \left[y(k) - C(k)\hat{x}(k) \right] \\
 \hat{y}(k) &= C(k)\hat{z}(k)
 \end{aligned} \tag{3.42}$$

Que corresponden a las ecuaciones de un observador del vector de estado con filtrado, es decir se estima el vector de estado en el instante $k + 1$, utilizando la medida que se ha efectuado en el propio instante $k + 1$. Esto se realiza en dos etapas. En la primera de ellas se estima $\hat{z}(k + 1)$, que es una aproximación de $x(k + 1)$, basándose en $\hat{x}(k)$ y $u(k)$. En la segunda etapa se utiliza la medida $y(k + 1)$ para mejorar $\hat{z}(k + 1)$ y obtener así la estimación final $\hat{x}(k + 1)$.

En el instante inicial:

$$\hat{x}(0) = \hat{z}(0) + K(0) \left[y(0) - C(0)\hat{z}(0) \right] \quad (3.43)$$

si escogemos:

$$\hat{z}(0) = \bar{x}(0) \quad (3.44)$$

que es un valor determinístico, entonces:

$$\hat{x}(0) = \bar{x}(0) + K(0) \left[y(0) - C(0)\bar{x}(0) \right] \quad (3.45)$$

El vector de error sería:

$$\begin{aligned} e(k + 1) &= x(k + 1) - \hat{x}(k + 1) \\ &= x(k + 1) - \hat{z}(k + 1) \\ &\quad + K(k + 1) \left[y(k + 1) - C(k + 1)\hat{z}(k + 1) \right] \end{aligned} \quad (3.46)$$

y sustituyendo $y(k + 1)$ por su valor y reagrupando:

$$\begin{aligned}
e(k+1) &= [K(k+1)C(k+1) - I] & (3.47) \\
&\quad \hat{z}(k+1) - K(k+1) \\
&\quad [C(k+1)x(k+1) + \omega(k+1) + x(k+1)] \\
&= [K(k+1)C(k+1) - I] \left[\hat{z}(k+1) - x(k+1) \right] \\
&\quad - K(k+1)\omega(k+1)
\end{aligned}$$

Esta expresión es útil para calcular el error en el instante inicial, como se indicará posteriormente. Sustituyendo las ecuaciones correspondientes puede escribirse:

$$\begin{aligned}
e(k+1) &= [K(k+1)C(k+1) - I] & (3.48) \\
&\quad \left[A(k)\hat{x}(k) - B(k)u(k) - A(k)x(k) - B(k)u(k) - v(k) \right] \\
&\quad - K(k+1)\omega(k+1) \\
&\quad [I - K(k+1)C(k+1)] A(k)e(k) \\
&\quad - [I - K(k+1)C(k+1)] v(k) - K(k+1)\omega(k+1)
\end{aligned}$$

Como $n(k)$ y $w(k)$ son ruidos blancos, una combinación lineal de ellos también lo es y se podría poner:

$$e(k+1) = [I - K(k+1)C(k+1)] A(k)e(k) + \xi(k) \quad (3.49)$$

siendo:

$$\xi(k) = [I - K(k+1)C(k+1)] A(k)E \{e(k)\} \quad (3.50)$$

El error en el instante inicial, es la siguiente:

$$e(0) = [K(0)C(0) - I] [\hat{z}(0) - x(0)] - K(0)\omega(0) \quad (3.51)$$

y la esperanza matemática sería:

$$\begin{aligned} E\{e(0)\} &= \bar{e}(0) \\ &= [K(0)C(0) - I] [\bar{x}(0) - E\{x(0)\}] \\ &= 0 \end{aligned} \quad (3.52)$$

Sustituyendo en la expresión:

$$E\{e(k+1)\} = [I - K(k+1)C(k+1)] A(k)E\{e(k)\} \quad (3.53)$$

se va obteniendo:

$$\bar{e}(1) = \bar{e}(2) = \dots = \bar{e}(k) = 0 \quad (3.54)$$

Se desea minimizar $P(k+1) = E\{e(k+1)e^T(k+1)\}$, por lo que teniendo en cuenta el valor de $e(k+1)$ resulta:

$$\begin{aligned} P(k+1) &= [I - K(k+1)C(k+1)] A(k)P(k)A^T(k) [I - K(k+1)C(k+1)]^T \\ &\quad + E\{\xi(k)\xi^T(k)\} \end{aligned} \quad (3.55)$$

ya que $\xi(k)$ y $e(k)$ son estadísticamente independientes y por lo tanto:

$$\begin{aligned} E\{e(k)\xi^T(k)\} &= E\{\xi(k)e^T(k)\} \\ &= 0 \end{aligned} \tag{3.56}$$

y además:

$$E\{e(k)e^T(k)\} = P(k) \tag{3.57}$$

Por otra parte:

$$E\{\xi(k)\xi^T(k)\} = [I - K(k+1)C(k+1)] \tag{3.58}$$

$$Q(k) [I - K(k+1)C(k+1)]^T \tag{3.59}$$

$$+K(k+1)R(k+1)K^T(k+1)$$

por lo que sustituyendo en la expresión de $P(k+1)$:

$$\begin{aligned}
P(k+1) &= [I - K(k+1)C(k+1)] & (3.60) \\
&N(k+1) [I - K(k+1)C^T(k+1)] \\
&+ K(k+1)R(k+1)K^T(k+1) \\
&= [N(k+1) - K(k+1)C(k+1)N(k+1)] \\
&[I - K(k+1)C^T(k+1)] \\
&+ K(k+1)R(k+1)K^T(k+1) \\
&= N(k+1) + K(k+1) \\
&[R(k+1) - C(k+1)N(k+1)C^T(k+1)] K^T(k+1) \\
&- N(k+1)C^T(k+1)K^T(k+1) \\
&- K(k+1)C(k+1)N(k+1)
\end{aligned}$$

Encontrada la ecuación de la matriz de covarianza se van a seguir dos técnicas para minimizarla, las de control óptimo y la de ponerla en forma cuadrática.

a) Por el criterio de la derivada.

En la expresión de la matriz de covarianza del error en el instante $k+1$ hay que tener en cuenta que $R + CNC^T$ es una matriz simétrica.

$$\begin{aligned}
P(k+1) &= N(k+1) & (3.61) \\
&+ K(k+1) [R(k+1) - C(k+1)N(k+1)C^T(k+1)] \\
&K^T(k+1) - N(k+1)C^T(k+1)K^T(k+1) \\
&- K(k+1)C(k+1)N(k+1)
\end{aligned}$$

derivando:

$$\begin{aligned} \frac{dP(k+1)}{dK(k+1)} &= 2K(k+1) [R(k+1) - C(k+1)N(k+1)C^T(k+1)] \\ &\quad - 2N(k+1)C^T(k+1) \\ &= 0 \end{aligned} \quad (3.62)$$

y despejando el valor de $K(k+1)$ que hace mínima la forma cuadrática $\alpha^T P(k+1)\alpha$ es:

$$K(k+1) = N(k+1)C^T(k+1) \quad (3.63)$$

$$[R(k+1) - C(k+1)N(k+1)C^T(k+1)]^{-1}$$

$$C(k+1)N(k+1) \quad (3.64)$$

$$= N(k+1) - K(k+1)C(k+1)N(k+1)$$

$$= [I - K(k+1)C(k+1)] N(k+1)$$

b) Poniendo $K(k+1)$ en forma cuadrática

Se define:

$$D(k) = R(k+1) - C(k+1)N(k+1)C^T(k+1) \quad (3.65)$$

puede colocarse como:

$$P(k+1) = N(k+1) \quad (3.66)$$

$$+ [K(k+1) - N(k+1)C^T(k+1)D^{-1}(k+1)] \quad (3.67)$$

$$D(k+1)K^T(k+1)$$

$$-K(k+1)C(k+1)N(k+1)$$

$$= N(k+1) +$$

$$[K(k+1) - N(k+1)C^T(k+1)D^{-1}(k+1)] D(k+1) \quad (3.68)$$

$$[K(k+1) - N(k+1)C^T(k+1)D^{-1}(k+1)]^T$$

$$-K(k+1)C(k+1)N(k+1)$$

$$+ [K(k+1) - N(k+1)C^T(k+1)D^{-1}(k+1)] D(k+1)$$

$$[K(k+1) - N(k+1)C^T(k+1)D^{-1}(k+1)]^T$$

Las matrices $D(k+1)$ y $N(k+1)$ son simétricas ya que $P(k)$, $Q(k)$ y $R(k)$ lo son y por tanto:

$$N^T(k+1) = [A(k)P(k)A^T(k) + Q(k)]^T \quad (3.69)$$

$$= A(k)P^T(k)A^T(k) + Q^T(k)$$

$$= A(k)P(k)A^T(k) + Q(k)$$

$$= N(k+1)$$

y análogamente $D(k+1)$. Sabiendo esto:

$$\begin{aligned}
& [K(k+1) - N(k+1)C^T(k+1)D^{-1}(k+1)] D(k+1) & (3.70) \\
& [K(k+1) - N(k+1)C^T(k+1)D^{-1}(k+1)]^T \\
= & [K(k+1)D(k+1) - N(k+1)C^T(k+1)] \\
& [D^{-1}(k+1)C(k+1)N(k+1)] \\
= & K(k+1)C(k+1)N(k+1) \\
& -N(k+1)C^T(k+1)D^{-1}(k+1)C(k+1)N(k+1)
\end{aligned}$$

y sustituyendo:

$$P(k+1) = N(k+1) \quad (3.71)$$

$$+ [K(k+1) - N(k+1)C^T(k+1)D^{-1}(k+1)] \quad (3.72)$$

$$D(k+1) [K(k+1) - N(k+1)C^T(k+1)D^{-1}(k+1)]^T$$

$$-N(k+1)C^T(k+1)D^{-1}(k+1)C(k+1)N(k+1)$$

Restaurando la expresión de $D(k+1)$:

$$P(k+1) = N(k+1) \quad (3.73)$$

$$+K(k+1)[R(k+1) + C(k+1)N(k+1)] \quad (3.74)$$

$$-N(k+1)C^T(k+1)[R(k+1) + C(k+1)N(k+1)C^T(k+1)]^{-1} \quad (3.75)$$

$$\begin{aligned} & [R(k+1) + C(k+1)N(k+1)] \\ & \left\{ \begin{array}{c} K(k+1) \\ -N(k+1)C^T(k+1) \\ [R(k+1) + C(k+1)N(k+1)C^T(k+1)] \end{array} \right\}^T \quad (3.76) \\ & -N(k+1)C^T(k+1)[R(k+1) + C(k+1)N(k+1)C^T(k+1)]^{-1} \\ & C(k+1)N(k+1) \end{aligned}$$

Resumiendo, puede decirse que la estimación del vector de estado en el momento actual viene dada por las ecuaciones:

$$\hat{x}(k+1) = \hat{z}(k+1) + K(k+1)[y(k+1) - C(k+1)\hat{z}(k+1)] \quad (3.77)$$

$$\hat{z}(k+1) = A(k)\hat{x}(k) + B(k)u(k)$$

donde:

$$K(k+1) = N(k+1)C^T(k+1) \quad (3.78)$$

$$[R(k+1) + C(k+1)N(k+1)C^T(k+1)]^{-1}$$

$$P(k+1) = [I - K(k+1)C(k+1)]N(k+1) \quad (3.79)$$

y

$$N(k+1) = A(k)P(k)A^T(k) + Q(k) \quad (3.80)$$

El proceso de implementación se remonta a iniciar en $t = 0$ los valores del filtro:

$$\hat{z}(0) = \bar{x}(0) \quad (3.81)$$

$$\hat{x}(0) = \bar{x}(0) + K(0) [y(0) - C(0)\bar{x}(0)] \quad (3.82)$$

$$K(0) = N(0)C^T(0) [R(0) + C(0)N(0)C^T(0)]^{-1}$$

$$P(0) = [I - K(0)C(0)] N(0) \quad (3.83)$$

Para hallar el valor de $N(0)$ hay que tener en cuenta que sustituyendo en $N(k+1)$ la expresión de $P(k)$ resulta:

$$\begin{aligned} N(k+1) &= Q(k) + A(k)N(k)A^T(k) \\ &\quad - A(k)N(k)C^T(k) [R(k) - C(k)N(k)C^T(k)]^{-1} \\ &\quad C(k)N(k)A^T(k) \end{aligned} \quad (3.84)$$

Que tiene la misma forma que la ecuación que se obtenía en el filtro de Kalman con predicción, que era:

$$\begin{aligned}
P(k+1) &= Q(k) + A(k)P(k)A^T(k) \\
&\quad - A(k)P(k)C^T(k) [R(k) - C(k)P(k)C^T(k)]^{-1} \\
&\quad C(k)P(k)A^T(k)
\end{aligned} \tag{3.85}$$

Por analogía:

$$N(0) = P_o \tag{3.86}$$

Los dos tipos de filtro de Kalman que se han presentado, pueden aplicarse también a sistemas que no tengan ruidos o perturbaciones pero se carezca de sensores adecuados.

3.2.3. ELIPSE DE DISTRIBUCIÓN DEL ERROR

La divergencia del filtro de Kalman se detecta por el crecimiento ilimitado de la matriz $P(k)$, que expresa el valor de la incertidumbre del error. Un error con incertidumbre muy elevada puede ser muy alto, y la diferencia entre el valor real y el estimado sería inaceptable.

La matriz de covarianza del error de estimación está definida por:

$$P(k) = E\{ [x(k) - \hat{x}(k)] [x(k) - \hat{x}(k)]^T \} \tag{3.87}$$

El lugar geométrico de los puntos, en los que la incertidumbre del error coincide con el error cuadrático (el doble del índice de comportamiento J) sería:

$$P(k) = [x(k) - \hat{x}(k)] [x(k) - \hat{x}(k)]^T \tag{3.88}$$

Transformando esta expresión adecuadamente, resulta:

$$\begin{aligned} P(k) \left\{ \left[x(k) - \hat{x}(k) \right]^T \right\}^{-1} &= \left[x(k) - \hat{x}(k) \right] \\ \left\{ \left[x(k) - \hat{x}(k) \right]^T \right\}^{-1} &= P^{-1}(k) \left[x(k) - \hat{x}(k) \right] \end{aligned} \quad (3.89)$$

o bien:

$$\left[x(k) - \hat{x}(k) \right]^T P^{-1}(k) \left[x(k) - \hat{x}(k) \right] = 1 \quad (3.90)$$

que es la expresión general de una superficie cuádrica. El estudio de los coeficientes de $P^{-1}(k)$ conduce, en este caso, a un elipsoide real con centro en $\hat{x}(k)$.

En el caso de un vector de estado de tres dimensiones, el elipsoide sería:

$$\begin{bmatrix} x_{1(k)} - \hat{x}_{1(k)} & x_{2(k)} - \hat{x}_{2(k)} & x_{3(k)} - \hat{x}_{3(k)} \end{bmatrix} \begin{bmatrix} \sigma_{1(k)}^2 & \sigma_{12(k)} & \sigma_{13(k)} \\ \sigma_{12(k)} & \sigma_{2(k)}^2 & \sigma_{23(k)} \\ \sigma_{13(k)} & \sigma_{23(k)} & \sigma_{3(k)}^2 \end{bmatrix}^{-1} \begin{bmatrix} x_{1(k)} - \hat{x}_{1(k)} \\ x_{2(k)} - \hat{x}_{2(k)} \\ x_{3(k)} - \hat{x}_{3(k)} \end{bmatrix} = 1 \quad (3.91)$$

y su representación se indica en la fig. 3.4:

El corte del elipsoide con el plano $x_3(k) = \hat{x}_3(k)$ es una elipse cuya proyección sobre el plano $x_1 - x_2$ tiene por ecuación:

$$\begin{bmatrix} x_1(k) - \hat{x}_1(k) & x_2(k) - \hat{x}_2(k) \end{bmatrix} \begin{bmatrix} \sigma_1^2(k) & \sigma_{12}(k) \\ \sigma_{12}(k) & \sigma_2^2(k) \end{bmatrix} \begin{bmatrix} x_1(k) - \hat{x}_1(k) \\ x_2(k) - \hat{x}_2(k) \end{bmatrix} = 1 \quad (3.92)$$

Como puede comprobarse fácilmente haciendo $x_3(k) - \hat{x}_3(k) = 0$ en la expresión del elipsoide.

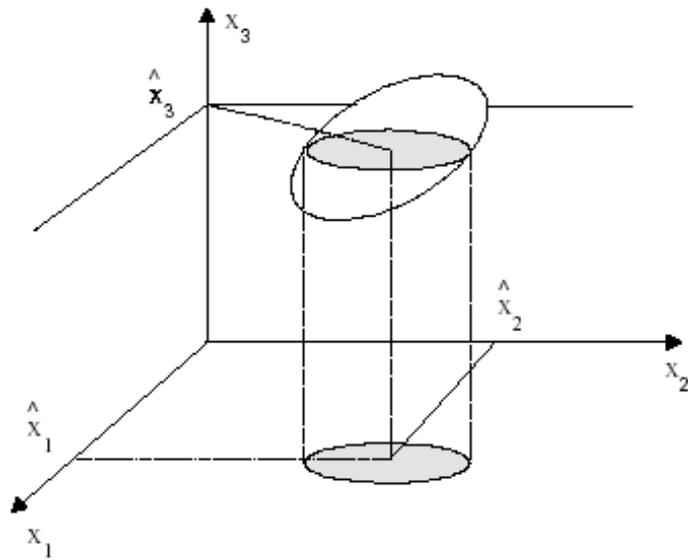


Figura 3.4: Elipse de distribución del error

Esta última elipse, centrada en $[\hat{x}_1(k), \hat{x}_2(k)]$ representa la elipse de incertidumbre de la estimación. Se ha demostrado que la probabilidad de que el vector de estado real se encuentre en el interior de esta elipse es aproximadamente del 50 %.

El hecho de que $\sigma_{12}(k) \neq 0$ indica que existe una dependencia entre las coordenadas x_1 y x_2 , por lo que cualquier mejora en la estimación de una de ellas, mejorará también la estimación de la otra.

Para representar la forma reducida (centrada en el origen y con los ejes coincidentes con los ejes de coordenadas) de la elipse que genera la matriz $P(k)$ se partiría de la ecuación general de la cónica:

$$[x_1 \ x_2 \ t] \begin{bmatrix} \begin{bmatrix} P_{11}(k) & P_{11}(k) \\ P_{11}(k) & P_{11}(k) \end{bmatrix}^{-1} & 0 \\ 0 & -1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ t \end{bmatrix} = 0 \quad (3.93)$$

o bien:

$$[x_1 \ x_2 \ t] D \begin{bmatrix} x_1 \\ x_2 \\ t \end{bmatrix} = 0 \quad (3.94)$$

Como el determinante de la matriz D es distinto de cero, la cónica no es degenerada (no cambia de forma).

Además el adjunto D_{33} de la matriz D es positivo por lo que la curva es una elipse, y como el producto del elemento d_{11} por el valor del determinante de la matriz D es negativo la elipse es real.

La ecuación reducida de la cónica es:

$$\lambda_1 x_1^2 + \lambda_2 x_2^2 + \frac{D_{33}}{|D|} = 0$$

Siendo λ_1 y λ_2 las raíces de la ecuación característica:

$$|\lambda I - P| = 0 \quad (3.95)$$

Operando para poner la ecuación de la forma:

$$\frac{x_1^2}{a^2} + \frac{x_2^2}{b^2} = 1 \quad (3.96)$$

El valor de los semi-ejes resulta:

$$\begin{aligned} a &= \sqrt{-\frac{D_{33}}{\lambda_1 |\mathbf{D}|}} \\ b &= \sqrt{-\frac{D_{33}}{\lambda_2 |\mathbf{D}|}} \end{aligned} \quad (3.97)$$

Cuanto menores sean los ejes de la elipse, mayor será la seguridad en la estimación. Cuando el filtro diverge el tamaño de la elipse de incertidumbre crece con el tiempo.

Tres posibles fuentes de divergencia del filtro de Kalman serían:

- a) Que el sistema no sea observable
- b) Errores de modelado
- c) Errores numéricos debidos al formato del procesador digital

Si no se cumple la condición de observabilidad es que un subconjunto de estados del sistema no es recuperable u observable por el filtro de Kalman, lo que redundaría en un error creciente en la estimación de dicho subconjunto de variables de estado; es decir los correspondientes elementos de la matriz de covarianza $P(k)$ crecen indefinidamente, llegando a desestabilizar el filtro. La única forma de evitar esta divergencia es ampliando el número de sensores, hasta conseguir que la nueva matriz de medida u observación C haga al sistema observable.

Cuando no se modela correctamente la dinámica del sistema y el ruido, la matriz de covarianza $Q(k)$ de las perturbaciones del sistema, o la matriz de covarianza $R(k)$ del

ruido de medida, aparecerán inevitablemente errores en la estimación del filtro. Sin duda, los errores más graves son debidos a la dinámica del sistema, ya sea porque el conjunto de ecuaciones no refleja el comportamiento real del sistema o porque los coeficientes del modelo, es decir la matriz A , no sean los correctos. Podría realizarse un estudio del filtro de Kalman en el dominio de la frecuencia, y se vería que la respuesta en frecuencia del filtro de Kalman depende intimamente del modelo de la planta y del modelo del ruido y lo hace de una forma compleja. A pesar de ello, fácilmente se observaría que el filtro de Kalman tiene ceros de transmisión, en los polos del modelo de ruido. Es decir, elimina el ruido de forma óptima.

Los errores numéricos provienen de la implementación del filtro de Kalman en un procesador digital.

Son especialmente peligrosos en una aplicación on-line, dado el carácter recursivo del algoritmo y al formato de los datos que no pueden ser de alta precisión para economizar tiempo de cómputo. La principal fuente de errores proviene de la matriz de covarianza $P(k)$, cuando por motivos del formato y de la aritmética del computador pierde la naturaleza de matriz definida positiva. Para evitar los posibles errores numéricos interesa:

- Emplear el formato de datos más potente.
- No utilizar nunca formatos de coma fija.
- Tener cuidado con la propagación de la matriz $P(k)$, que puede llegar a rozar la condición de semidefinida positiva al hacerse algunos elementos de la diagonal principal muy próximos a cero. En estos casos conviene sumar unos términos ficticios a la diagonal principal, o al menos a los términos que tienden a cero.

- Mantener siempre la propiedad de simetría de la matriz $P(k)$.
- Lo más aconsejable es calcular únicamente los términos de la parte triangular superior y rellenar el triángulo simétrico sin calcularlo.

3.3. EL FILTRO DE KALMAN EXTENDIDO

Normalmente, el proceso a estimar o la ecuación de medición son no lineales. Debe hacerse, por tanto, una aproximación a este caso. Un filtro de Kalman que linealiza en torno a la media y a la covarianza actual se denomina un Filtro de Kalman Extendido (FKE).

Ahora el proceso vuelve a tener un vector de estado:

$$x(k+1) = f(x(k), u(k), \omega(k)) \quad (3.98)$$

Con una medición o salida:

$$d(k) = h(x(k)) + v(k) \quad (3.99)$$

Donde las variables aleatorias $\omega(k)$ y $v(k)$ representan, como antes, el ruido de media cero del proceso y de la medida, respectivamente (con matrices de covarianza $Q(k)$ y $R(k)$). Las funciones f y h son funciones no lineales que relacionan el estado en el instante t con el estado en el instante $k+1$ y con la medición $d(k)$, respectivamente.

Mediante la linealización de las ecuaciones de estado y de medición se llega a una serie de ecuaciones equivalentes a las del caso lineal. Así, la estimación a priori del estado se aproxima ahora haciendo:

$$\hat{x}^-(k) = f(\hat{x}(k-1), u(k-1)) \quad (3.100)$$

y la covarianza del error a priori se calcula con:

$$P^-(k) = A(k-1)P(k-1)A^T(k-1) + X(k-1)Q(k-1)X^T(k-1) \quad (3.101)$$

Donde A y X son matrices nuevas. La matriz A se define ahora como la matriz de derivadas parciales (jacobiano), de f respecto al estado:

$$A(k) = \begin{bmatrix} \frac{\partial f_1}{\partial x_1}(k) & \frac{\partial f_1}{\partial x_2}(k) & \dots & \frac{\partial f_1}{\partial x_n}(k) \\ \frac{\partial f_2}{\partial x_1}(k) & \frac{\partial f_2}{\partial x_2}(k) & \dots & \frac{\partial f_2}{\partial x_n}(k) \\ \dots & \dots & \dots & \dots \\ \frac{\partial f_n}{\partial x_1}(k) & \frac{\partial f_n}{\partial x_2}(k) & \dots & \frac{\partial f_n}{\partial x_n}(k) \end{bmatrix} \quad (3.102)$$

Donde se ha abreviado $f_n(k)$ por $f_n(\hat{x}(k), u(k))$.

Por otra parte, W es la matriz de derivadas parciales de f respecto al ruido:

$$W(k) = \begin{bmatrix} \frac{\partial f_1}{\partial \omega_1}(k) & \frac{\partial f_1}{\partial \omega_2}(k) & \dots & \frac{\partial f_1}{\partial \omega_n}(k) \\ \frac{\partial f_2}{\partial \omega_1}(k) & \frac{\partial f_2}{\partial \omega_2}(k) & \dots & \frac{\partial f_2}{\partial \omega_n}(k) \\ \dots & \dots & \dots & \dots \\ \frac{\partial f_n}{\partial \omega_1}(k) & \frac{\partial f_n}{\partial \omega_2}(k) & \dots & \frac{\partial f_n}{\partial \omega_n}(k) \end{bmatrix} \quad (3.103)$$

La matriz de ganancia se obtiene en el filtro extendido de Kalman a partir de la ecuación 3.104:

$$K(k) = P^-(k)H^T(k)(H(k)P^-(k)H(k)^T + V(k)R(k)V^T(k))^{-1} \quad (3.104)$$

Donde H es el jacobiano de las derivadas parciales de h respecto al estado:

$$H(k) = \begin{bmatrix} \frac{\partial h_1}{\partial x_1}(k) & \frac{\partial h_1}{\partial x_2}(k) & \dots \frac{\partial h_1}{\partial x_n}(k) \\ \frac{\partial h_2}{\partial x_1}(k) & \frac{\partial h_2}{\partial x_2}(k) & \dots \frac{\partial h_2}{\partial x_n}(k) \\ \dots & \dots & \dots \\ \frac{\partial h_m}{\partial x_1}(k) & \frac{\partial h_m}{\partial x_2}(k) & \frac{\partial h_m}{\partial x_n}(k) \end{bmatrix} \quad (3.105)$$

Donde se ha abreviado $h_m(k)$ por $h_m(\hat{x}^-(k))$ y V es la matriz de derivadas parciales de f respecto v :

$$V(k) = \begin{bmatrix} \frac{\partial h_1}{\partial v_1}(k) & \frac{\partial h_1}{\partial v_2}(k) & \dots \frac{\partial h_1}{\partial v_n}(k) \\ \frac{\partial h_2}{\partial v_1}(k) & \frac{\partial h_2}{\partial v_2}(k) & \dots \frac{\partial h_2}{\partial v_n}(k) \\ \dots & \dots & \dots \\ \frac{\partial h_m}{\partial v_1}(k) & \frac{\partial h_m}{\partial v_2}(k) & \frac{\partial h_m}{\partial v_n}(k) \end{bmatrix} \quad (3.106)$$

Donde otra vez se ha escrito $h_m(k)$ por $h_m(\hat{x}^-(k))$

La estimación a posteriori del estado utiliza también aquí K para ponderar la diferencia entre la medición real y una predicción de la medida:

$$\hat{x}^-(k) = \hat{x}(k) + K(k) \left[d(k) - h(\hat{x}^-(k)) \right] \quad (3.107)$$

Finalmente, la covarianza del error tiene una forma similar a la del caso lineal, aunque debe tenerse en cuenta que ahora $H(k)$ se calcula de manera diferente al caso lineal:

$$P(k) = (I - K(k)H(k))P^-(k) \quad (3.108)$$

La operación básica del FKE se puede resumir en los siguientes pasos. En primer lugar, se proyectan las estimaciones del estado y de la covarianza del error del instante k al $k + 1$. Después ha de hacerse uso de estas nuevas estimaciones a priori para obtener unas ecuaciones corregidas al considerar la medición de $d(k)$, $R(k)$ y $Q(k)$ que son parámetros ajustables del algoritmo.

3.4. ALGORITMO DE APRENDIZAJE BASADO EN LOS FILTROS DE KALMAN

La Extensión de los Filtros de Kalman (EFK) aproxima la estimación de los parámetros de un sistema dinámico y tiene un número considerable de aplicaciones reportados en [39], [40]. La EFK basado en el algoritmo de aprendizaje para los pesos de una red neuronal con capas ocultas fue estudiado primero por Singhal y Wu (1989). Recientemente, Rutck et al. (1992) y Chandra (1994) estudiaron el EFK para el aprendizaje del perceptron multicapa, y también ellos estudiaron la conexión entre el algoritmo de Backpropagation y la EFK. Algunos algoritmos de la descomposición de la EFK se derivan en esta sección para el desempeño del aprendizaje de los pesos de la red neuronal feedforward multicapa (MFNN por sus siglas en inglés). Las dimensiones del vector de pesos, que consisten de todos los pesos de la MFNN, es usualmente muy grande, para tener una eficiente aproximación y para reducir los cálculos y los requerimientos de almacenamiento de el algoritmo de aprendizaje el vector de pesos es descompuesto en una serie de subvectores.

Considere el problema para la estimación de los parámetros para un sistema no lineal mostrado en la ecuación 3.109.

$$\begin{aligned}
y(k) &= f(w, x(k)) + v(k) \\
&= f(w_{a1}^{(1)}, \dots, w_{an}^{(1)}, \dots, w_1^M, w_{nM}^M x(k)) + v(k)
\end{aligned} \tag{3.109}$$

Donde $y(k)$ es el vector de salida de la red al tiempo k con dimensiones $n_M \times 1$, $f(\cdot)$ es un vector que depende de la entrada y de los pesos de la red con dimensiones $n_M \times 1$, w representa el vector de todos los pesos y los umbrales de la red neuronal, $v(k)$ es un vector que simula el ruido blanco con una matriz de covarianza $R(k)$ debido al modelo del error y los componentes diagonales de la matriz $R(k)$ son iguales o insignificantes, menores que 1. Suponga que $x(k)$ es una entrada del modelo, $y_d(k)$ es un vector de salida deseada del modelo con dimensiones $n_M \times 1$ de la MFNN, y $w_j^i(k)$ es un vector de pesos al tiempo k . La propuesta de aprendizaje de los pesos de la MFNN es estimar el vector de pesos w_j^i para que sea semejante a la salida $y(k)$ de la MFNN para que siga una trayectoria dada por la salida deseada $y_d(k)$, con un error que converja a cero, cuando $k \rightarrow \infty$. Por lo tanto, si los pesos de una MFNN son tomados en cuenta como los parámetros no conocidos de un sistema de entrada-salida, el problema de aprendizaje de los pesos de la MFNN se puede expresar como los parámetros del proceso de identificación de el sistema no lineal.

La función no lineal $f(w(k), x(k))$ puede ser linealizada por el vector de los parámetros estimados $w_j^i(k-1)$ de la siguiente manera.

$$\begin{aligned}
f(w(k), x(k)) &\equiv f(w(k-1), x(k)) \\
&+ \sum_{i=1}^{M-1} \sum_{j=1}^n H_j^i(k) [w_j^i(k) - w_j^i(k-1)]
\end{aligned} \tag{3.110}$$

Donde la matriz jacobiana $H_i^j(k)$ de dimensiones $n_M \times (n_j + 1)$ es obtenida por

$$H_i^j(k) = \frac{\partial f(w(k-1), x(k))}{\partial w_j^i(k-1)} \quad (3.111)$$

El vector de la salida del error tiene dimensiones de $1 \times n_M$ entre la salida deseada y la salida actual de la red usando el vector de parámetros estimados $w_j^i(k-1)$ es definido como.

$$e(k) = y_d(k) - f(w(k-1), x(k)) \quad (3.112)$$

Es conocido que a través de la covarianza y la información implementada de los filtros Kalman son algebraicamente equivalentes, la covarianza de los filtros es más popular, debido a esto es relativamente más simple computacionalmente cuando las dimensiones de la salida es considerablemente pequeña que las dimensiones de los parámetros estimados. De este modo, para el problema del aprendizaje de los pesos, la Descomposición de la Extension de los Filtros de Kalman (DEFK) puede ser fácilmente obtenida de la EFK que formuló Jazwinski, (1970) de la siguiente manera.

$$\begin{aligned}
A(k) &= \left[R(k) + \sum_{\alpha,\gamma=1}^M \sum_{\beta=1}^{n_\alpha} \sum_{i=1}^{n_\beta} H_\beta^\alpha(k) P_{\beta\lambda}^{\alpha\gamma}(k-1) (H_i^\gamma(k))^T \right]^{-1} \quad (3.113) \\
G_j^i(k) &= \sum_{\alpha=1}^M \sum_{\beta=1}^{n_\alpha} P_{\beta\lambda}^{\alpha\gamma}(k-1) (H_\beta^\alpha(k))^T A(k) \\
P_{jm}^{il}(k) &= P_{jm}^{il}(k-1) - \sum_{\alpha=1}^M \sum_{\beta=1}^{n_\alpha} G_j^i(k) (H_\beta^\alpha(k)) P_{\beta m}^{\alpha l}(k-1) \\
w_j^i(k) &= w_j^i(k-1) + G_j^i(k) e(k) \\
1 &\leq i \leq M, 1 \leq j \leq n_i, 1 \leq l \leq M, 1 \leq m \leq n_i
\end{aligned}$$

Donde $A(k)$ es una matriz de $n_M \times n_M$, $G_j^i(k)$ es una matriz de la ganancia del filtro con dimensiones de $(n_i+1) \times n_M$ ($1 \leq i \leq M-1$), y $P_{jm}^{il}(k) = (P_{jm}^{il}(k))^T$ es la matriz del error de la covarianza y tiene dimensiones de $(n_i+1) \times (n_i+1)$ entre la estimación de $w_j^i(k)$ y $w_m^l(k)$. Una comparación del EKF y DEKF muestran que siempre los requerimientos de almacenamiento para las matrices del error de covarianza $P_{jm}^{il}(k)$ son lo mismo, el algoritmo de aprendizaje a cada paso requiere $O\left(\left(\sum_{n_s=2}^M n_s(n_{s-1}+1)\right)^2\right)$ almacenamiento para la matriz $P_{jm}^{il}(k)$, el algoritmo DEKF evita la multiplicación de matrices con dimensiones altas en cada iteración.

El algoritmo de aprendizaje con la descomposición de los filtros de Kalman, si las matrices del error de covarianza $P_{jm}^{il}(k)$ de la estimación $w_j^i(k)$ y $w_m^l(k)$ no son tomados en cuenta en el procedimiento iterativo de la formulación neural-descomposición EKF, o NDEKF, puede ser obtenido de la DEKF como sigue:

$$\begin{aligned}
A(k) &= \left[R(k) + \sum_{\alpha,\gamma=1}^M \sum_{\beta=1}^{n_\alpha} H_\beta^\alpha(k) P_\beta^\alpha(k-1) (H_\beta^\alpha(k))^T \right]^{-1} \\
G_j^i(k) &= P_j^i(k-1) (H_j^i(k))^T A(k) \\
P_j^i(k) &= (I - G_j^i(k) H_j^i(k)) P_j^i(k-1) \\
w_j^i(k) &= w_j^i(k-1) + G_j^i(k) e(k) \\
1 &\leq i \leq M, 1 \leq j \leq n_i
\end{aligned} \tag{3.114}$$

Donde $P_j^i(k)$ son matrices del error de covarianza con dimensiones de $(n_i+1) \times (n_i+1)$, $w_j^i(k)$ es el error de varianza de estimación de los pesos. Es obvio que el algoritmo NDEKF requiere de $O\left(\left(\sum_{n_s=2}^M n_s(n_{s-1}+1)\right)^2\right)$ almacenamiento para la matriz $P_j^i(k)$. Por lo tanto, los cálculos y el requerimiento de almacenamiento de el NDEKF son significativamente menores que la DEKF. Fuera de los costos de esta reducción es un decremento en la precisión del algoritmo de aprendizaje recursivo.

Es bien conocido que el algoritmo de aprendizaje NDEKF es un tipo de algoritmo de descomposición parcial, en el cual, la iteración entre la neurona de cada capa es considerado invariante en el proceso de actualización, además, en el orden para archivar la descomposición completa del aprendizaje para cada peso de la MFNN, una simple y natural extensión basado en las correspondientes características del algoritmo de Backpropagation es simulado para el error de covarianza $P_j^i(k)$ de los pesos $w_j^i(k)$ y $w_m^l(k)$ son despreciados en el algoritmo NDEKF. Otra aproximación de la descomposición de los pesos EKF o WDEKF, puede ser derivada de la formulación NDEKF de la siguiente manera:

$$\begin{aligned}
w_{js}^i(k) &= w_{js}^i(k-1) + \sum_{v=1}^{n_M} \mu_{j_{sv}}^i(k) h_{j_{sv}}^i(k) e_v(k) & (3.115) \\
\mu_{j_{sv}}^i(k) &= p_{js}^i(k-1) a_v(k) \\
p_{js}^i(k) &= \left(1 - \sum_{v=1}^{n_M} \mu_{j_{sv}}^i(k) (h_{j_{sv}}^i(k))^2 \right) p_{js}^i(k-1) \\
a_v(k) &= \frac{1}{r_v(k) + \sum_{i=1}^M \sum_{j=1}^{n_i} \sum_{s=1}^{n_{i-1}+1} (h_{j_{sv}}^i(k))^2 p_{js}^i(k-1)} \\
e_v(k) &= y_{dv}(k) - f_v(w(k-1), x(k)) \\
h_{j_{sv}}^i(k) &= \frac{\partial e_v(k)}{\partial w_{js}^i(k-1)} \\
1 &\leq v \leq n_M, 1 \leq i \leq M, 1 \leq j \leq n_i, 1 \leq s \leq n_{i-1} + 1
\end{aligned}$$

Donde $\mu_{j_{sv}}^i(k)$ es la velocidad de aprendizaje de los pesos $w_{js}^i(k)$ al tiempo k con respecto a el error de la salida v th, $a_v(k)$ son los ajustes de los parámetros centrales, $p_{js}^i(k)$ son las varianzas de los pesos $w_{js}^i(k)$ y todas las variables iterativas son escalares.

Las ventajas asociadas con los cálculos y almacenamiento, la otra atracción de el WDEKF es que puede ser integrado dentro de la correspondiente estructura de la red similar al algoritmo convencional backpropagation. El algoritmo WDEKF es, en el transcurso computacionalmente más complejo que el algoritmo del gradiente descendente. De cualquier modo, la velocidad de convergencia del WDEKF es mucho mas rápido que el algoritmo backpropagation. Estas características del algoritmo WDEKF son muy usados para sistemas de control basados en redes neuronales.

La ecuación 3.115 es similar a la ecuación de la actualización de los pesos de el convencional algoritmo de aprendizaje de backpropagation (Narendra and Parthasarathy,

1990; Rumelhart and Mc Celland, 1986), el cual es un algoritmo de aprendizaje con una velocidad de aprendizaje constante. En el curso de las simulaciones numéricas con el algoritmo convencional Backpropagation, debe ser claro que la velocidad de aprendizaje μ es crítico. Si μ es muy grande, el algoritmo no convergera, mientras si μ es muy pequeña, la convergencia será muy baja para ser práctico. El algoritmo de aprendizaje WDEKF resulta este dificultoso por usar una velocidad de aprendizaje variable el cual está adaptado para buscar el valor óptimo y ajustarse en cada instante. En otras palabras, el WDEKF puede ser tratado así como un tipo de algoritmo backpropagation con una velocidad de aprendizaje óptima. Además es fácil demostrar que el WDEKF se reduce al algoritmo de backpropagation, cuando $p_{js}^i(k) \equiv \text{constante}$ y $a_v(k) \equiv \text{constante}$ para toda k , este es un factor descubierto por Et. al. (1992) and Chandran (1994).

Capítulo 4

LÓGICA DIFUSA

4.1. INTRODUCCIÓN

Las ideas de incertidumbre y ambigüedad llevaron en 1964 al Doctor Lotfi Zadeh a establecer un principio de incompatibilidad el cual establece que la complejidad y la ambigüedad (imprecisión), están inversamente relacionadas. Esto significa que entre más se aprende de un sistema, su complejidad decrece y nuestro entendimiento aumenta. Esto le llevó a la publicación del artículo “Conjuntos Difusos” en 1965 [17].

Después de la aparición del artículo de Conjuntos Difusos, surgieron una infinidad de publicaciones y aplicaciones en ingeniería, ciencias, economía, medicina, psicología, y en otros campos en general.

Básicamente la lógica difusa es usada para representar conocimientos imprecisos e inciertos, lo que suministra un medio efectivo que describe el comportamiento de sistemas que son complejos o no son fáciles de analizar.

Zadeh argumentó que para poder automatizar un sistema utilizando la lógica di-

fusa, podría ser impedido por una barrera entre el razonamiento humano y la programación en el ordenador. Debido a esta incapacidad de decidir que es lo correcto o lo incorrecto el propuso a la lógica difusa como una solución a este problema.

La primera aplicación de la lógica difusa en el campo de la ciencia médica data de principios de los años 1965-1975. En el año de 1968, L.A. Zadeh presenta el primer artículo llamado "Fuzzy set", este trata sobre la posibilidad de desarrollar aplicaciones de lógica difusa en biología.

Después de la publicación del artículo "Fuzzy set" surgieron nuevos artículos que fueron publicados en el año de 1980 sobre aplicaciones de sistemas difusos en medicina. Con la publicación de estos artículos, los cuales fueron los años pioneros en aplicaciones en medicina con lógica difusa. La primera aplicación reportada, iba dirigida a la evaluación de síntomas y el modelaje de razonamiento médico. Consecuentemente, surgieron una serie de aplicaciones como en psicología y el modelaje de procesos de diagnóstico médico. Después en 1975, se desarrollaron aplicaciones en el diagnóstico (decisión), en sistemas de soporte y sistemas expertos para medicina. Los artículos publicados en la primera década de la teoría de sistemas difusos también establecieron la fundación para más avances en la aplicación, tal así se clasificaron (primer artículo por E.t Lee, 1975), posteriormente (Saridis 1975), procesamiento de imágenes en medicina, terapia, etc.

Como resultado de esto, la lógica difusa se usa actualmente sobre cualquier área de aplicación de mando inteligente o procesamiento de datos, así como en procesos químicos y procesos biológicos.

4.2. LÓGICA DIFUSA

Los desarrollos que han surgido en la aplicación de la lógica difusa para el control de sistemas es muy importante para la automatización de procesos que requieren una supervisión constante como es el caso de la ingeniería biomédica. Los controladores difusos tienen la ventaja de basarse en decisiones o reglas que son impuestas por el experto. Esto se puede entender mejor si comparamos un sistema difuso con una terapia o un tratamiento que propone el médico, este tiene que decidir que dosis y por cuanto tiempo se le debe de suministrar a un paciente para una mejor y rápida recuperación. Respecto a el control de las incubadoras neonatales tiene mucha influencia ya que se debe de tener un microambiente controlado, tanto la temperatura como la humedad y el flujo de aire.

4.2.1. CONTROLADOR DIFUSO

Para diseñar un controlador difuso se debe contar con una gran cantidad de información acerca de cómo un constructor de decisiones actuaría en lazo cerrado con el sistema. Muchas veces, esta información proviene de un operador humano que ejecuta la acción de control, pero en otras ocasiones es necesario adquirir tal información de manera propia, entendiendo el funcionamiento del sistema en estudio. Toda esta información debe colocarse en un arreglo de sentencias del tipo “Si..., entonces..”, es decir “Si la salida de la planta con respecto a la señal de referencia se está comportando de cierta manera, “entonces” la entrada a la planta debe tener este comportamiento”

La lógica difusa aplicada a la ingeniería de control, o también llamado control difuso, provee una metodología formal para representar, manipular e implementar el conocimien-

to heurístico humano acerca de cómo controlar un sistema. [10].

La estructura de un sistema de control difuso fig. 4.1, tiene cuatro componentes principales:

- La base de reglas. Contiene el conocimiento, en la forma de un conjunto de reglas, de cómo controlar de la mejor manera al proceso.
- El mecanismo de inferencia que evalúa cuales de las reglas son relevantes al momento, y decidir entonces cual es la acción de control que debe aplicarse a la planta.
- La interfase de “Fuzificación”, que modifica la entrada al controlador para que esta pueda ser entendida por el mecanismo de inferencia.
- La interfase de “Defuzificación” que convierte las conclusiones alcanzadas por el mecanismo de inferencia, en acciones de control para la planta.

La estructura de lógica difusa, y los componentes básicos de un sistema difuso en donde los conjuntos clásicos U_i y Y_i son llamados el universo del discurso para u_i y y_i respectivamente. Un conjunto clásico es aquel que solo tiene pertenencia en dos valores o condiciones, por ejemplo negro o blanco, o 1 si pertenece, y si no 0. La teoría de logica difusa quita esta limitacion de pertenencia parcial a un conjunto, y lo convierte en un grado de asociación al conjunto. De este modo en la lógica difusa se permiten grados de pertenencia en un rango de 0 a 1. de esta manera se puede describir una transición suave y gradual, de la región externa del conjunto a la region interna.



Figura 4.1: Estructura del controlador difuso

Funciones de membresía

Un conjunto difuso es definido como una función que mapea objetos a su correspondiente valor de pertenencia en el conjunto. esta función es llamada "función de membresía", la cual esta asociada a una serie de datos u objetos. Las series de datos u objetos se llaman "Universo de discurso".

En particular, para un sistema de control, $u_i \in U_i$ con $i = 1, 2, 3, \dots, n$ y $y_i \in Y_i$ con $i = 1, 2, \dots, m$, las cuales definen las entradas y salidas correspondientes. Las formas de las funciones de membresías mas comunes utilizadas en sistemas difusos son de tipo triangulares, gaussianas (es la más utilizada para los sistemas neurodifusos), tipo S, tipo Z, trapezoidales, etc.

Fuzificación

El proceso de la fuzificación consiste en una transformación de un dato o de un conjunto clásico a su correspondiente conjunto difuso, por tanto, denotemos por U_i^* , el conjunto de todos los posibles conjuntos difusos que pueden ser definidos por U_i y dado $u_i \in U_i$, denotemos la transformación difusa de un conjunto difuso por A_i^{fuz} , el cual es definido en el universo. La transformación de un conjunto clásico a un conjunto difuso se produce mediante el uso del operador de fuzificación \mathcal{F} , [10], definido por $\mathcal{F} : U_i \rightarrow U_i^*$ en donde $\mathcal{F}(u_i) = A_i^{fuz}$. Cada una de los elementos de interfase para el sistema de control difuso, y en general toda la estructura de éste, está basado en los llamados conjuntos difusos, los cuales establecen la sustentación formal de la Lógica Difusa, y que fueron propuestos por Lofti Zadeh.

Mecanismo de inferencia difusa

El mecanismo de inferencia difusa es el núcleo de cualquier controlador difuso. Su comportamiento dinámico es en general caracterizado por un conjunto de reglas difusas de la forma

$$\textit{Si } x \textit{ es } A \textit{ entonces } y \textit{ es } B \tag{4.1}$$

En donde A y B son valores lingüísticos definidos por un conjunto difuso en un universo X y Y respectivamente. La cláusula *Si*, un antecedente, es una condición en el dominio de aplicación; la cláusula *entonces*, una consecuencia, es una acción de control dado al proceso bajo control. Con un conjunto de reglas difusas, el mecanismo de inferencia difusa es capaz

de derivar una acción de control para un conjunto de valores de entrada. En otras palabras, una acción de control es determinada por las entradas observadas, las cuales representan el estado del proceso a ser controlado mediante el uso de las reglas de control. La expresión “Si x es A entonces y es B ”, la cual se abrevia regularmente como $A \rightarrow B$, en esencia, es una relación binaria R de las variables x y y en el espacio del producto $X \times Y$. Existen diversos métodos de inferencia difusa que pueden ser formulados a través de los operadores t-norma y s-norma para calcular la relación difusa $R = A \rightarrow B$. En general, los siguientes métodos son los más utilizados:

1. Implicación de Dienes-Rescher: En esta implicación la regla difusa es interpretada como una relación R_D en $A \times B$ con función de membresía

$$\mu_{R_D}(x, y) = \text{máx}[1 - \mu A(x), \mu B(y)] \quad (4.2)$$

2. Implicación Lukasiewics: Específicamente, la regla difusa es interpretada como una relación difusa R_L en $A \times B$ con función de membresía

$$\mu_{R_L}(x, y) = \text{mín}[1, 1 - \mu A(x) + \mu B(y)] \quad (4.3)$$

3. Implicación de Zadeh: Aquí la regla difusa es interpretada como una relación difusa R_Z en $A \times B$ con función de membresía

$$\mu_{R_Z}(x, y) = \text{max}[\text{min}(\mu A(x), \mu B(y)), 1 - \mu A(x)] \quad (4.4)$$

4. Implicación Mamdani: La regla difusa es interpretada como una relación R_M en $A \times B$ con función de membresía

$$\mu_{RM}(x, y) = \min[\mu A, \mu B], \text{ ó } \mu_{RM} = \mu A(x) \cdot \mu B(x) \quad (4.5)$$

En general el operador inferencia se aproxima por medio de una t-norma.

Defuzificación

La defuzificación es definida como un mapeo de un conjunto difuso B en $V \subset R$ (que es la salida de la inferencia difusa) a un elemento de un conjunto clásico $y_q^{crisp} = y^* \in V$. Conceptualmente, la tarea de defuzzificar es especificar un punto, elemento de V , que refleje la mejor representación del conjunto difuso B . De otra manera la defuzificación extrae una salida única basado en los métodos caracterizados por el paso de la inferencia que depende del tipo de inferencia utilizado. El método de defuzificación más conocido es el método del centroide, en el cual un valor de salida y_q^{crisp} se elige utilizando los centros de cada una de las funciones de membresía de salida y la certeza máxima de cada una de las conclusiones alcanzadas por la inferencia, y está dada en la ecuación 4.6.

$$y_q^{crisp} = \frac{\sum_{i=1}^R b_q^i \mu_i(u_1, u_2, \dots, u_n)}{\sum_{i=1}^R \mu_i(u_1, u_2, \dots, u_n)} \quad (4.6)$$

Donde b_q^i es el centro de la función de membresía donde se debe asegurar que $\mu_i(u_1, u_2, \dots, u_n) \neq 0$ para todas las entradas.

Capítulo 5

TÉCNICAS AVANZADAS DE IDENTIFICACIÓN

5.1. REDES NEURONALES

5.1.1. CONCEPTOS FUNDAMENTALES DE REDES NEURONALES ARTIFICIALES.

Las redes neuronales están inspiradas por el modelaje de las redes de neuronas reales en el cerebro humano. Así, los elementos de procesamiento son llamadas neuronas artificiales, o simplemente neuronas. Un cerebro humano consiste de 1×10^{11} neuronas de muchos tipos diferentes. Una neurona típica tiene tres partes principales: el cuerpo celular o soma, donde el núcleo de la célula esta alojado. Un axón es una conexión cilíndrica sencilla y larga que se extiende del cuerpo de la célula y lleva los impulsos de la neurona. El final de un axón se conecta con una ramificación fina estándar. Cada terminación tiene un pequeño

bulbo llamado sinápsis, donde la red neuronal introduce sus señales en las neuronas vecinas. Las terminaciones de recepción de estas uniones en las neuronas vecinas se pueden ubicar en otras terminaciones llamadas dendritas.

Las señales que alcanzan una sinápsis se reciben en las dendritas, y son impulsos eléctricos. Tales señales de transmisión involucran un complejo proceso químico, en la que una sustancia química transmisora es liberada desde el lado de transmisión de la sinápsis. Esto incrementa o disminuye el potencial dentro del cuerpo de la célula que recibe la señal. La célula receptora se “enciende” si el potencial eléctrico alcanza un valor de umbral, y un pulso o potencial de acción de una fuerza y duración específicas, se envía a través del axón hacía el árbol axonal de las conjunciones sinápticas de otras neuronas. Después del encendido de la neurona, esta presenta un período de tiempo llamado período refractario, antes de que esta pueda dispararse de nuevo. Las sinápsis son excitatorias si ellas permiten pasar los impulsos debido al mismo impulso de la célula receptora, o inhibitorias si ellas limitan el paso del impulso.

El modelo matemático propuesto por McCulloch y Pitts, de la representación de una neurona, es usualmente llamado neurona M-P fig. 5.1.

En este modelo, el i – *ésimo* elemento de procesamiento calcula una suma ponderada de sus entradas y salidas $y_i = 1$ (encendido), ó de acuerdo a si la suma ponderada, es mayor o menor a un valor preestablecido de umbral Θ_i , ecuación 5.1 .

$$y_i(t + 1) = a \left(\sum_{j=1}^m w_{ij} - \Theta_i \right) \quad (5.1)$$

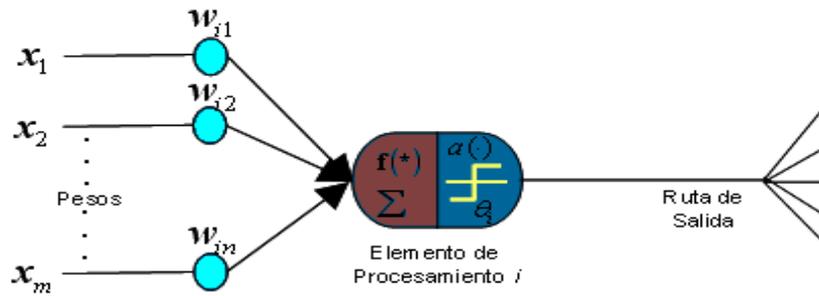


Figura 5.1: Perceptrón simple

Donde la función de activación es una función escalón unitario, ecuación 5.2:

$$a(f) = \begin{cases} 1 & f \leq 0 \\ 0 & f < 0 \end{cases} \quad (5.2)$$

Los pesos w_{ij} representan la “fuerza” de la sinápsis (llamada la conexión o el enlace) conectando la neurona (fuente) a la neurona (destino). Un peso positivo corresponde a una sinápsis excitatoria, y un peso negativo es una sinápsis inhibitoria. Sí $w_{ij} = 0$, no hay conexión entre las dos neuronas.

En resumen, una ANN es un procesador de información distribuida paralelamente que tiene las siguientes características principales:

- Es un modelo matemático histológicamente inspirado.
- Consiste de un gran número de elementos de procesamiento, altamente interconectados.
- Sus conexiones (pesos) mantienen el conocimiento.
- Un elemento de procesamiento puede responder dinámicamente a sus estímulos de entrada, y la respuesta depende completamente de su información local; esto es, las

señales llegan al elemento de procesamiento vía los pesos de conexión.

- Tiene la habilidad de aprender, reorganizar y generalizar a través de los datos de entrenamiento por asignación o ajuste de pesos de conexión.
- Su comportamiento colectivo demuestra su potencia computacional, y una neurona específica no acarrea información específica.

Dadas estas características, otros nombres comunes para las redes neuronales son: modelos de procesamiento paralelo distribuido, modelos conexionistas, sistemas autoorganizados, sistemas neurocomputacionales y sistemas neuromórficos [3].

5.1.2. TIPOS DE CONEXIONES DE LAS REDES NEURONALES

Una ANN consiste de muchas interconexiones de elementos de procesamiento (PE's por sus siglas en inglés) de las cuales cada salida de un PE es conectada a través de pesos a otros PE's o a ellos mismos; en ambas conexiones, el retardo nulo es permitido. Así, la estructura que organiza estos PE's y las conexiones geométricas a través de ellos pueden ser específicas para una ANN. Esto es importante para el punto de salida de las primeras y últimas conexiones, además que especifican cada función de cada PE en un ANN. La conexión más simple de un nodo en una red neuronal se muestra en la fig. 5.2, esta muestra cinco tipos básicos de conexiones geométricas [Nelson y Illingworth, 1991].

Tomado el primer PE y combinamos este con otro PE, se forma una capa de estos nodos. Las salidas pueden ser conectadas a estos nodos con varios pesos, resultando una serie de salidas, una por nodo. Este resultado es una red anteaumentada de capa simple fig. 5.2 inciso (a). Se pueden interconectar muchas capas para formar una red anteaumentada

multicapa fig. 5.2 inciso (b). La capa que recibe entradas es llamada capa de entrada y no desempeña otra función que el enrutamiento de la señal de entrada. Las salidas de la red son generadas desde la capa de salida. Puede no haber capas ocultas o hasta muchas de ellas en un ANN. Se dice que la red está completamente conectada si todas las salidas desde la primera capa esta conectada a todos los nodos en la siguiente capa.

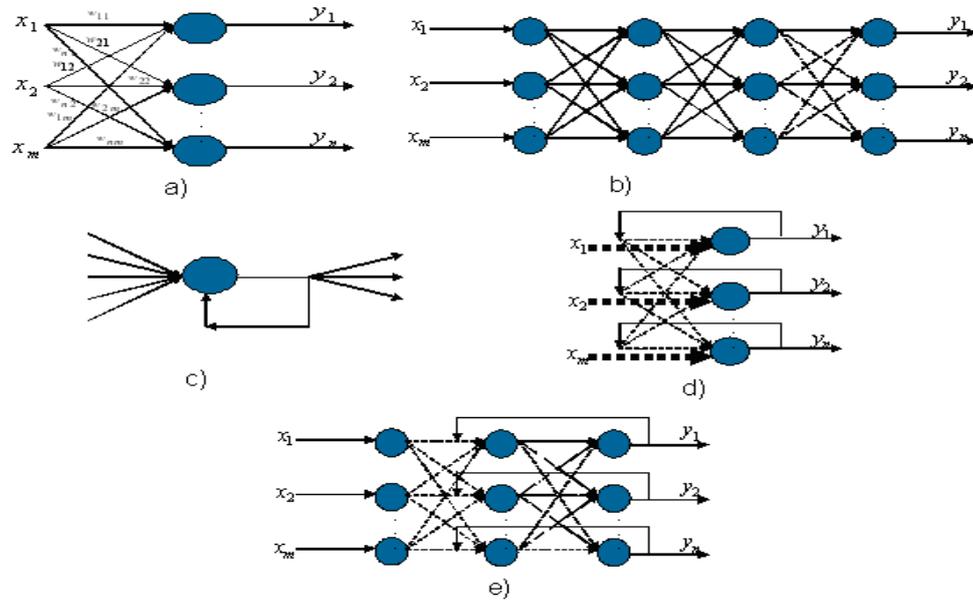


Figura 5.2: Conexión de las redes neuronales

Los dos tipos de redes mencionadas anteriormente (de capa simple y multicapas) son redes antealimentadas, dado que la salida de un PE, no es una entrada al nodo en la misma capa o en la capa que le precede. Cuando las salidas son directamente conectadas como entradas a la misma ó a los nodos de la capa que le precede, la red es llamada retroalimentada. La retroalimentación en la cual la salida de los PE es conectada directamente como entrada a los PE's de la misma capa es llamada retroalimentación lateral. La redes

retroalimentadas que utilizan lazo cerrado son llamadas redes recurrentes. La fig. 5.2 inciso (c), muestra la red neuronal recurrente más simple, con retroalimentación a él mismo. Una red de capa simple con una conexión en retroalimentación se muestra en la fig. 5.2 inciso (d), en la cual la salida de PE puede ser conectada al mismo PE, a otro PE o a ambos. Un tipo importante de conexión con retroalimentación lateral es la estructura fuera de alrededor, dentro del centro ó inhibición lateral. En esta estructura cada PE recibe dos diferentes clases de entradas “excitatorias” (entradas cercanas al PE) e “inhibitorias” (entradas desde PE más lejanos). En una red con multicapas recurrentes, un PE de salida puede ser directamente conectada a ese mismo PE y a otros PE’s en la misma capa. En la fig. 5.2 inciso (e) se muestra una red recurrente multicapa.

5.1.3. ALGORITMO BACKPROPAGATION

El algoritmo de aprendizaje backpropagation es uno de los mecanismos más importantes, históricamente hablando, en el desarrollo de las redes neuronales. [Bryson y Ho, 1969; Verbos, 1974; LeCun, 18985; Paker, 1985; Rumelhart, 1986 a y b]. Este fue diseñado para ser empleado por la comunidad científica y tecnológica en el modelado y el procesado de muchos fenómenos cuantitativos utilizando redes neuronales. El proceso de aprendizaje, es aplicado a las redes neuronales multicapas anteaumentadas consistentes de elementos de procesamiento, con funciones de activación continuas y diferenciables. Dado un conjunto de pares de entrenamiento (x^k, d^k) , $k = 1, 2, 3, \dots, p$, donde x^k es son las entradas, d^k es la salida deseada, el algoritmo provee un procedimiento para cambiar los pesos en una red neuronal, para clasificar los patrones de forma correcta.

Para un par entrada-salida (x^k, d^k) , el algoritmo backpropagation desarrolla dos

fases en el flujo de información. Primero, el patrón de entrada x^k es propagado de la capa de entrada a la capa de salida, y como resultado de este flujo de datos hacia adelante, este produce una salida y^k . Después, las señales de error resultantes de la diferencia entre y^k y d^k son propagadas hacia atrás de la capa de salida, a la capa anterior con el fin de actualizar sus pesos.

Primero se considera un par de entrenamiento entrada-salida (x^k, d^k) . Dado la entrada de entrenamiento, un PE en la capa oculta recibe una entrada de la red, ecuación 5.3.

$$net_q = \sum_{j=1}^m v_{qj}x_j \quad (5.3)$$

Y produce una salida, ecuación 5.4:

$$z_q = a(net_q) = a\left(\sum_{j=1}^m v_{qj}x_j\right) \quad (5.4)$$

La entrada de la red para el elemento de procesamiento o neurona en la capa de salida es, ecuación 5.5:

$$\begin{aligned} net_i &= \sum_{q=1}^l w_{iq}z_q = \sum_{q=1}^l w_{iq}a(net_q) \\ &= \sum_{q=1}^l w_{iq}a\left(\sum_{j=1}^m v_{qj}x_j\right) \end{aligned} \quad (5.5)$$

Produciendo una salida, ecuación 5.6:

$$\begin{aligned}
y_i &= a(\text{net}_i) = a\left(\sum_{q=1}^l w_{iq}z_q\right) = a\left(\sum_{q=1}^l w_{iq}a(\text{net}_q)\right) \\
&= a\left(\sum_{q=1}^l w_{iq}a\left(\sum_{j=1}^m v_{qj}x_j\right)\right)
\end{aligned} \tag{5.6}$$

La ecuación anterior indica la propagación hacia adelante de las señales de entrada, a través de las capas de neuronas. Definiendo una función de costo como en la ecuación 5.7:

$$\begin{aligned}
E(w) &= \frac{1}{2} \sum_{i=1}^n (d_i - y_i)^2 = \frac{1}{2} \sum_{i=1}^n [d_i - a(\text{net}_i)]^2 \\
&= \frac{1}{2} \sum_{i=1}^n \left[d_i - \left(a \sum_{q=1}^l w_{iq}z_q \right) \right]^2
\end{aligned} \tag{5.7}$$

De acuerdo al método de gradiente descendente, los pesos en las conexiones de la capa oculta a la capa de salida, son actualizados con la ecuación 5.8.

$$\Delta w_{iq} = -\eta \frac{\partial E}{\partial w_{iq}} \tag{5.8}$$

Como se observa en la ecuación de costo, para poder derivar conforme a los pesos en cada una de las capas se debe de utilizar la regla de la cadena para obtener la actualización de los pesos [3].

5.2. SISTEMAS NEURODIFUSOS

5.2.1. ARQUITECTURA NEURODIFUSA.

Un sistema neurodifuso, describe a un modelo difuso basado en reglas utilizando una estructura de tipo ANN. Un sistema neurodifuso difiere de una ANN en cuatro grandes formas. Primero, los nodos y los enlaces en un sistema neurodifuso, son estructurados, porque cada uno de los componentes corresponde a un paso en el proceso del sistema difuso. Segundo, un nodo en un sistema Neurodifuso si requiere de estar completamente conectado a los nodos de la capa anterior. De hecho, las conexiones entre los nodos en un sistema neurodifuso, refleja la estructura de reglas. Tercero, los nodos en diferentes capas de la ANN ejecutan diferentes funciones. Finalmente, un sistema neurodifuso, generalmente, tiene más capas que las ANN.

Típicamente, una arquitectura neurodifusa tiene de cinco a seis capas de nodos. La funcionalidad asociada con diferentes capas generalmente, incluye lo siguiente:

1. La primera capa calcula el grado de pertenencia de una condición difusa involucrando una sola variable.
2. En la segunda capa se calcula el grado de membresía de una condición difusa conjuntiva involucrando muchas variables.
3. La tercera capa obtiene el valor normalizado de pertenencia.
4. La cuarta capa sirve para calcular el valor de inferencia obtenido por el método propuesto, ya sea “AND” o el producto.
5. Por último en la capa final, se combina la conclusión de todas las reglas difusas en un modelo.

Es obvio que todas las tareas juntas constituyen una inferencia basada en reglas. Un modelo general de un sistema neurodifuso se conoce como ANFIPS, cuyas cinco capas corresponden a las mencionadas en el listado anterior. La razón de la normalización, esta separada de la combinación en el paso cinco, debido a que la condición en una red multicapa de retroalimentación proviene de que, en una capa solo se puede recibir información de la capa adyacente a la izquierda, es decir de la capa anterior.

La arquitectura ANFIPS fig. 5.3 implementa un Modelo Takagi-Sugeno-Khan (TSK) que separa el espacio de entrada usando funciones de membresía diferenciables. De hecho, la elección del modelo TSK y el uso de funciones de membresía diferenciables en los antecedentes son elementos comunes en casi todos los sistemas neurodifusos. Las funciones de tipo distribución normal o Gaussianas, son el tipo más empleado para los sistemas neurodifusos [12].

5.2.2. TIPOS DE CONTROLADORES NEURODIFUSOS

Basándose en tres tipos diferentes de razonamiento difuso, los tipos de controladores neurodifusos que pueden distinguirse son:

Tipo 1. Este tipo es el más formal. La función de membresía de salida es usualmente en forma de campana, triangular o trapezoidal. La respuesta difusa de cada regla se pesa en la función de membresía de salida por su “fuerza” de disparo, y el centroide de la respuesta es calculado por la generación de salidas apropiadas. Cuando la función de membresía de salida, es reducida a una función impulso, la consecuencia de cada regla es un singleton difuso. Una defuzificación simplificada común es llamada defuzificador singleton, el cual toma el valor de la salida con el mayor grado de la función de membresía como la respuesta

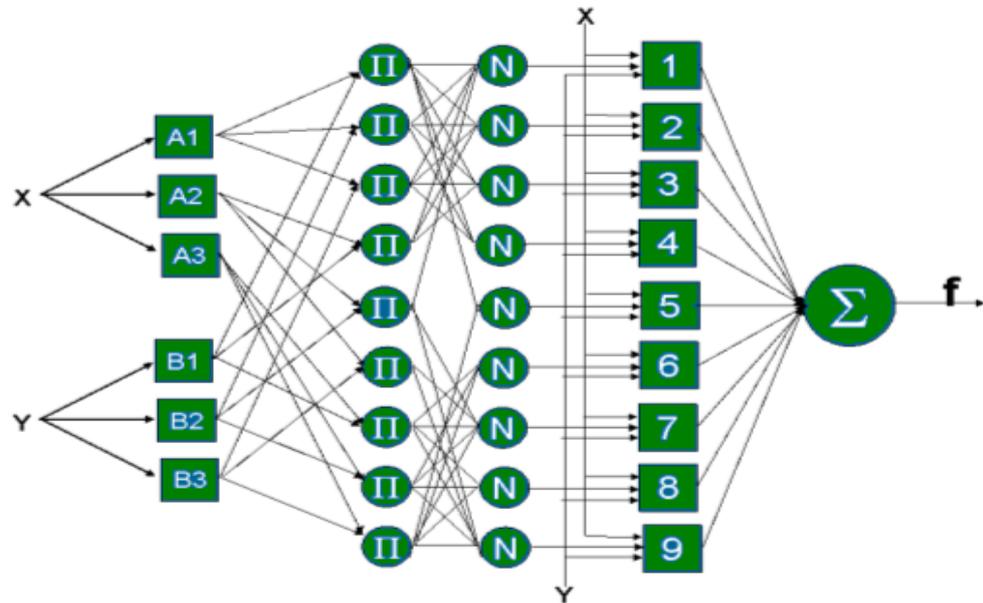


Figura 5.3: Estructura ANFIPS de un sistema neurodifuso

(“crisp”) de cada regla, y entonces responder con la salida apropiada.

Tipo 2: En este tipo, la función de membresía de salida es incrementada por una función monótonica (Función tipo S) o función sigmoideal. La respuesta de una regla difusa es determinada por su “fuerza” de disparo, de acuerdo a la función de membresía de salida. La agregación de valores de salida de todos los NFC es una combinación lineal de las respuestas y el disparo de las reglas difusas. Note que la consecuencia de cada una de las reglas llega a ser un singleton difuso cuando la función de membresía de salida es reducida a una función umbral.

Tipo 3: Este tipo usa las reglas difusas TSK, y desempeña un razonamiento difuso del tercer tipo. La respuesta de cada regla es una combinación lineal de los valores de las variables de entrada. La respuesta son pesadas y sumadas de acuerdo a su ponderación

de disparo, obteniendo así la respuesta final. La consecuencia de cada regla llega a ser un singleton difuso, cuando todos los coeficientes, en la parte condicionante, son cero.

El propósito de proponer sistemas de control neurodifuso aplicando el aprendizaje de técnicas neuronales, es encontrar y entonar los parámetros y/o estructuras de los sistemas de control difuso. Los controladores difusos requieren dos tipos de entonación: entonación estructural y entonación paramétrica. La entonación estructural envuelve la entonación de la estructura de las reglas difusas, tal como el número de variables de conteo para cada variable de entrada y salida de la partición del Universo de Discurso (*UD*); el número de reglas y las conjunciones que constituyen ellas mismas. Si una estructura satisfactoria de las reglas no es obtenida, controladores neurodifusos necesitan un desempeño de la entonación paramétrica. En esta fase parámetro-aprendizaje, los parámetros posibles a ser entonados, incluyen los asociados con una función de membresía tal como centros, pesos, inclinaciones, extensión de la regla, y los pesos de las reglas difusas.

El aprendizaje supervisado, el cual requiere un “instructor”, que especifique el vector de salida deseado, y reforzar el aprendizaje; lo cual requiere sólo una evaluación escalar simple de la salida; es sustituido por parámetros de aprendizaje para ajustar los parámetros de la reglas difusa y/o las funciones de membresía, para la salida deseada en un sistema de control neurodifuso. En casos donde las funciones de membresía son diferenciables, se puede hacer un cálculo del gradiente descendiente, basado en métodos de aprendizaje (por ejemplo el algoritmo de backpropagation) para parámetros de aprendizaje.

Capítulo 6

METODOLOGÍA

Una vez que se ha dado las bases fisiológicas sobre el periodo neonatal y las enfermedades que están asociadas con la edad gestacional temprana del recién nacido, así como las técnicas que se utilizan en este trabajo para la identificación de la temperatura central en el microambiente de un prototipo de una incubadora neonatal. Se tiene las bases para desarrollar un software para las pruebas de simulación para la identificación de la temperatura dentro del microambiente de la incubadora. Principalmente, la identificación de la temperatura central de la incubadora, nos ayudará a tener un sensor virtual, así como el comportamiento de la temperatura dentro de la misma. Como se ha comentado anteriormente, la identificación de la temperatura, es una variable muy importante para conocer si la temperatura es adecuada para el traslado del recién nacido prematuro dentro de la incubadora, ya que si la temperatura no se encuentran en un rango establecido, se pueden provocar caídas de temperatura en el recién nacido prematuro, lo que es indeseado para la supervivencia y desarrollo del recién nacido prematuro, ya que una de las funciones de las

incubadoras neonatales es tratar de mantener una temperatura constante del neonato en cualquier zona del microambiente de la incubadora neonatal.

6.1. PROTOTIPO DE UNA INCUBADORA NEONATAL

El prototipo de la incubadora esta desarrollado conforme a la norma oficial mexicana NOM-066-SSA-1993, la cual cuenta con diferentes partes como es el chasis, el capacete, la plataforma y el soporte para el colchón. Como la norma lo establece, la incubadora debe de tener dimensiones que sean apropiadas para un promedio de un neonato normal, las dimensiones del prototipo son de 90cm. x 43cm. x 27cm. Estas dimensiones también son apropiadas para introducir los sistemas que requiere una incubadora neonatal, como son el sistemas de calefacción o temperatura el cual va a proveer de calor al neonato, el sistema de ventilación para la extracción del bióxido de carbono que se almacena en el microambiente de la incubadora y el sistema de humidificación, que es útil para una mejor respiración del neonato [1].

6.1.1. CHASIS

Esta parte de la incubadora es una base metálica, la cual tiene que soportar el peso del capacete y del neonato, así como dar alojamiento a los sistemas de calefacción, de extracción y recirculación de aire, y los circuitos que conforman a la incubadora. El material del chasis de la incubadora es resistente a la humedad y a las temperaturas altas [1].

6.1.2. CAPACETE

Este elemento es la parte de la cubierta de la incubadora, y está hecho de polipropileno como material de construcción debido a que este material, permite una completa visibilidad del interior del microambiente, además de ser fácilmente manejable para el mantenimiento. El arreglo tiene una forma de un un prisma rectangular de 90 cm. de largo x 42 cm. de ancho x 42 cm. de alto, que se coloca sobre el chasis, el cual crea el espacio necesario para mantener al neonato, dejando suficiente espacio vacío para manipular de manera correcta todo el equipo adicional que se pudiera necesitar en la terapia para el paciente [1].

6.1.3. PLATAFORMA Y SOPORTE PARA EL COLCHÓN

La plataforma es la base donde se coloca el capacete, esta tiene las dimensiones apropiadas para el espesor del propileno, el cual debe de ser de un material resistente que está hecho de aluminio, se empleó este material debido a que no sufrirá corrosión con la humedad; las dimensiones de la plataforma son de 90cm de largo x 36cm de ancho y 2 cm de espesor. El soporte del colchón está hecho de varias capas de corcho (material aislante), el cual separan, la sección de la incubadora donde se genera el calor y donde éste se distribuye. Para dar una mayor rigidez a esta parte, se utilizaron unos forros de acrílico [1].

6.1.4. INTERCAMBIADOR DE CALOR

El sistema de calefacción debe de proveer de una distribución uniforme, así como un mantenimiento de la temperatura en el microambiente de la incubadora, y sobre todo debe de mantener la temperatura constante del neonato. la temperatura se distribuirá mediante

convección, es decir el microambiente se calentará por el gradiente del aire caliente dentro del capacete y es mediante una resistencia eléctrica, con potencia máxima de 3.5 kW, que tiene una superficie amplia para establecer la transferencia de calor uniforme. Este efecto es muy importante, con el fin de evitar que dentro del microambiente se presenten gradientes de temperatura indeseados que perturben las mediciones del GTE [1].

6.1.5. UNIDAD DE ACONDICIONAMIENTO TÉRMICO DEL AIRE

En este elemento se coloca el soporte del elemento calefactor y de los ventiladores, el cual está formado por una serie de arreglos de acrílico, donde se encuentran la resistencia de calefacción y los ventiladores, esto es para lograr una homogenización mayor de la temperatura dentro del capacete. Este sistema de acondicionamiento se coloca dentro del chasis y está hecho de acrílico transparente con dimensiones de 70 cm. x 23 cm. x 23 cm. Respecto a la circulación del aire, se regula por medio de tres ventiladores de 5 cm. de radio, alimentados con 12 volts de corriente directa, y de 0.25 HP de potencia [1].

6.1.6. SISTEMA DE EXTRACCIÓN DE AIRE

Para tratar de eliminar la acumulación de dióxido de carbono expirado por el neonato dentro del capacete, se cuenta con un sistema de extracción de aire dentro del chasis. Este está construido por medio de un arreglo de conductos de PVC, que sirven para el transporte del aire que se encuentra en el microambiente de la incubadora. El aire es extraído por medio de unos orificios realizados en el chasis, en las zonas cercanas a las paredes del mismo, manteniendo así la temperatura central uniforme por el intercambio gaseoso. Para obtener la extracción del aire, se cuenta con un ventilador de corriente directa,

con 1500 rev/min y con una potencia de 0.25 HP, alimentado con 12V de corriente directa y con una dimensión de 5 cm de diámetro [1].

6.1.7. SENSOR DE TEMPERATURA

Principalmente para la identificación de la temperatura se debe seleccionar un sensor que cumpla con las características que requieran un menor consumo de energía y una corriente de fuga pequeña, ya que el sensor estara en contacto de con la piel del neonato. El sensor de temperatura que se encuentra en el mercado es el LM35 que es un circuito integrado con encapsulado TO-92 construido con plástico de un coeficiente alto de transferencia térmica, y además, tiene un coste muy bajo. Respecto a las características eléctricas que posee el sensor LM35 la salida de voltaje es linealmente proporcional a la temperatura, por ejemplo si la temperatura se encuentra en 25°C la salida del sensor nos entregara un voltaje de 0.25 Volts. Otra característica importante del sensor, es la ausencia de calibración externa en el chip, ya que proporciona precisiones de $\pm 1\frac{1}{4}^{\circ}\text{C}$ a una temperatura de 25°C , y $\pm 3\frac{1}{4}^{\circ}\text{C}$ promedio sobre el rango completo de temperatura de operación (-55 a $+150^{\circ}\text{C}$). Pensando en las necesidades médicas en cuanto a seguridad eléctrica se refiere, el LM35 es muy útil, ya que drena tan sólo $60\mu\text{A}$ de la fuente de alimentación, lo que se traduce en un muy bajo nivel de calentamiento de operación del dispositivo (menor de 0.1°C a temperatura ambiente). Debido a las características específicas y a los requerimientos que se deben de tener en un equipo médico y principalmente cuando el dispositivo se tiene que implantar en la superficie de la piel del paciente se debe de tener características especiales del dispositivo eléctrico a emplear en la medición de la variable de interés para que no ocurran accidentes indeseados como puede ser un macroshock o un microshock, lo que puede repercutir en la

vida del paciente, por estos casos se debe de tener mucho cuidado en seleccionar el tipo de dispositivo y la corriente de fuga que maneja.

Para lograr un voltaje que represente la temperatura real se debe de aplicar el voltaje dado por el sensor, el cual cuenta con 3 etapas las cuales son:

- Medición
- Acoplamiento
- Amplificación

La primera etapa se refiere a la medición directa del sensor, que entrega un voltaje de un valor muy pequeño y tiene las características antes mencionadas, ya que es imposible introducir este voltaje a un sistema de adquisición de datos, ya que el convertidor de analógico a digital que contiene la tarjeta, no representaría un voltaje aceptado para la conversión. Para la amplificación se requiere antes un acoplamiento entre el sensor y los amplificadores los cuales deben de tener características especiales; el amplificador operacional TL082 dual se eligió debido a su bajo consumo de corriente, así como resistencias que sirvan para las configuraciones de los amplificadores para obtener un voltaje representativo y un acoplamiento entre cada una de las etapas, esto para reforzar la corriente en los amplificadores. La primera parte es un seguidor inversor con ganancia fija de 10, que está dado por el valor de las resistencias que se colocan en las terminales del amplificador, debido a la configuración la salida del amplificador será inversa, es decir un voltaje negativo.

$$V_1 = -10 * V_{sensor} \quad (6.1)$$

Debido al voltaje inverso se necesita otro amplificador en configuración seguidor

inversor para obtener un valor que represente un voltaje superior para la adquisición de datos, así aplicando el siguiente seguidor inverso se tendrá una salida de la siguiente manera:

$$V_2 = 10 * V_{sensor} \quad (6.2)$$

Por último, ya que se tiene un voltaje representativo se adiciona un acoplador de impedancia el cual es un seguidor no inversor, y sirve para la protección de la tarjeta de adquisición de datos, este tipo de configuración no modifica el valor del voltaje de salida de la etapa anterior, debido a las características de un amplificador, que tiene un voltaje de offset que se debe a los transistores intrínsecos propia de su construcción, así también el valor de voltaje de salida tendrá una perturbación, debida a la construcción hecha por el fabricante. La perturbación que se tiene depende del tipo de amplificador que se utilice, en este caso en la segunda etapa se utilizó un amplificador operacional TL071, ya que presenta un offset y una perturbación muy pequeña.

$$V_3 = 10 * V_{sensor} + \Delta V$$

6.2. DISEÑO DE LA RED NEURONAL CON EXTENSIÓN DE FILTROS DE KALMAN PARA LA IDENTIFICACIÓN DE LA TEMPERATURA

Las aplicaciones que tiene las redes neuronales suelen ser muy variadas, y sobrepasan las aplicaciones y las investigaciones que han venido surgiendo desde que se ob-

tuvo el modelaje de una neurona biológica. Actualmente las redes neuronales se clasifican en redes neuronales estáticas y redes neuronales dinámicas, la diferencia que existen entre ellas, es que las redes estáticas son para sistemas en tiempo discreto, mientras que las redes neuronales dinámicas son para sistemas en tiempo continuo. La técnica que se utilizó en el presente trabajo, fueron las redes neuronales en tiempo discreto, ya que el nuevo algoritmo de aprendizaje para la red neuronal es utilizado para redes estáticas. Como se mencionó anteriormente las redes neuronales tiene diferentes aplicaciones y son una herramienta importante para control, estimación e identificación de variables. Para conocer su comportamiento, se puede lograr con un set de entradas que se puedan medir por medios físicos del tal modo que al entrenar a la red neuronal con estas entradas se puede identificar la variable de interés y observar el comportamiento de la misma.

Para la identificación de la temperatura central del prototipo de la incubadora neonatal con la red neuronal, se cuenta con dos entradas, una de ellas depende de la temperatura del neonato y la temperatura del microambiente llamada GTE (Gradiente de Temperatura externo) (6.3), así como el cambio en el gradiente de temperatura externo respecto al tiempo ΔGTE (6.4), que es la velocidad del GTE , las cuales se definen a continuación:

$$GTE = T_{piel} - T_{Incubadora} \quad (6.3)$$

$$\Delta GTE = \frac{GTE_{actual} - GTE_{anterior}}{t_{actual} - t_{anterior}} \quad (6.4)$$

Para el desarrollo del algoritmo para la identificación de la temperatura, no existe

un criterio que describa cuando se debe de utilizar un cierto número de capas ocultas y de neuronas para el diseño de la red neuronal; principalmente la estructura de la red neuronal depende mucho del diseñador y del ajuste de los pesos para obtener el valor de salida deseado, en este caso el seguimiento de la temperatura en el interior de la incubadora.

El diseño de la estructura de la red neuronal, cuenta con una capa de entrada, una capa oculta y una capa de salida, la estructura de la red se puede observar en la fig. 6.1.

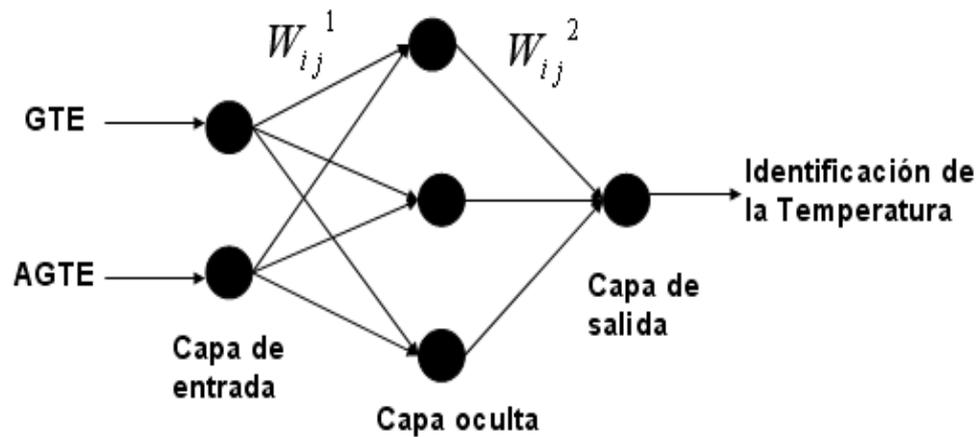


Figura 6.1: Estructura de la red neuronal utilizada para la identificación de temperatura

Se eligió la estructura de la red neuronal con una sola capa oculta, con la finalidad de tener un coste computacional, es decir, si la estructura de la red neuronal fuese mas complicada los cálculos realizados por la pc tardarían más dando por resultado que la memoria de la pc se agotará, claro está que depende del procesador y la memoria disponible. El programa que se pretende realizar simplemente con una capa oculta requiere de muchos cálculos lo que puede ser una desventaja si se tiene un procesador de baja velocidad como

de memoria disponible, dado que al utilizar una capa oculta se puede ponderar los pesos de la red neuronal mediante las entradas para la red neuronal, lo cual asegura una mayor velocidad de procesamiento y un error menor en la identificación de la temperatura, la cual se verá con los resultados que se obtengan, tanto para las pruebas de simulación, como para las pruebas en tiempo real.

Respecto a las pruebas de simulación, se realizó un software que simule el comportamiento de la temperatura del neonato y la temperatura del microambiente, para obtener las variables de interés (GTE y ΔGTE). La temperatura de la piel del neonato se eligió como $35^{\circ}C$ con una variación aleatoria con media de 0 y varianza de 1, de la misma forma para la temperatura del microambiente de $28^{\circ}C$ se le adicionó una variación aleatoria con media 0 y varianza de 1, dado que la temperatura de una persona y la del ambiente tiene variaciones.

Denotemos las entradas de la red como:

$$x_1 = GTE = T_{piel} - T_{Incubadora} \quad (6.5)$$

$$x_2 = \Delta GTE = \frac{GTE_{actual} - GTE_{anterior}}{t_{actual} - t_{anterior}} \quad (6.6)$$

La salida de la red neuronal en la capa de entrada sera:

$$y_k^1 = \sum_{j=1}^n x_j W_{jk}^1 \quad (6.7)$$

La salida en la capa oculta esta dada por:

$$y_i^2 = \frac{1}{1 + \exp(-y_k^1)} = \frac{1}{1 + \exp(-\sum_{k=1}^n x_j W_{jk}^1)} \quad (6.8)$$

Donde y_i^2 es una función de activación llamada sigmoide.

Finalmente la salida de la red neuronal queda de la siguiente forma:

$$\begin{aligned} y_l^3 &= \sum_{j=1}^n y_j^2 W_{ij}^2 = \frac{1}{1 + \exp(-y_k^1)} W_{ij}^2 \\ &= \sum_{j=1}^n \frac{1}{1 + \exp(-\sum_{i=1}^n x_i W_{jk}^1)} W_{ij}^2 \end{aligned} \quad (6.9)$$

6.2.1. REGLAS DE APRENDIZAJE PARA LA RED NEURONAL

Primeramente para la actualización de los pesos, se debe de tener un índice de desempeño para la identificación de la temperatura, que va a depender tanto de la salida de la red como la salida deseada, la cuales se denotan como I_p y I_p^* respectivamente. El índice de desempeño está dado de la siguiente forma:

$$\begin{aligned} J_p &= \frac{1}{2}(I_p - I_p^*)^2 \\ &= \frac{1}{2}e_v^2 \end{aligned} \quad (6.10)$$

Denotemos a la salida de la red como una función lineal como $y_l^3 = \varphi(V_j)$. Donde

$$V_j = \sum_{j=1}^2 y_j^2 W_{ij}^2$$

Para la actualización de los pesos en la capa 2 se utiliza el algoritmo de aprendizaje de los pesos con los filtros de Kalman, dado que este algoritmo utiliza backpropagation para

el cálculo de la matriz jacobiana, y se obtiene de la siguiente manera:

$$h_{ij}^2(k) = \frac{\partial J_p}{\partial e_v} \frac{\partial e_v}{\partial y_i^3} \frac{\partial y_i^3}{\partial V_j} \frac{\partial V_j}{\partial W_{ij}^2(k)} = e_v y_i^3 \quad (6.11)$$

Siguiendo con los pasos para la actualización de los pesos, el algoritmo requiere de parámetros que serán necesarios para una mayor adaptación de los pesos en un tiempo muy pequeño, lo cual lo indica la ecuación 3.115. Los parámetros que rigen el aprendizaje de la red neuronal, son la velocidad de aprendizaje $\mu_{jv}^2(k)$, la actualización de las covarianzas $p_{ij}^2(k)$ de los pesos W_{ij}^2 y el ajuste central de los parámetros $a_v(k)$ que pondera la velocidad de aprendizaje. Cada elemento es calculado de la siguiente manera:

$$a_1(k) = \frac{1}{r_1(k) + \sum_{i=1}^M \sum_{j=1}^{n_i} \sum_{s=1}^{n_{i-1}+1} (h_{ij}^2(k))^2 p_{ij}^2(k-1)} \quad (6.12)$$

$$\mu_{jv}^2(k) = p_{js}^2(k-1) a_1(k) \quad (6.13)$$

$$p_{ij}^2(k) = \left(1 - \sum_{v=1}^{n_M} \mu_{ijv}^2(k) (h_{ij}^2(k))^2 \right) p_{ij}^2(k-1) \quad (6.14)$$

Teniendo cada uno de los parámetros utilizados para la actualización de los pesos en la capa oculta que esta dado por:

$$W_{ij}^2(k) = W_{ij}^2(k-1) + \sum_{v=1}^n \mu_{ijv}^2(k) h_{ijv}^2(k) e_v(k) \quad (6.15)$$

De la misma forma para la actualización de los pesos en la capa de entrada se utiliza el algoritmo backpropagation. La matriz jacobiana es calculada como sigue:

Denotemos a $y_i^2 = \varphi(V_i)$ donde $V_i = \sum_{k=1}^2 x_i W_{jk}^1$ de tal modo que la matriz jacobiana queda de la siguiente forma

$$\begin{aligned} h_{jk}^1(k) &= \frac{\partial e_v(k)}{\partial W_{ij}^1(k-1)} = \frac{\partial J_p}{\partial e_v} \frac{\partial e_v}{\partial y_i^3} \frac{\partial y_i^3}{\partial V_j} \frac{\partial V_j}{\partial y_i^2} \frac{\partial y_i^2}{\partial V_i} \frac{\partial V_i}{\partial W_{ij}^1} \\ &= e_v W_{ij}^2 \varphi'(V_i) x_i \end{aligned} \quad (6.16)$$

Donde $\varphi'(V_i)$ es la derivada de la función de activación. Para la actualización de los pesos en la capa de entrada estan dados de la siguiente manera:

$$a_2(k) = \frac{1}{r_2(k) + \sum_{i=1}^M \sum_{j=1}^{n_i} \sum_{s=1}^{n_{i-1}+1} (h_{j_{sv}}^1(k))^2 p_{js}^1(k-1)} \quad (6.17)$$

$$\mu_{j_{kv}}^1(k) = p_{jk}^1(k-1) a_2(k) \quad (6.18)$$

$$p_{jk}^1(k) = \left(1 - \sum_{v=1}^{n_M} \mu_{j_{kv}}^1(k) (h_{j_{kv}}^1(k))^1 \right) p_{jk}^1(k-1) \quad (6.19)$$

Donde $a_2(k)$ es el ajuste de los parámetros de la red, $\mu_{j_{kv}}^1(k)$ es la velocidad de aprendizaje y $p_{jk}^1(k)$ son las covarianzas de los pesos.

Finalmente la actualización de los pesos queda descrito de la siguiente manera:

$$W_{jk}^1(k) = W_{jk}^1(k-1) + \sum_{v=1}^{n_M} \mu_{j_{kv}}^1(k) h_{j_{kv}}^1(k) e_v(k) \quad (6.20)$$

6.3. DISEÑO DEL SISTEMA NEURODIFUSO PARA LA IDENTIFICACIÓN DE LA TEMPERATURA

El desarrollo de la lógica difusa y las redes neuronales en los últimos años se ha clasificado como aproximadores universales (identificadores), para sistemas no lineales. Mientras que la teoría de lógica difusa tiene una desventaja en cuanto al ajuste y modificación de la estructura de la función de membresía para las variables de entrada. En tanto al diseño de la red neuronal depende mucho del diseñador en cuanto al número de nodos, capas, etc. Recientemente se han desarrollado trabajos en los cuales se ha demostrado que la fusión entre estas dos tecnologías tienen una mayor efectividad en la identificación de sistemas no lineales [11], [12], por lo cual los algoritmos que se han desarrollado implican una aplicación a un número mayor de sistemas que ejecuten acciones más complejas con un gasto de recursos mínimo. Así mismo la fusión de estas dos tecnologías ayuda a modificar la estructura de las funciones de membresía, cabe señalar que las funciones que utilizan un sistema neurodifuso son de tipo distribución normal o también llamadas funciones de membresía Gaussianas. La red neuronal modifica los parámetros como son los centros y la desviación estandar de este tipo de funciones. El diseño de los sistema neurodifuso se puede presentar en diferentes topologías de acuerdo con la planta que se este tratando. Para el caso de la incubadora se utilizó una estructura de la red neuronal con cinco capas, las cuales van a desempeñar cada una de las capas, la estructura de un sistema difuso, tal y como se muestra en el esquema general de la estructura del sistema neurodifuso fig. 6.2.

A continuación se describirán cada uno de los pasos que se siguieron para el diseño

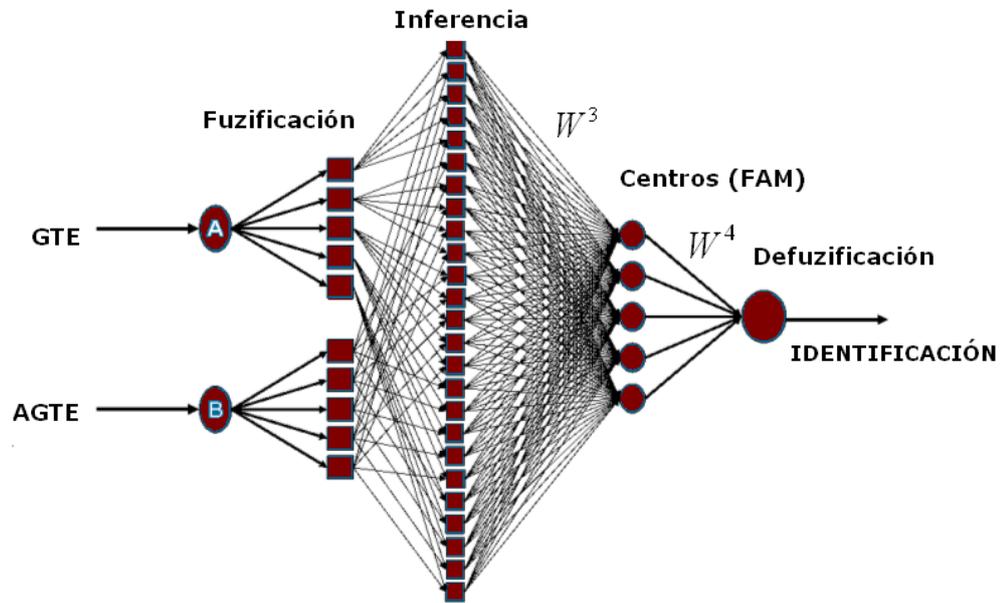


Figura 6.2: Estructura del sistema neurodifuso

del sistema neurodifuso.

Así para la primera capa deberá de cumplir el paso de fuzificación, el cual se obtiene por la evaluación de los valores de entrada denotados por u_1 y u_2 en una función de tipo Distribución normal.

$$\begin{aligned}
 f_{A_i}(u_1) &= \exp \left[-\frac{1}{2} \left(\frac{u_1 - q_i}{\sigma_{A_i}} \right)^2 \right] \\
 f_{B_j}(u_2) &= \exp \left[-\frac{1}{2} \left(\frac{u_2 - c_j}{\sigma_{B_j}} \right)^2 \right]
 \end{aligned}
 \tag{6.21}$$

Donde A_i y B_j representan el i - ésimo y j - ésimo predicados del sistema difuso para la entrada 1 y 2 respectivamente, lo que implica la aparición del concepto de término lingüístico asociado a cada entrada. Donde e_i y c_j son los centros de cada una de

las funciones de membresía Gaussianas, así como σ_{A_i} y σ_{B_j} son las desviaciones estandar para cada función de membresía asociadas a sus respectivas entradas.

El siguiente paso es calcular la implicación o valor asociado a cada combinación de términos de cada entrada. Así en la capa tres, se calcula el producto que es representado por la FAM, por lo tanto:

$$O_l^2 = f_{A_i}^1 * f_{B_j}^1 \quad (6.22)$$

Para la capa 4, asumimos que tiene asignado una asociación lingüística

$$f_k^3 = \frac{1}{1 + \exp\left(-\sum_{l=1}^L W_{kl}^3 O_l^2\right)} \quad (6.23)$$

Donde f_k^3 es una función sigmoïdal y W_{kl}^3 es el peso de la conexión entre el i -ésimo nodo de la capa 2 con el k -ésimo nodo en la capa 3.

Por último la capa 5, asigna una expresión de salida:

$$f_l^4 = \sum_{k=1}^K W_k^4 f_k^3 \quad (6.24)$$

Donde W_k^4 son los pesos de interconexión entre la capa tres y la cuatro.

6.3.1. REGLAS DE APRENDIZAJE

Una vez que se ha diseñado el modelo, se necesita un algoritmo que ajuste los parámetro tanto de los pesos como la estructura de las funciones de membresía de tipo gaussiano. Para el ajuste de los pesos se utiliza la extensión de los filtros de Kalman explicado en los capítulos anteriores. Para aplicar el algoritmo de la actualización de los pesos con la

extensión de los filtros de Kalman (WEKF por sus siglas en inglés). Se debe de definir una función para un índice de desempeño de la identificación de la incubadora el cual se muestra en la ecuación siguiente:

$$\begin{aligned} J_p &= \frac{1}{2}(U_p - U_p^*)^2 \\ &= \frac{1}{2}e_v^2 \end{aligned} \quad (6.25)$$

Donde U_p es la salida del sistema neurodifuso y U_p^* es la salida deseada. Ya definido el error medio cuadrático o índice de desempeño, el siguiente paso es el cálculo de la matriz jacobiana utilizando el algoritmo backpropagation. De esta manera para la actualización de los pesos W_{js}^4 de la capa 4 en donde se encuentran las asociaciones lingüísticas esta dado de la siguiente manera:

$$\begin{aligned} h_{j_{sv}}^4(k) &= \frac{\partial e_v(k)}{\partial W_{js}^4(k-1)} = \frac{\partial}{\partial W_{js}^4(k-1)} \left[\frac{1}{2} \left(\sum_{k=1}^K W_k^4 f_k^3 - U_p^* \right)^2 \right] \\ &= e_v f_k^3 \end{aligned} \quad (6.26)$$

De la misma forma que en la red neuronal los parámetros que utiliza el algoritmo de aprendizaje, utilizados en la red neuronal se pueden apreciar en las siguientes fórmulas:

$$a_1(k) = \frac{1}{r_2(k) + \sum_{i=1}^M \sum_{j=1}^{n_i} \sum_{s=1}^{n_{i-1}+1} (h_{j_{sv}}^4(k))^2 p_{js}^4(k-1)} \quad (6.27)$$

$$\mu_{j_{sv}}^4(k) = p_{js}^4(k-1) a_v(k) \quad (6.28)$$

$$p_{js}^4(k) = \left(1 - \sum_{v=1}^{n_M} \mu_{j_{sv}}^4(k) (h_{j_{sv}}^4(k))^2 \right) p_{js}^4(k-1) \quad (6.29)$$

Donde $a_v(k)$ es el ajuste de los parámetros para el peso $W_{js}^4(k)$, $\mu_{j_{sv}}^4(k)$ es la velocidad de aprendizaje, $p_{js}^4(k)$ es la varianza de los pesos. Finalmente, la actualización de los pesos en la capa 4 queda descrito de la foma siguiente:

$$W_{js}^4(k) = W_{js}^4(k-1) + \sum_{v=1}^{n_M} \mu_{j_{sv}}^4(k) h_{j_{sv}}^4(k) e_v(k) \quad (6.30)$$

Respecto a la capa 3 se realiza el mismo procedimiento que la capa 4, como ya se vio el algoritmo de aprendizaje backpropagation, actualiza los pesos hacia atrás, lo cual en las siguientes actualizaciones de los pesos deben de quedar implícitos los pesos de la capa posterior, de igual modo la matriz jacobiana para la actualización de los pesos en la capa 3 (inferencia) está dada por:

$$\begin{aligned} h_{j_{sv}}^3(k) &= \frac{\partial e_v(k)}{\partial W_{js}^3(k-1)} = \frac{\partial J_p}{\partial e_v} \frac{\partial e_v}{\partial f_k^3} \frac{\partial f_k^3}{\partial W_{js}^3} \\ &= e_v W_{js}^4 \left(1 + \exp \left(- \sum_{l=1}^L W_{js}^3 O_l^2 \right) \right)^{-2} \exp \left(- \sum_{l=1}^L W_{js}^3 O_l^2 \right) O_l^2 \\ &= e_v W_{js}^4 (f_k^3)^2 \exp \left(- \sum_{l=1}^L W_{js}^3 O_l^2 \right) O_l^2 \end{aligned} \quad (6.31)$$

De este modo los parámetros para la actualización de los pesos $W_{js}^3(k)$ son similares a los de la capa 4.

$$a_2(k) = \frac{1}{r_2(k) + \sum_{i=1}^M \sum_{j=1}^{n_i} \sum_{s=1}^{n_{i-1}+1} (h_{j_{sv}}^3(k))^2 p_{js}^3(k-1)} \quad (6.32)$$

$$\mu_{j_{sv}}^3(k) = p_{j_s}^3(k-1)a_v(k) \quad (6.33)$$

$$p_{j_s}^3(k) = \left(1 - \sum_{v=1}^{n_M} \mu_{j_{sv}}^3(k)(h_{j_{sv}}^3(k))^2\right) p_{j_s}^3(k-1) \quad (6.34)$$

La actualización de los pesos $W_{j_s}^3(k)$, se rigen por la ecuación siguiente:

$$W_{j_s}^3(k) = W_{j_s}^3(k-1) + \sum_{v=1}^{n_M} \mu_{j_{sv}}^3(k)h_{j_{sv}}^3(k)e_v(k) \quad (6.35)$$

Como se mencionó anteriormente la red neuronal tiene la capacidad de ajustar los parámetros de las funciones de membresía, que son las desviaciones estándar y los centros para cada variable de entrada, así como para cada término lingüístico. La actualización de los parámetros se debe llevar a cabo en la capa de 3, ya que en esta capa se encuentra los valores implicados en la decisión del valor de fuzificación llamado mecanismo de inferencia.

En primer término para la actualización de los parámetros de las funciones de membresía de tipo gaussiano, en este caso los centros de la primer variable de entrada (*GTE*), se realiza el cálculo para la matriz jacobiana:

$$\varsigma_{j_{sv}}(k) = \frac{\partial J_p}{\partial e_v} \frac{\partial e_v}{\partial f_k^3} \frac{\partial f_k^3}{\partial O_l^2} \frac{\partial O_l^2}{\partial q_i} = e_v W_k^4 (f_k^3)^2 \exp\left(-\sum_{l=1}^L W_{kl}^3 O_l^2\right) W_{kl}^3 \frac{\partial O_l^2}{\partial q_i} \quad (6.36)$$

Denotemos los términos que van a ser invariantes en los cálculos posteriores por:

$$\gamma = e_v W_k^4 (f_k^3)^2 \exp\left(-\sum_{l=1}^L W_{kl}^3 O_l^2\right) W_{kl}^3 \quad (6.37)$$

De esta manera la expresión de la matriz jacobiana para la actualización de los centros del *GTE* queda de la siguiente forma:

$$\varsigma_{j_{sv}}(k) = \gamma f_{B_j}^1 \exp\left(-\frac{1}{2}\left(\frac{u_1 - q_i}{\sigma_{A_i}}\right)^2\right) \left(\frac{u_1 - q_i}{\sigma_{A_i}}\right) \left(\frac{1}{\sigma_{A_i}}\right) \quad (6.38)$$

Finalmente, la expresión que denota la actualización de los centros esta dada por:

$$\varsigma_{j_s}(k) = \varsigma_{j_s}^i(k-1) + \sum_{v=1}^{n_M} \mu_{j_{sv}}(k) h_{j_{sv}}(k) e_v(k) \quad (6.39)$$

Para la actualización de las desviaciones estandar del *GTE*, obteniendo las derivadas respecto a la desviación estándar queda expresado de la siguiente forma:

$$\begin{aligned} \delta_{j_{sv}}(k) &= \gamma f_{B_j}^1 \exp\left(-\frac{1}{2}\left(\frac{u_1 - q_i}{\sigma_{A_i}}\right)^2\right) \frac{\partial O_l^2}{\partial \sigma_{A_i}} \\ &= \gamma f_{B_j}^1 \exp\left(-\frac{1}{2}\left(\frac{u_1 - q_i}{\sigma_{A_i}}\right)^2\right) \frac{(u_1 - q_i)^2}{(\sigma_{A_i})^3} \end{aligned} \quad (6.40)$$

Finalmente, la actualización de los pesos queda descrita de la siguiente manera:

$$\delta_{j_s}(k) = \delta_{j_s}(k-1) + \sum_{v=1}^{n_M} \mu_{j_{sv}}(k) h_{j_{sv}}(k) e_v(k) \quad (6.41)$$

Para la actualización de la segunda variable de entrada (ΔGTE), debido a que se encuentran en el mismo nivel que la primer variable de entrada, obteniendo las derivadas, de la matriz jacobiana queda de la siguiente forma:

$$\begin{aligned}
\chi_{j_{sv}}(k) &= \frac{\partial J_p}{\partial e_v} \frac{\partial e_v}{\partial f_k^3} \frac{\partial f_k^3}{\partial O_l^2} \frac{\partial O_l^2}{\partial c_j} = e_v W_k^4 (f_k^3)^2 \exp\left(-\sum_{l=1}^L W_{kl}^3 O_l^2\right) W_{kl}^3 \frac{\partial O_l^2}{\partial c_j} \quad (6.42) \\
&= \gamma f_{A_i}^1 \exp\left(-\frac{1}{2} \left(\frac{u_2 - c_j}{\sigma_{B_j}}\right)^2\right) \left(\frac{u_2 - c_j}{\sigma_{B_j}}\right) \left(\frac{1}{\sigma_{B_j}}\right)
\end{aligned}$$

Así las ecuaciones que rigen a actualización de los centros queda descrita de la siguiente manera:

$$\chi_{js}(k) = \chi_{js}(k-1) + \sum_{v=1}^{n_M} \mu_{j_{sv}}(k) h_{j_{sv}}(k) e_v(k) \quad (6.43)$$

De la misma manera para la actualización de las desviaciones estándar de la función de membresía del (ΔGTE). Obteniendo la matriz jacobiana se tiene el siguiente resultado:

$$\begin{aligned}
\vartheta_{j_{sv}}(k) &= \gamma f_{A_i}^1 \exp\left(-\frac{1}{2} \left(\frac{u_2 - c_j}{\sigma_{B_j}}\right)^2\right) \frac{\partial O_l^2}{\partial \sigma_{B_j}} \quad (6.44) \\
&= \gamma f_{A_i}^1 \exp\left(-\frac{1}{2} \left(\frac{u_2 - c_j}{\sigma_{B_j}}\right)^2\right) \frac{(u_2 - c_j)^2}{(\sigma_{B_j})^3}
\end{aligned}$$

Finalmente, la actualización de las desviaciones estándar está descrita por la ecuación siguiente:

$$\vartheta_{js}(k) = \vartheta_{js}(k-1) + \sum_{v=1}^{n_M} \mu_{j_{sv}}(k) h_{j_{sv}}(k) e_v(k) \quad (6.45)$$

Teniendo las bases teóricas y el diseño del sistema neurodifuso, debido a los complejos cálculos que se requieren para el entrenamiento del sistema neurodifuso; así como el ajuste de las funciones de membresía, que va a realizar el mismo para obtener una aproximación de la temperatura dentro de la incubadora, se debe de desarrollar un software que

sea capaz de realizar los cálculos del sistema neurodifuso. El siguiente paso es describir los variables lingüísticas y los términos lingüísticos, necesarios para construir la matriz de conocimiento difuso (FAM) (tabla 2), que son necesarios para la actualización de los parámetros de las funciones de membresía. Para cada variable de entrada se consideraron 5 terminos lingüísticos, los cuales fueron elegidos para abarcar las fronteras de cada variable de entrada (estos se pueden observar en la tabla 1), las cuales al realizar las reglas de inferencia se obtiene 25 consecuencias dados por la combinación de los términos lingüísticos con cada variable de entrada.

Tabla 1. descripción de los términos lingüísticos para cada variable de entrada

Variable Lingüística	Término Lingüístico
$GTE(u_1)$	Muy negativo
	Negativo
	Cero
	Positivo
	Muy positivo
$\Delta GTE(u_2)$	Muy negativo
	Negativo
	Cero
	Positivo
	Muy positivo

Tabla 2. matriz de conocimiento difuso (FAM)

Temperatura central		ΔGTE				
		MN	N	C	P	MP
GTE	MN	0.1	0.2	0.3	0.1	0.3
	N	0.1	0.2	0.2	0.1	0.3
	C	0.2	0.2	0.3	0.5	0.3
	P	0.2	0.2	0.2	0.5	0.3
	MP	0.5	0.2	0.3	0.3	0.3

6.4. ESTRUCTURA EN TIEMPO REAL

Para llevar a cabo la implementación de los algoritmos realizados en tiempo real se muestra un diagrama a bloques 6.3 de la obtención de los datos de la temperatura por medio de los sensores en la incubadora, teniendo en cuenta que las señales obtenidas del sensor se encuentran en un rango de voltaje muy bajo, por lo tanto se debe de amplificar para obtener un voltaje representativo que sea útil para la tarjeta de adquisición de datos, así como un aislamiento para aumentar la impedancia de salida para proteger a la misma, de este modo una vez acondicionada la señal, los datos adquiridos por la tarjeta serán introducidos en la pc, la cual, primero calculará el GTE utilizando la diferencia entre el sensor 1 que corresponde a la temperatura de la piel del neonato y el sensor 2, correspondiente a la temperatura del microambiente de la incubadora, posteriormente se calculará el ΔGTE . Estas dos variables servirán para la identificación de la temperatura central, así como para la identificación de humedad relativa. Las pruebas en tiempo real se llevaron a cabo en MATLAB, utilizando el toolbox de adquisición de datos, los cuales son programas hechos en funciones M.

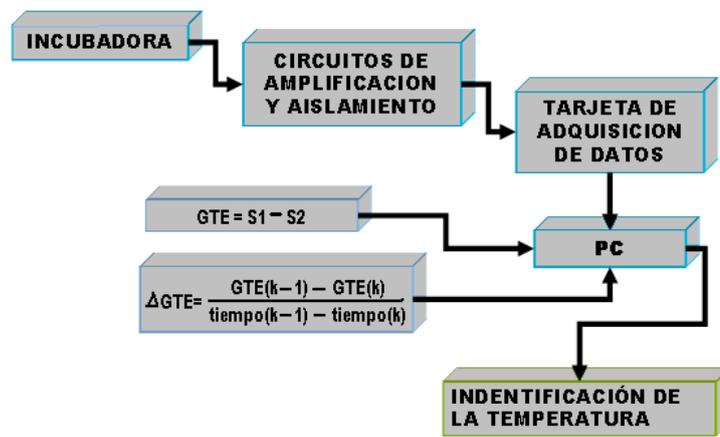


Figura 6.3: Diagrama a bloques del sistema para la identificación de la temperatura central en tiempo real

Capítulo 7

RESULTADOS

7.1. INTRODUCCIÓN

Teniendo las bases, tanto fisiológicas, médicas, así como la importancia que tiene las técnicas de inteligencia artificial (redes neuronales, lógica difusa y la fusión de estas dos técnicas llamados sistemas neurodifusos), utilizadas para la identificación de sistemas no lineales, aplicando nuevos algoritmos de aprendizaje, tanto para las redes neuronales como para los sistemas neurodifusos, ya descritos y diseñados los algoritmos para la identificación de la temperatura. El siguiente paso es el desarrollo de los programas tanto de la red neuronal como para el sistema neurodifuso, esto con la intención de hacer una comparación entre los dos algoritmos y observar cual de los dos algoritmos identificar la temperatura más rápidamente, primeramente se diseñó un software que simulara el comportamiento de la piel del neonato y la temperatura en el interior de la incubadora, lo cual se puede calcular el GTE y el ΔGTE . Teniendo los patrones de entrada para la identificación de la temperatura central de incubadora, se realizaron simulaciones utilizando la red neuronal

con el algoritmo de aprendizaje de la extensión de los filtros de Kalman, del mismo modo se hicieron simulaciones del sistema neurodifuso con el mismo algoritmo de aprendizaje. Posteriormente teniendo un prototipo de una incubadora neonatal con los aditamentos descritos en capítulos anteriores y principalmente la utilización del sistema de calefacción que cuentan con los sensores de temperatura, los ventiladores y el actuador, los cuales servirán para realizar pruebas en tiempo real para la identificación de la temperatura central de la incubadora, utilizando el GTE y el ΔGTE . Los programas realizados para las pruebas de simulación y las pruebas en tiempo real se realizaron en MATLAB en funciones M, de los cuales se mostrarán las gráficas obtenidas, así como los parámetros iniciales de la red neuronal y del sistema neurodifuso para la identificación de la temperatura en la incubadora.

7.2. PRUEBAS DE SIMULACIÓN

7.2.1. IDENTIFICADOR DE LA TEMPERATURA CENTRAL UTILIZANDO LA RED NEURONAL

Para el software que se diseñó para la simulación del paciente y la temperatura dentro de la incubadora, se utilizaron valores de temperatura que se encontrarán en condiciones que no fueran normales con la finalidad de observar el comportamiento del identificador, de la misma manera con las dos temperaturas tanto del paciente como la del interior de la incubadora, se calcularon los valores del GTE y ΔGTE . Las temperaturas que se eligieron fueron las siguientes:

$$T_{piel} = 35^{\circ}C$$

$$T_{Incubadora} = 25^{\circ}C$$

Para la simulación de la temperatura, se agregó una variación aleatoria con una media de 0 y una varianza de 1, que es un valor muy pequeño, el cual contiene ruido producido por el sensor o por una fuente externa, los resultados obtenidos del *GTE* se pueden observar en la fig. 7.1 .

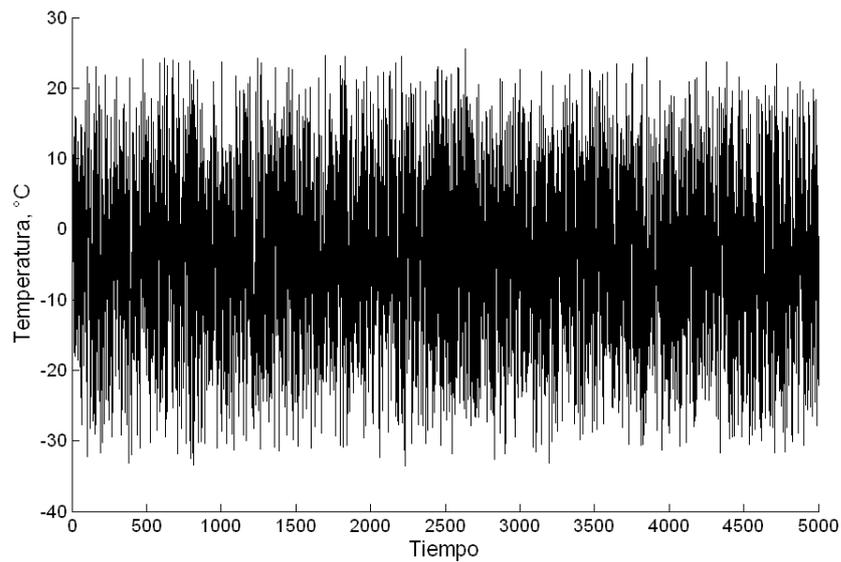


Figura 7.1: Gradiente de temperatura externo (GTE)

Como puede observarse en *GTE*, presenta variaciones que no se encuentran dentro de los rangos permisibles ($0.5^{\circ}C$), esto se hizo con la intención de tener una entrada con demasiado ruido, y de esta manera observar que sucede con la identificación de la

temperatura. La otra variable de entrada es el ΔGTE , la cual se puede observar en la fig. 7.2.

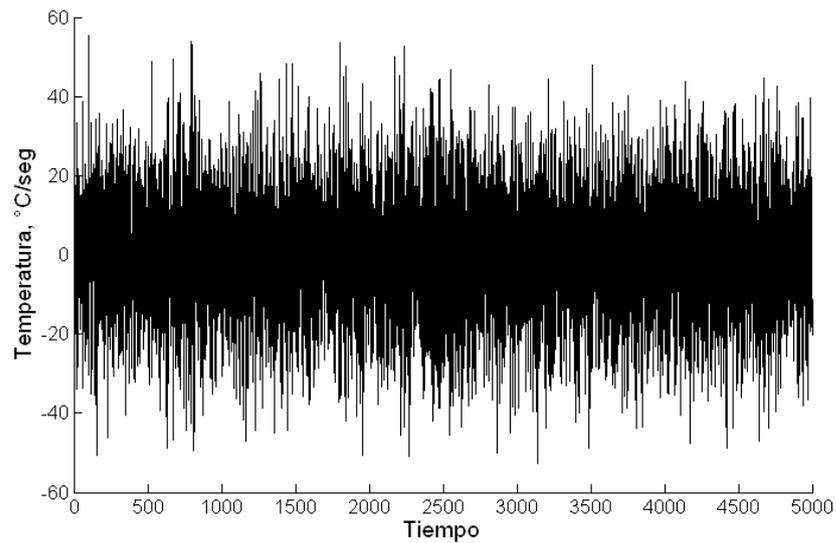


Figura 7.2: Cambio del gradiente de temperatura externo respecto a el tiempo (AGTE)

Como anteriormente se mencionó, el $AGTE$ muestra el cambio del GTE respecto al tiempo, lo que representa una aproximación de la velocidad del GTE .

Para la identificación de la temperatura, la red neuronal requiere de un proceso de entrenamiento, lo cual se realiza mediante la elección de valores iniciales de los pesos y las varianzas en cada capa de la red descritas en la ley de aprendizaje con la EFK 3.115. Los valores iniciales, los cuales tuvieron una mejor respuesta para la identificación fueron los siguientes:

Tabla 3. parámetros de la red neuronal

	W_{ik}^l	$P_{ik}^l(k-1)$
capa 1	0.6	0.02
capa 2	0.1	0.09

La respuesta que se obtuvo para la identificación de la temperatura con una referencia de $37\text{ }^\circ\text{C}$ se muestra en la fig.7.3 .

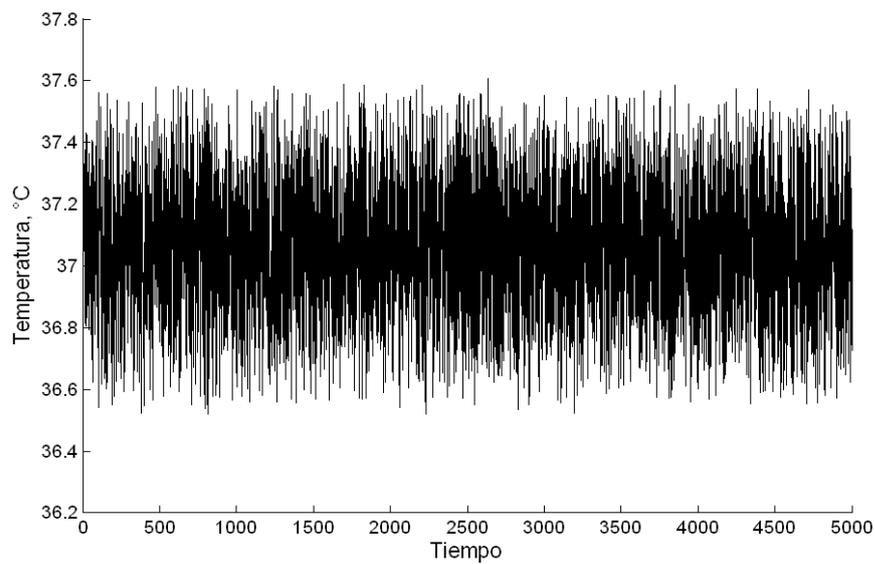


Figura 7.3: Salida de la red neuronal

La respuesta de la red neuronal muestra la identificación de la temperatura ($37\text{ }^\circ\text{C}$). Las cuales presentan variaciones debido al tipo de entrada que se eligió.

La convergencia del error de identificación de la temperatura se muestra en la fig. 7.4 :

El error obtenido es el índice de desempeño que se obtuvo al identificar la temperatura, el cual es muy pequeño (cercano a cero).

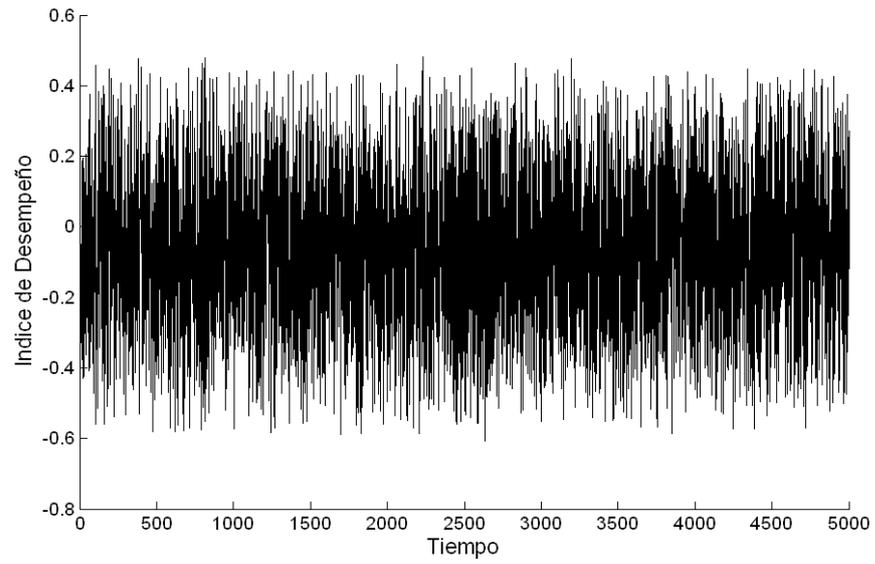


Figura 7.4: Error obtenido en la identificación de la temperatura

Recordemos que los valores iniciales de los pesos y las varianzas se actualizarán,

con la finalidad de minimizar el índice de desempeño, en la fig. en la fig. 7.5 observamos la evolución que tiene los pesos para el entrenamiento de la red neuronal.

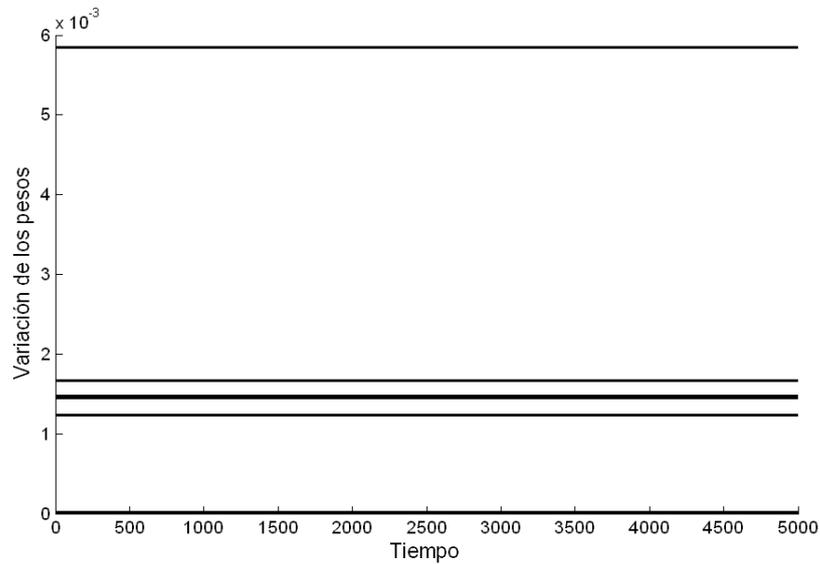


Figura 7.5: Dinámica de los pesos durante la identificación de la temperatura

Los valores de los pesos tienden a un valor constante en un tiempo muy pequeño, lo cual coincide con la identificación de la temperatura. Respecto a las varianzas de los pesos, los resultados que se obtuvieron para observar el comportamiento de las mismas, se pueden apreciar en la fig. 7.6 :

La varianza de los pesos cambiaron, conforme el aprendizaje de la red se iba realizando, tendiendo a un valor constante de 1 en un tiempo muy pequeño.

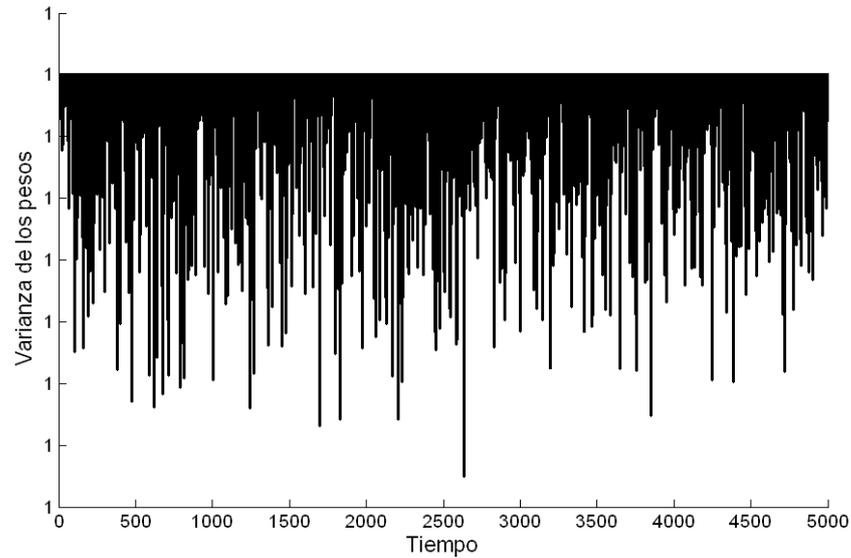


Figura 7.6: Varianza de los pesos, durante la identificación de la temperatura

7.2.2. IDENTIFICADOR DE LA TEMPERATURA CENTRAL UTILIZANDO EL SISTEMA NEURODIFUSO

De igual manera para obtener un ajuste de los parámetros para el entrenamiento del sistema neurodifuso, empezando con las variables de entrada, llamada variables lingüísticas, así como los términos lingüísticos para cada una de las variables de entrada, se seleccionaron los siguientes valores iniciales, los cuales se observan en la tabla 4.

Tabla 4. Parámetros de las funciones de membresía de tipo gaussiano, así como los términos lingüísticos para cada variable de entrada para la identificación de la temperatura.

Variable Lingüística	Tér. Lingüístico	Centro	Desv. Estandar	Varianza
$GTE(u_1)$	Muy negativo	2.0	-1.0	0.02
	Negativo	5.0	0.5	0.01
	Cero	6.0	1.0	0.02
	Positivo	8.0	1.5	0.02
	Muy positivo	10	2.0	0.01
$\Delta GTE(u_2)$	Muy negativo	1.5	-2.0	0.02
	Negativo	1.8	-1.5	0.01
	Cero	3.0	1.0	0.02
	Positivo	3.6	1.2	0.01
	Muy positivo	4.2	1.5	0.02

El sistema neurodifuso requiere de la matriz de conocimiento difuso (FAM) que

son las reglas que se obtiene al combinar cada uno de los términos lingüísticos de la primer variable lingüística, con los segundos terminos lingüísticos de la segunda variable lingüística, estos valores irán cambiando mediante la actualización de los pesos y los parámetros de las funciones de membresía de tipo gaussiano, resumiendo lo antes dicho en la tabla 5 queda de la siguiente forma:

Tabla 5. FAM para la identificación de la temperatura

Temperatura central		ΔGTE				
		MN	N	C	P	MP
GTE	MN	0.1	0.2	0.3	0.1	0.3
	N	0.1	0.2	0.2	0.1	0.3
	C	0.2	0.2	0.3	0.5	0.3
	P	0.2	0.2	0.2	0.5	0.3
	MP	0.5	0.2	0.3	0.3	0.3

La evaluación del sistema neurodifuso, se observara en un conjunto de gráficas,

en las cuales mostrarán la evolución, tanto de la salida y su error, así como la variación de los parámetros que se ajustarán durante el entrenamiento del sistema neurodifuso. Las entradas para el entrenamiento del identificador tienen las mismas características que se utilizaron para la red neuronal. Del mismo modo, se eligió una referencia de $37\text{ }^{\circ}\text{C}$ para la identificación, lo cual tuvo un comportamiento en la salida la cual se puede observar en la fig. 7.7.

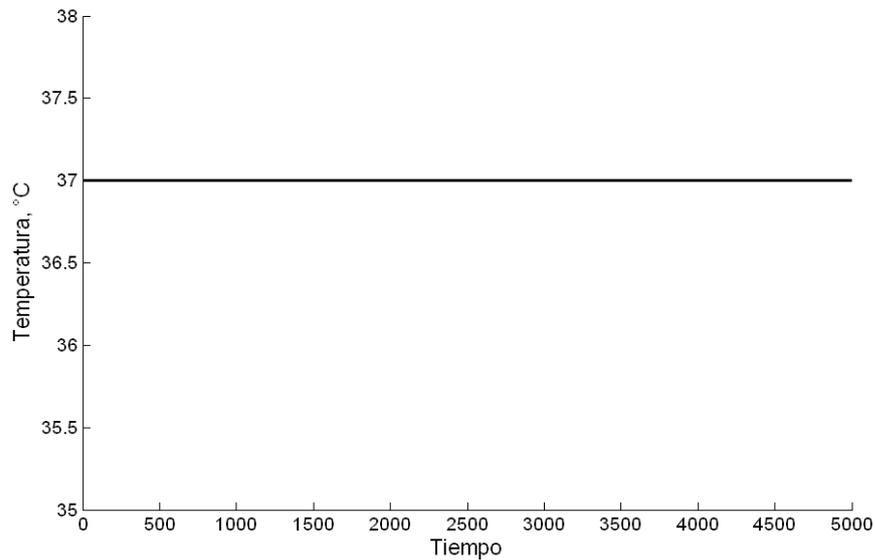


Figura 7.7: Salida del sistema neurodifuso

Observamos que la señal de referencia que se propone, en un tiempo muy pequeño se logra identificar. También se nota que no hay variaciones aleatorias como las observadas en la red neuronal. El desempeño de la identificación de la temperatura se muestra en la fig. 7.8.

Observamos que el valor del error converge a cero en un tiempo muy pequeño. De la misma manera que la red neuronal los valores iniciales de los pesos, los parámetros de las funciones de membresía y las varianzas de cada uno de estos parámetros que son importantes para el aprendizaje del sistema neurodifuso cambiarán sus valores, los cuales se muestran en la fig. 7.9.

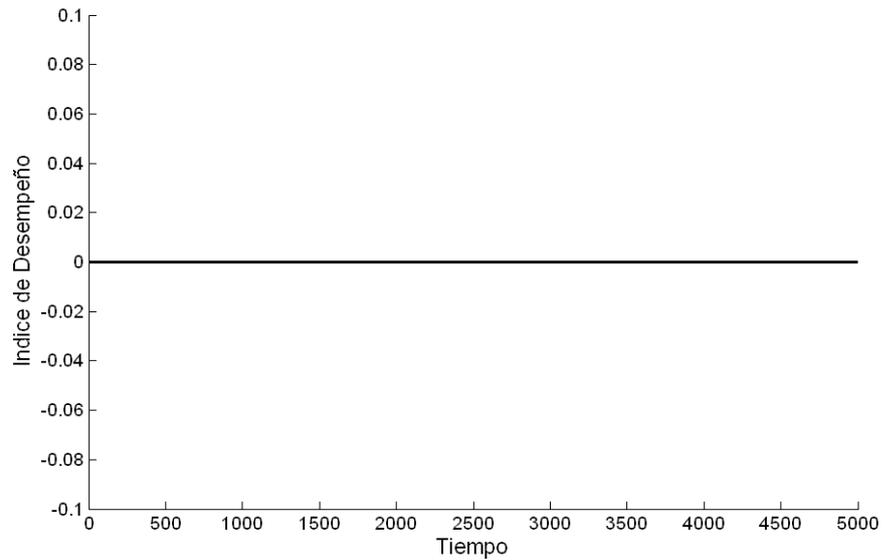


Figura 7.8: Comportamiento del error del sistema neurodifuso

La variación de los centros, muestra un comportamiento constante durante el proceso de actualización, lo cual coincide con la identificación de la temperatura, al llegar a el valor constante en un tiempo muy pequeño. De la misma manera la actualización de los pesos y de las funciones de membresía presenta un valor de covarianza que tiende a un valor de 1, lo cual se obtuvo el mismo valor en la red neuronal. En la fig. 7.10 se puede observar el comportamiento de los centros.

Cabe resaltar que en las gráficas presentadas, solo para un parámetro de las funciones de membresía se presentan variaciones semejantes, solo para mostrar que los pesos, los centros y las desviaciones estándar sufren modificaciones al comenzar el entrenamiento

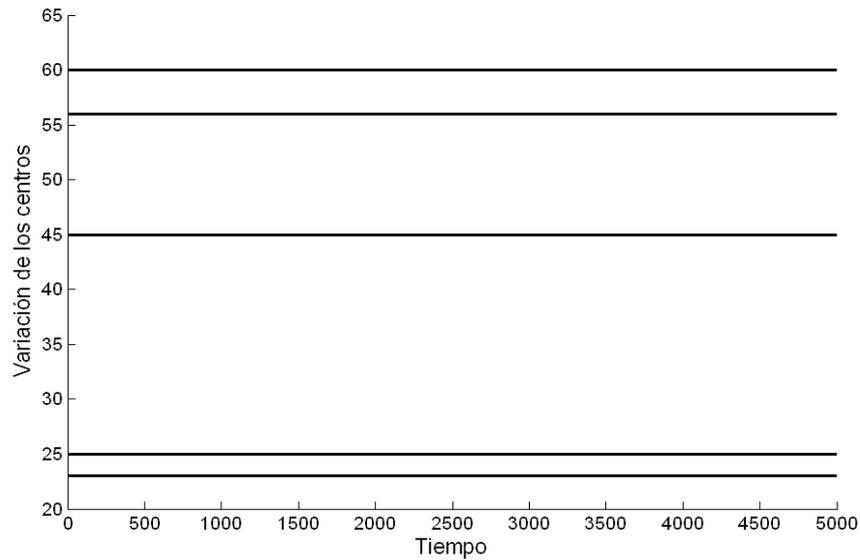


Figura 7.9: Dinámica de los centros de las funciones de membresía de tipo gaussiano del sistema neurodifuso.

7.3. PRUEBAS EN TIEMPO REAL

Para las pruebas en tiempo real, los programas realizados en funciones M en MATLAB utilizados para las simulaciones, se les adicionó un programa llamado data acquisition (DAQ) que se encuentra en la librería de MATLAB utilizadas únicamente para funciones M. Basicamente la librería DAQ son una serie de comandos para configurar el dispositivo de adquisición de datos (tarjeta de adquisición de datos, puerto paralelo, tarjeta de sonido, etc.). En este caso se utilizó de dispositivo una tarjeta de National Instruments (PCI-6024E), la cual tiene las siguientes características:

- 16 ADC

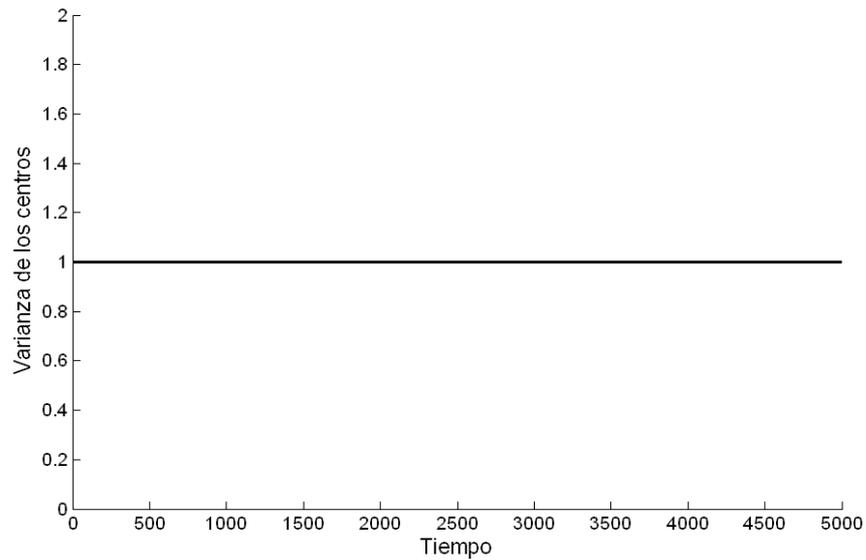


Figura 7.10: Varianza de los centros de las funciones de membresía de tipo gaussiano

- 2 DAC
- 8 Lineas Digitales TTL (IN/OUT)
- 2 contadores temporizadores (UP/DOWN)
- Margen Dinámico desde $\pm 0,05VA \pm 10V$
- Frecuencia máxima de muestreo de 200000 Muestras/s
- 2 salidas analógicas con salidas máximo de 110V

Tomando en cuenta la frecuencia de muestreo de la tarjeta, se seleccionó para el programa en tiempo real, 1000 muestras por segundo, con la finalidad de evaluar el comportamiento del identificador.

Para las mediciones en tiempo real descrito en la metodología, los elementos necesarios para llevar a cabo estas pruebas, se pueden apreciar mejor en un diagrama a bloques

de los elementos físicos, como son el prototipo de la incubadora neonatal, los sensores de temperatura (a), los circuitos de aislamiento y amplificación (b), la tarjeta de adquisición de datos (c), y la pc (d), la cual va a realizar el cálculo numérico, y nos entregara los resultados de la identificación de la temperatura mediante gráficas que describan el comportamiento de la red neuronal y del sistema neurodifuso, estos elementos se pueden observar en la fig. 7.11.

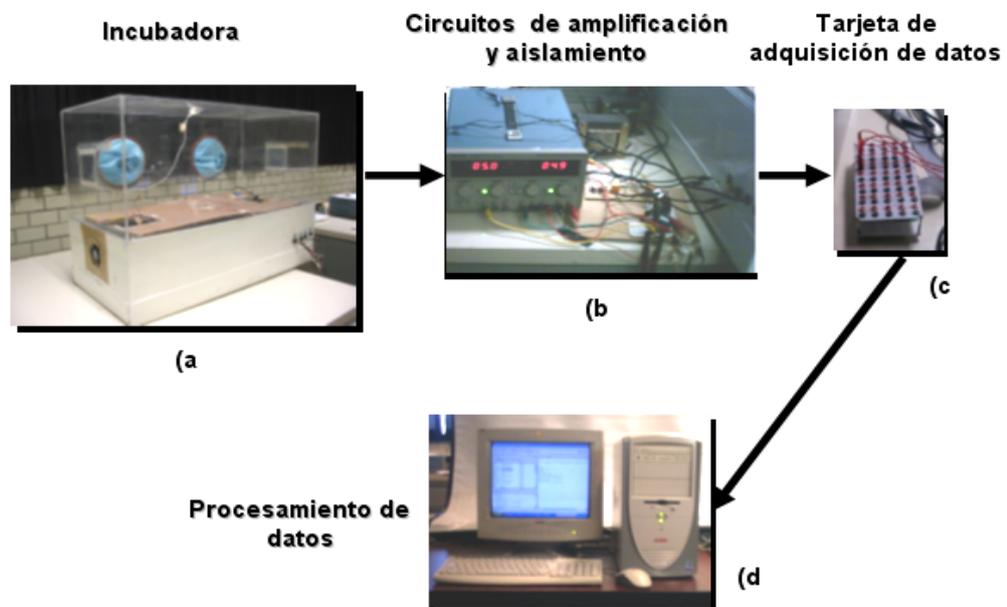


Figura 7.11: Diagrama esquemático para la identificación en tiempo real

7.3.1. IDENTIFICACIÓN DE LA TEMPERATURA CENTRAL DE LA INCUBADORA CON LA RED NEURONAL

De este modo para la evaluación del identificador de temperatura utilizando la red neuronal, el primer paso consiste en calentar el interior de la incubadora por medio del actuador (resistencia de alta potencia), la cual por medio de las mediciones de las variables de entrada GTE y ΔGTE , identificaremos la temperatura central. La salida del identificador es obtenida mediante una gráfica que nos muestre la evolución del sistema fig. 7.12.

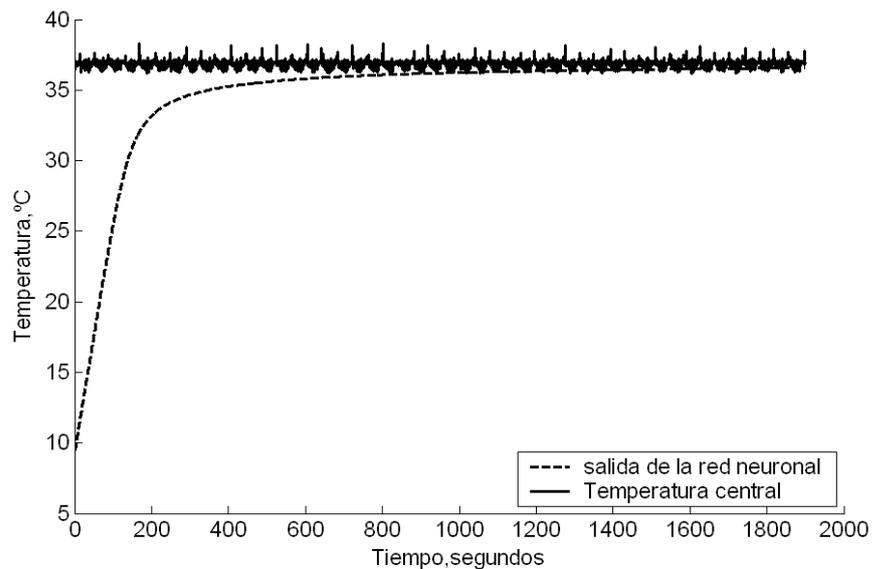


Figura 7.12: Comportamiento de la salida de la red neuronal

Observamos en la salida de la red la convergencia a un valor de temperatura central de aproximadamente $37^{\circ}C$ (esta temperatura es adecuada para las condiciones que necesita el recién nacido prematuro), en un tiempo de 27 segundos. Las perturbaciones que

se observan son debidas a la señal del sensor. El desempeño de la red neuronal se puede observar mediante el error de identificación, el cual converge a cero, mediante la evolución del entrenamiento de la red, fig. 7.13.

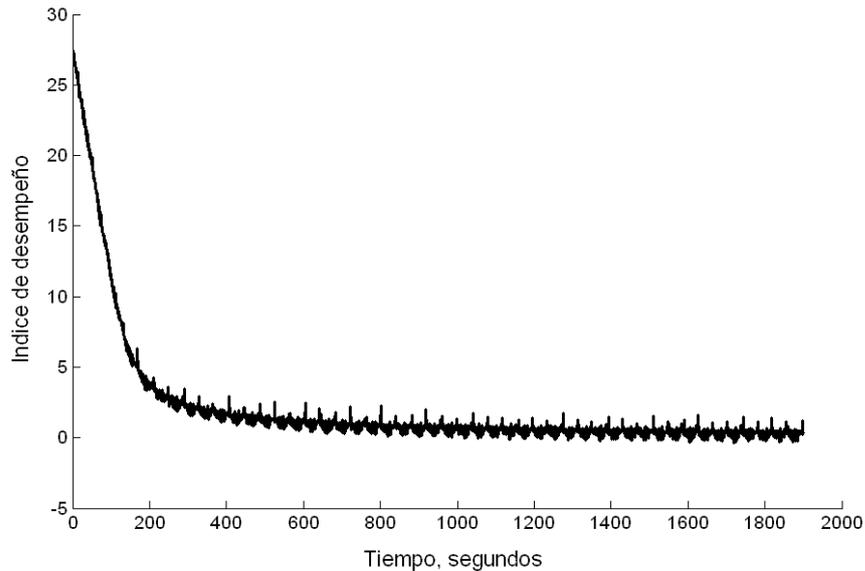


Figura 7.13: Error de Identificación de la temperatura central de la incubadora

Como se mencionó anteriormente los parámetros de la red neuronal (pesos y varianzas), cambiaran de acuerdo a la evolución del sistema por el algoritmo de aprendizaje WEKF estudiado anteriormente, la evolución de los pesos, gráficamente se pueden apreciar en la fig. 7.14. los cuales muestran que durante el aprendizaje su magnitud aumenta, con variaciones antes de llegar a la temperatura central. Una vez que la red ha alcanzado el valor de la temperatura central la magnitud de los pesos se corrigen tendiendo a un valor en magnitud menor a las variaciones antes comentadas.

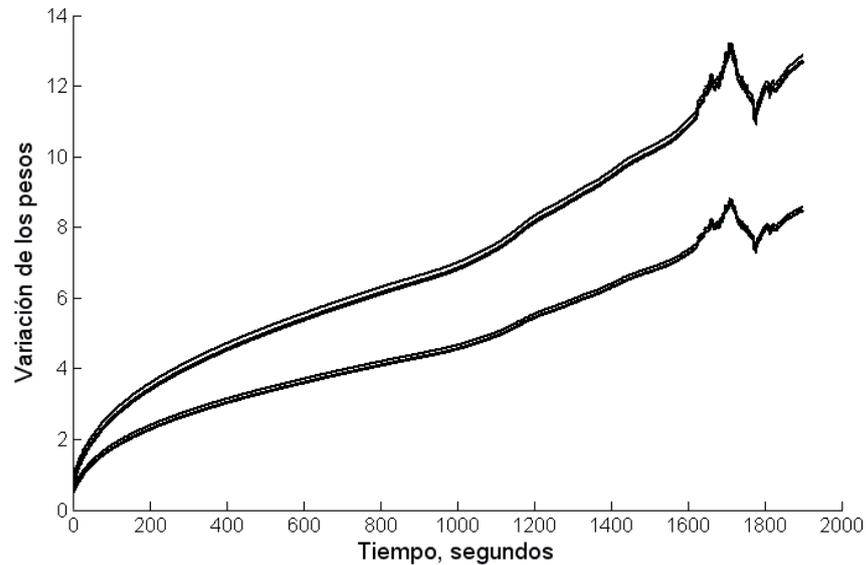


Figura 7.14: Comportamiento de los pesos, durante la identificación de la temperatura

Los otros parámetros de la red neuronal son las varianzas de los pesos, fig. 7.15, en los cuales se observa que convergen a un valor constante conforme la identificación de la temperatura se va logrando, claramente se observa que el valor de las varianzas no tienden a un valor de 1, mientras que en las simulaciones se tenía este valor cuando la salida del sistema tendía a $37^{\circ}C$.

7.3.2. IDENTIFICACIÓN DE LA TEMPERATURA CENTRAL UTILIZANDO EL SISTEMA NEURODIFUSO

Para el sistema neurodifuso, la adaptación de los pesos y los parámetros de las funciones de membresía para el proceso de identificación, depende de los valores iniciales

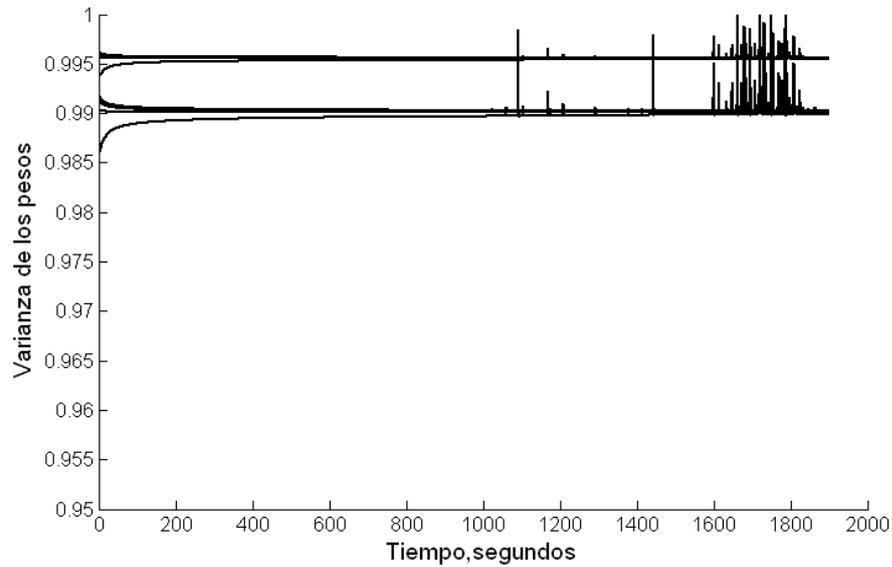


Figura 7.15: Varianza de los pesos, durante la identificación de la temperatura

de cada elemento que se van a actualizar, como son los pesos en la capa 3 y 4, así como las desviaciones estándar y los centros de las funciones de tipo gaussiano, de esta manera los valores seleccionados para la adaptación de los pesos son los siguientes: Recordemos que estos valores cambiarán conforme a la evolución del aprendizaje de la red neuronal. Los resultados obtenidos en la identificación de la incubadora, muestran una convergencia más rápida a la temperatura central, en un tiempo menor, aproximadamente en 15 segundos. En la fig. 7.16 se muestra la salida del sistema neurodifuso, persiguiendo la temperatura central de la incubadora.

De la misma manera la evaluación del comportamiento del identificador se puede observar por medio del índice de desempeño, el cual converge a un valor de cero, en un tiempo muy pequeño, fig. 7.17.

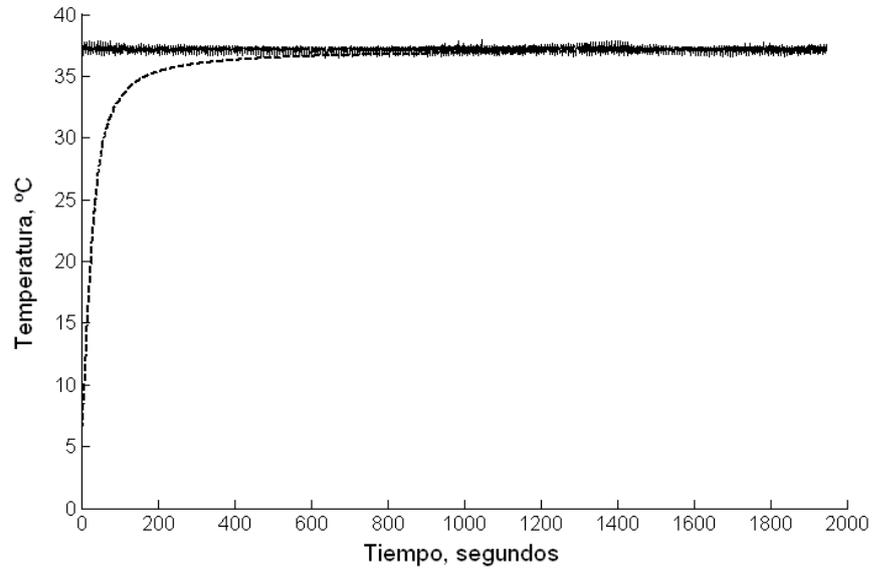


Figura 7.16: Identificación de la temperatura, mediante el sistema neurodifuso

El desempeño del sistema neurodifuso, es evaluado mediante la evolución dinámica de los parámetros de las funciones de membresía y los pesos, los cuales deben tender a un valor constante, durante el proceso de identificación, este proceso de aprendizaje se puede observar en la fig. 7.18 las variaciones de los pesos, los cuales muestran el comportamiento antes descrito.

El otro parámetro que describe la adaptación de la identificación, son las covarianzas de los pesos, los cuales se observan en la fig. 7.19 variaciones significativas, lo cual corresponde a un error muy grande en la identificación, de este modo conforme la salida del sistema se va ajustando a la temperatura central de la incubadora, las covarianzas de los pesos tienden a un valor constante.

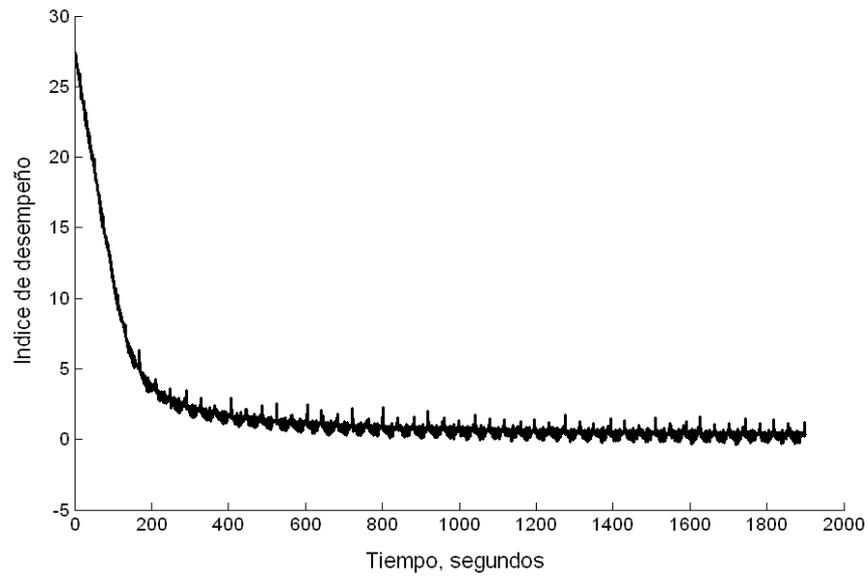


Figura 7.17: Comportamiento del error de identificación del sistema neurodifuso

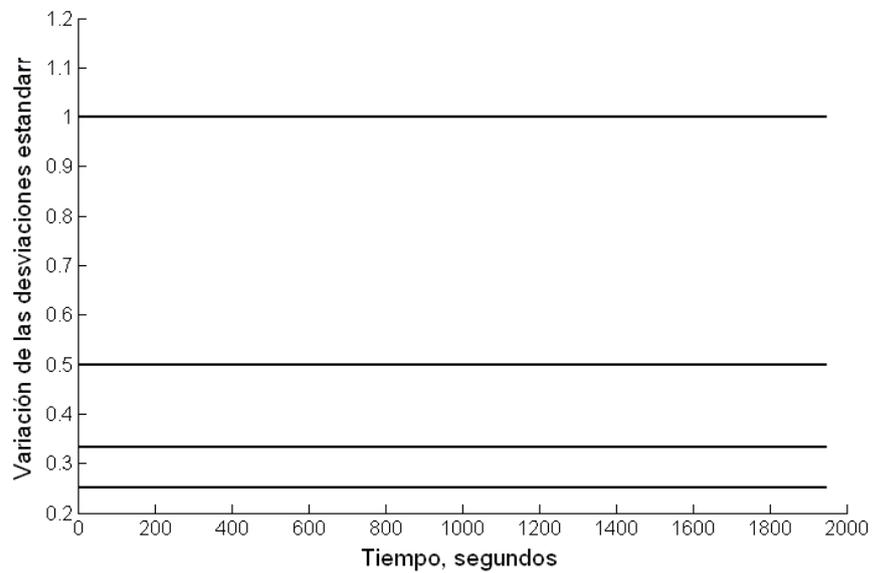


Figura 7.18: Comportamiento temporal de las desviaciones estándar de las funciones de membresía de tipo gaussiano

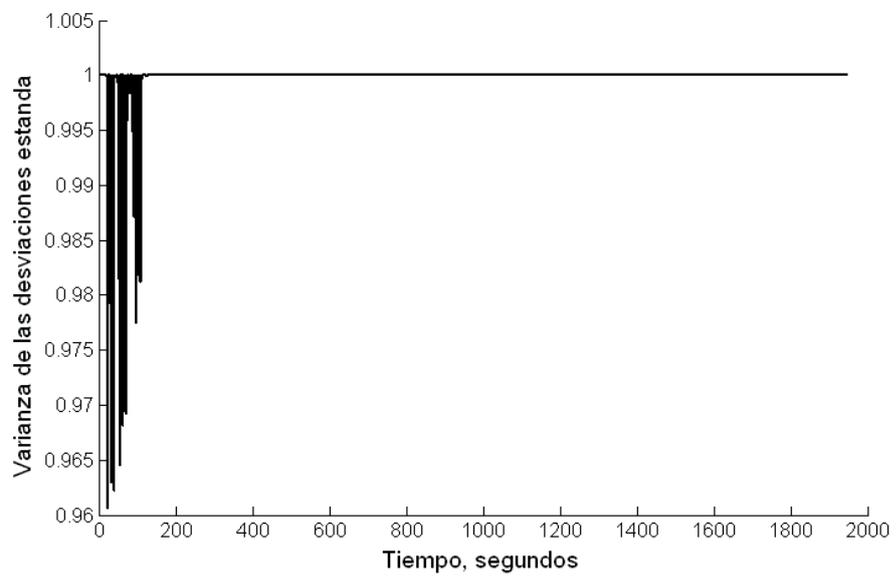


Figura 7.19: Comportamiento de las varianzas de las desviaciones estandar de las funciones de membresía

Capítulo 8

CONCLUSIONES

Se realizó un sistema para la identificación de la temperatura central, tanto pruebas de simulación como en tiempo real, utilizando el concepto de GTE, ya que es un factor muy importante para el desarrollo metabólico del recién nacido prematuro. Además se utilizaron como técnicas de identificación, las redes neuronales y los sistemas neurodifusos.

Para las pruebas de simulación, se desarrolló un software que simuló el comportamiento de la temperatura en el interior de la incubadora, así como la temperatura del neonato; lo cual se realizó mediante variaciones aleatorias de una temperatura de referencia (37°C). Las pruebas realizadas en tiempo real, se diseñaron circuitos de amplificación y aislamiento, para los voltajes que son entregados por el sensor de temperatura, así como para proteger la tarjeta de adquisición de datos respectivamente, los cuales se llevaron a cabo en un prototipo de una incubadora neonatal, diseñada de acuerdo a la norma oficial (NOM-066-SSA1-1993).

Para la identificación de la temperatura central, se diseñó una red neuronal, y un sistema neurodifuso utilizando como ley de aprendizaje de los pesos, la extensión de filtros de Kalman.

La aplicación de los algoritmos realizados para la identificación de la temperatura en una incubadora neonatal, pueden servir como un sensor de tipo virtual.

El sistema neurodifuso converge más rápidamente a la temperatura central en un tiempo menor que la red neuronal.

La identificación es muy importante para conocer la dinámica de la incubadora, debido a que no se tiene un modelo matemático que describa el comportamiento en el interior de la misma.

La extensión de este trabajo nos llevaría al desarrollo de las instrucciones de este algoritmo, de una manera más compacta, como puede ser la implementación en microcontrolador, para mejorar los instrumentos de diagnóstico.

Bibliografía

- [1] Chairez, A. et al. "Control Inteligente Aplicado a Incubadoras Neonatales". Tesis. 2003.
UPIBI. IPN
- [2] Manual de referencia Honeywell. Año 2000.
- [3] Budak, Adam. "Passive And Active Network: Analysis And Synthesis". 1991. Waveland Press, Inc. USA.
- [4] Lubchenco L., D. Hansman C. et al. "Intrauterine growth as estimated from liveborn birth". 1963. Pediatrics.
- [5] Martínez, R. Y Novoa J. "La Salud del Niño y del Adolescente". 1983. Tomo 1. Ed. Salvat. México
- [6] Revista de Neonatología ."Neonatology". primera edicion. 2001
- [7] Croenwell. L. "Biomedical Instrumentation And Measurements". 1980. Prentice Hall. USA.
- [8] Herrera V. J. "Servocontrol Programable de Incubadoras de Temperatura".
- [9] Pasquod. "La Couvesue Artificielle Chez Les Nouveau-Nés". 1899. These de país.

- [10] Passino, K. "Fuzzy Control". 1996. Addison Wesley. USA.
- [11] Brown, C.J. Harris, M. "Neurofuzzy Adaptive Modelling And Control". Prentice Hall.1994
- [12] Chin-Teng Lee. "Neural Fuzzy Systems". 1998. Ed. Prentice Hall. USA.
- [13] Hudson. L. "Neural Networks And Artificial Intelligence For Biomedical Engineering". 2000. IEEE Press. USA.
- [14] Infante O. "Control de Temperatura para Incubadora de Neonatos con Alarmas y Comunicación para Control Supervisorio".
- [15] Real Time Windows Target. Manual Para Usuario Con Matlab. 2001. Mathworks. USA.
- [16] Norma Oficial Mexicana. NOM-066-SSA1-1993. 1993. Secretaría de Salud y Asistencia. México.
- [17] Zadeh, L.A. "Fuzzy sets". 1965 Inf. Cont. 8:338-353
- [18] Zadeh, L.A. "Probability measure of fuzzy events". J. Math. Anal. Appl. 23:421-427.
- [19] Jin. L. Nikiforuk. P. N. Gupta. M. M..^Adaptive Model Reference Control of discrete-time Nonlinear System Using Neural Networks".pag. 1379-1397. 1995
- [20] Ronald, J. Williams."Some Observation on the Use of the Extended Filter as a Recurrent Network Learning Algorithm".1992
- [21] Welch, G. Bishop, G. "An Introduction to the Filter Kalman".Departmen of Computer Science. University of North Carolina. 2004

- [22] Boylestad, R. "Electrónica. Teoría De Circuitos". 1989. Prentice Hall. México
- [23] Budin M. Le Nourrison. 1900. París.
- [24] Guyton A. "Fisiología". Ed. Prentice Hall, México, D.F. 1995
- [25] Hebb, D.O. "The Organization off Behavior: A Neuropsychological Theory". New York: John Wiley.
- [26] Driscoll J. "Amplificadores operacionales". Ed. Prentice Hall. 1999.
- [27] Enciclopedia Médica Salvat. Ed. Salvat. 1998. Tomo 3.
- [28] Simon, D."Fuzzy Membership Optimization via the Extended Kalman Filter".Cleveland, Ohio, USA.2000
- [29] Rivals I. Personnaz, L. "A Recursive Algorithm Based on the Extended Kalman Filter for the Training of Feedforward Neural Models".In Neurocomputing 20(1-3): 279-294 (1998).1998
- [30] Ortiz,J. A. Felix A. Douglas E. Schmidhuberx J. "Kalman lters improve LSTM network performance in problems unsolvable by traditional recurrent nets".2003
- [31] Hanselman. D. Matlab V5.2 Guía Del Usuario. 1998. Prentice Hall. México.
- [32] Ribeiro,M. I. "Kalman and Extended Kalman Filters: Concept, Derivation and Properties". 2004
- [33] Baumgart, S."Current Concepts and Clinical Strategies for Managing Low-Birth - Weight Infants under Radiant".1987

- [34] Fanaroff, A., Martin, R. "Neonatal- Perinatal Medicine".5th ed.Mosby Year Book, St. Louis. 401- 419. 1992
- [35] Klaus, M.H, Martin R. Fanaroff, A.A. "Care of the High Risk Neonate".W.B.Saunders . Philadelphia. 114-129.1993
- [36] Marshall ,A. "Humidifying the Environment for the Premature Neonate".Journal of Neonatal Nursing. 32-36. 1997
- [37] Thomas, K. "Thermoregulation in Neonates". Neonatal network . 13 (2) 15-22. ,1994
- [38] Rutter, N. "Humidification ". Air Shields Clinical Module. 1995
- [39] Jazwinski, A.H."Stochastic Procces and Filtering Theory". Academic. Press. N.Y. 1970
- [40] Ljung, L. S. Gunnarson."Adaptive Tracking in System Identificaction". Survey. Automatica. 26.1,7-22.1990
- [41] P. S.. "Comments on Comparative Analysis of Backpropagation and the Extended Filter Kalman for Training Multilayer Perceptron". IEEE. Trans. Pattrn Analysis Machin Intelligence. PAMI-16,8,862-863