



**TRABAJO FINAL
ESPECIALIDAD EN TECNOLOGIAS DE
EXPLOTACION DE LA INFORMACION**

**CLASIFICACION AUTOMATICA
DE EMISIONES DE RADAR
MEDIANTE
REDES NEURONALES**

Autor: Ing. Armando Mario Trobiani

Directores:

M. Ing. Paola Britos

M. Ing. Claudio Rancan

2008

RESUMEN

El **radar** es considerado como el mayor avance en la detección remota de objetos, desde la invención del telescopio en 1608. Casi simultáneamente con la aparición del radar, para contrarrestar la ventaja táctica que otorgaba este dispositivo, surgió la Inteligencia Electrónica (Electronic Intelligence **ELINT**), que es el proceso de observar las señales transmitidas por los sistemas de Radar, para obtener información acerca de sus capacidades. Con ELINT es posible obtener información valiosa, manteniéndose suficientemente alejado del radar bajo observación. Obviamente ELINT es mucho más útil en situaciones de conflicto donde hay hostilidad entre dos o más partes. El valor de ELINT consiste en proveer información a tiempo sobre sistemas que constituyen una amenaza, como ser radares que guían aviones o misiles hacia sus blancos.

Se denomina Guerra Electrónica (Electronic Warfare **EW**) a la interacción entre dos o más sistemas que transmiten y/o reciben emisiones de radiofrecuencia con el propósito de utilizar el espectro radioeléctrico en beneficio propio, negando a su vez su uso al oponente (Van Brunt, 1982).

EW tiene tres grandes divisiones:

- Las Medidas de Apoyo Electrónico (Electronic Support Measures **ESM**) que tienen que ver con la búsqueda, interceptación, localización, análisis e identificación de energía electromagnética irradiada con propósitos militares.
- Las Contra Medidas Electrónicas (Electronic Counter Measures **ECM**), cuyo propósito es negar el uso efectivo del espectro electromagnético por parte del oponente.
- Las Contra Contra Medidas Electrónicas (Electronic Counter Counter Measures **ECCM**), que involucran las acciones tomadas para asegurar el uso efectivo del espectro electromagnético, a pesar de las acciones del oponente para entorpecerlo.

Una función crítica de un sistema ESM es la identificación en tiempo real del tipo de radar asociado con cada tren de pulsos interceptado. Los métodos actuales ordenan los pulsos de radar entrantes en trenes de pulso individuales, y luego comparan las características de cada

tren contra una librería de descripciones paramétricas, que contiene una lista de todos los tipos de radares conocidos.

Esta tarea constituye un desafío debido a la creciente densidad electromagnética, típica de una zona de conflicto o crisis, donde puede haber cientos de miles de pulsos por segundo, además de dispersión en los modos de trabajo de los radares militares, agilidad en los parámetros (por ejemplo en la frecuencia de repetición de pulsos, radiofrecuencia y barrido de antena), modos reservados o desconocidos para los cuales no existe registro en la librería, solapamiento de los parámetros de diferentes tipos de radares, ruidos y efectos de la propagación que conducen a una caracterización incompleta o errónea.

Imaginemos un escenario donde un avión que porta un sistema ESM está ingresando en una zona de conflicto bélico. La aeronave podría estar siendo iluminada por un Radar de Control Tiro enemigo que guía un misil antiaéreo. Si el sistema ESM fracasa en su función de identificar dicha señal y emitir un alerta, la tripulación no advertiría la existencia de esta amenaza y la aeronave correría un peligro cierto de ser derribada.

El ESM está incluido dentro del equipamiento de carácter crítico, para una aeronave que debe ingresar en una zona hostil, debido a que está directamente vinculado a la supervivencia de la misma. Por consiguiente es de vital importancia que estos sistemas cumplan con su función de manera eficiente y confiable.

En este trabajo se examinará una aproximación alternativa. Un sistema de reconocimiento que combina diversas fuentes de información para predecir el tipo de radar más probable, para cada pulso interceptado. Los parámetros del pulso que caracterizan el tipo de radar se utilizan para la tarea de clasificación, mientras que los parámetros de carácter espacial (dirección de arribo y amplitud) se utilizan para separar los trenes de pulsos correspondientes a los distintos emisores activos.

El componente clave del sistema de reconocimiento es un clasificador basado en una red neuronal, que se entrena para determinar el tipo de emisor radar presente en el ambiente. El sistema aprende en forma autónoma a identificar cada tipo específico de radar, directamente a partir de la información recolectada de campo.

Se espera que el entrenamiento directo sobre datos del medio ambiente permita lograr una predicción de la clase de radar más rápida y precisa, a la vez que se elimina la necesidad de construir y mantener a mano una librería de emisores.

AGRADECIMIENTOS

Siento que debo comenzar estas expresiones de agradecimiento, por un orden no estrictamente cronológico, dedicando este trabajo a la memoria de mis padres; quienes a pesar de las escasas oportunidades de recibir educación formal que ofrecían las condiciones sociales de su época, siempre creyeron e inculcaron en mí que el conocimiento es el único bien perdurable que ennoblece a las personas, y que el trabajo con dedicación y esfuerzo es el camino que se debe transitar para lograr todas las metas.

Casi nada en este mundo se puede obtener sin la colaboración de alguien más, y este trabajo no es la excepción. Gracias a mi familia por haber cedido generosamente la cuota de mi tiempo que les pertenece, para poder dedicarme a ser estudiante otra vez. Especialmente a Graciela por su apoyo *incondicional*, con el más amplio significado que pueda tener esa palabra.

Gracias a Paola Britos por la orientación que me brindó, por todo lo que aprendí de ella y sobre todo por alentarme a superar los temores que deambulan por la mente de alguien que pasó por las aulas universitarias hace ya tres décadas. Gracias también a Claudio Rancan por el aporte de su invaluable experiencia.

Finalmente gracias al ITBA por permitir que este sueño se haga realidad.

TABLA DE CONTENIDO

1. <u>INTRODUCCION.....</u>	1
1.1. INTRODUCCIÓN	1
1.2. ESTRUCTURA DEL TRABAJO.....	2
1.3. TERMINOLOGÍA Y ACRÓNIMOS.....	3
DE RADAR	3
DE INTELIGENCIA ELECTRÓNICA.....	3
DE REDES NEURONALES	4
2. <u>PRINCIPIOS BASICOS DE RADAR</u>	6
2.1. INTRODUCCIÓN	6
2.2. DETERMINACIÓN DE LA POSICIÓN DEL BLANCO	7
DISTANCIA	7
DIRECCIÓN	9
ALTURA.....	9
MOVIMIENTO.....	10
2.3. FRECUENCIAS DE RADAR	11
2.4. APLICACIONES DEL RADAR.....	12
2.5. OTROS TIPOS DE RADARES	13
EL EFECTO DOPPLER	13
EL RADAR DE SEGUIMIENTO (TRACKING RADAR).....	15
2.6. PROPAGACIÓN DE ONDAS RADAR	15
3. <u>INTELIGENCIA ELECTRONICA.</u>	17
3.1. DEFINICIÓN	17
3.2. ANÁLISIS DEL HAZ DE ANTENA	17
3.3. ANÁLISIS DEL BARRIDO DE ANTENA	19
HAZ ABANICO: BARRIDO CIRCULAR Y SECTORIAL	21
HAZ LÁPIZ: BARRIDO RASTER, HELICOIDAL, ESPIRAL Y CÓNICO.....	24
3.4. ANÁLISIS DE LA FORMA DEL PULSO.....	27
3.5. ANÁLISIS DEL INTERVALO DE REPETICIÓN DE PULSOS.....	28

3.6. DESENREDO DE TRENES DE PULSOS (PULSE TRAINS DEINTERLEAVING)	31
DESENREDO COMPUTARIZADO.....	31
ALGORITMOS BASADOS ÚNICAMENTE EN EL INTERVALO.....	32
ALGORITMOS CON MÚLTIPLES PARÁMETROS	33
4. <u>TEORIA DE LA RESONANCIA ADAPTATIVA</u>	35
4.1. TEORÍA DE LA RESONANCIA ADAPTATIVA	35
EL DILEMA ESTABILIDAD – PLASTICIDAD	35
RELACIÓN ENTRE APRENDIZAJE, EXPECTATIVA, ATENCIÓN Y RESONANCIA.....	36
APRENDIZAJE BASADO EN SEMEJANZA Y APRENDIZAJE BASADO EN EL ERROR	37
4.2. EL CICLO DE FUNCIONAMIENTO DE UN SISTEMA ART	38
REPRESENTACIÓN DISTRIBUIDA Y REPRESENTACIÓN SIMBÓLICA VINCULADAS MEDIANTE LA RESONANCIA.....	39
RESONANCIA Y APRENDIZAJE	39
APRENDIZAJE Y BÚSQUEDA EN MEMORIA.....	40
CONTROL DE LA GENERALIZACIÓN DEL CONOCIMIENTO. EJEMPLARES Y PROTOTIPOS	40
4.3. LA RED ART 1.....	41
DESCRIPCIÓN DEL FUNCIONAMIENTO	43
CONTROL DE LA GANANCIA ATENCIONAL Y PREPARACIÓN ATENCIONAL.....	46
4.4. LA RED ART 2.....	48
4.5. LA RED ARTMAP	51
REGLA DE LOS $\frac{2}{3}$	53
CONTROL DE GANANCIA DE F_1	54
SELECCIÓN DE F_2	54
REGLAS DE APRENDIZAJE.....	55
APRENDIZAJE DESCENDENTE	55
APRENDIZAJE ASCENDENTE	56
BÚSQUEDA Y EVENTOS NUEVOS	58
VIGILANCIA Y APRENDIZAJE RESONANTE.....	58
CONTROL DE GANANCIA DE F_2	60
EL CAMPO DE MAPEO	60
LA REGLA DE LOS $\frac{2}{3}$ EN EL CAMPO DE MAPEO	61
CONTROL DE GANANCIA F^{AB}	62
ACTIVACIÓN DEL CAMPO DE MAPEO.....	62
RESET DEL CAMPO DE MAPEO Y SEGUIMIENTO DE LA SEMEJANZA.....	63

4.6. RED ARTMAP DIFUSA (FUZZY ARTMAP).....	63
RESUMEN DEL MODELO FUZZY ART	65
DINÁMICA DE UN SISTEMA FUZZY ART	69
5. <u>LA METODOLOGIA CRISP-DM</u>	73
6. <u>FASE 1: COMPRESIÓN DEL NEGOCIO</u>	76
6.1. DETERMINACIÓN DE LOS OBJETIVOS DEL NEGOCIO	76
OBJETIVOS DEL NEGOCIO	76
BACKGROUND	76
CRITERIOS DE ÉXITO DEL NEGOCIO.....	79
6.2. EVALUACIÓN DE LA SITUACIÓN	79
INVENTARIOS DE RECURSOS.....	79
REQUISITOS, SUPUESTOS Y RESTRICCIONES.....	80
RIESGOS Y CONTINGENCIAS	80
TERMINOLOGÍA	80
6.3. DETERMINACIÓN DE LOS OBJETIVOS DEL DATA MINING.....	81
LAS METAS DEL DATA MINING	81
CRITERIOS DE ÉXITO DEL DATA MINING	81
7. <u>FASE 2: ENTENDIMIENTO DE LOS DATOS</u>	83
7.1. RECOLECCIÓN DE LOS DATOS INICIALES	83
7.2. DESCRIPCIÓN DE LOS DATOS.....	83
8. <u>FASE 3: PREPARACIÓN DE LOS DATOS.....</u>	85
8.1. PREPARACIÓN DE LOS DATOS DEL PULSO RADAR.....	85
9. <u>FASE 4: MODELO</u>	86
9.1. SELECCIÓN DE LA TÉCNICA DE MODELADO	86
9.2. CONSTRUCCIÓN DEL MODELO.....	87
ARQUITECTURA DEL MODELO.....	88
PROCESAMIENTO DIFERENCIAL DE LAS DOS CADENAS	88

ACUMULACIÓN DE EVIDENCIA	90
LA RED ARTMAP PARA CLASIFICACIÓN	90
FUZZY ARTMAP	91
9.3. AGRUPAMIENTO DE PATRONES	95
ASOCIACIÓN DE DATOS.	96
MANTENIMIENTO DE TRACKS.	97
FILTRADO Y PREDICCIÓN KALMAN.....	98
ACUMULACIÓN SECUENCIAL DE LA EVIDENCIA.....	98
FUSIÓN DE LA INFORMACIÓN ESPECÍFICA Y ESPACIAL.....	98
PREDICCIÓN DESDE MÚLTIPLES VISTAS.	99
10. FASE 5: EVALUACIÓN	101
10.1. EVALUACIÓN DE RESULTADOS	101
SIMULACIONES COMPARATIVAS.	101
10.2. PROCESO DE REVISIÓN	103
CONVERGENCIA Y SEGUIMIENTO NEGATIVO DE LA SEMEJANZA	103
CLASIFICACIÓN DE DATOS INCOMPLETOS.....	104
ESTRATEGIA DEL VECTOR INDICADOR PARA COMPONENTES FALTANTES.	105
DISCRIMINACIÓN DE FAMILIARIDAD.....	108
ALGORITMO ARTMAP-FD.....	108
SELECCIÓN DEL UMBRAL DE FAMILIARIDAD.	109
APRENDIZAJE DE CLASES DESCONOCIDAS.	110
SIMULACIONES CON DISCRIMINACIÓN DE FAMILIARIDAD Y CLASES DESCONOCIDAS.	112
SIMULACIÓN CON ACUMULACIÓN DE EVIDENCIA.....	113
10.3. CONCLUSIONES	117
10.4. PRÓXIMOS PASOS	118
POSIBLES ACCIONES	118
BIBLIOGRAFÍA.....	119

1. INTRODUCCION

1.1. Introducción

Las Medidas de Apoyo Electrónico (Electronic Support Measures ESM) involucran la búsqueda, intercepción, localización, análisis e identificación de energía electromagnética (principalmente de radar) radiada con propósitos militares. Las ESM proveen información valiosa para conocimiento de la situación en tiempo real, para detección y evasión de amenazas y para el despliegue a tiempo de contra medidas (Browne, J. P. R, & Thurbon, M. T., 1998), (Wiley R. G., 1993).

Una función crítica de un sistema ESM es la identificación en tiempo real del tipo de radar asociado con cada tren de pulsos interceptado. Las aproximaciones clásicas ordenan los pulsos de radar entrantes en trenes individuales, y luego comparan las características de ese tren con una librería de descripciones paramétricas, que contiene una lista de los tipos de radares conocidos. Esta tarea constituye todo un reto debido al constante aumento de la densidad electromagnética en los teatros de operaciones modernos (un radar Doppler puede transmitir cientos de miles de pulsos por segundo); así como la multiplicación y dispersión de los modos de trabajo de los radares militares, la agilidad en parámetros como el intervalo de repetición de pulsos, la radio frecuencia y el barrido; modos desconocidos o reservados para los cuales no existen entradas en las librerías ESM, solapamiento entre los parámetros de diferentes tipos de radar; y ruidos o efectos de propagación que conllevan a una caracterización incompleta o errónea. Estos aspectos del problema imponen una gran demanda a los sistemas ESM.

En este trabajo examinaremos una aproximación alternativa. Un nuevo sistema de reconocimiento que combina diversas fuentes de información, para predecir el tipo de radar más probable por cada tren de pulsos interceptado. Los parámetros específicos de clase se utilizan para clasificar los pulsos de acuerdo al tipo de radar, mientras que los parámetros específicos de la posición espacial se usan para separar los pulsos provenientes de los distintos emisores activos. Esta separación permite al sistema acumular las respuestas del clasificador para cada emisor, y predecir por consiguiente su identidad.

Un componente clave del nuevo sistema de reconocimiento es un clasificador basado en una red neuronal, que se entrena para determinar los tipos de radares presentes en el medio ambiente. El sistema aprende autónomamente, directamente de la información recogida en campo, a identificar los rangos de los parámetros correspondientes a tipos específicos de radar. Además de evitar en parte el ordenamiento de los pulsos, el entrenamiento con información real del ambiente puede aportar una mayor precisión predictiva. Más aún, ya no resulta necesario construir a mano una librería de emisores.

Desde el punto de vista de ESM, entrenar un sistema directamente con la información del radar es un apartamiento radical de las prácticas corrientes. En la actualidad la información se recoge, analiza y combina con información previa en forma offline por expertos, para luego volcarla en librerías ESM. Nuevas librerías conteniendo descripciones explícitas de distintos tipos de radar se envían a campo, según van surgiendo las necesidades. El mayor inconveniente de la aproximación convencional es que se trata de un proceso complejo y prolongado, a la vez que no permite modificaciones rápidas de las librerías, tras el descubrimiento en campo de un nuevo tipo de radar. El uso de una red neuronal con capacidad de aprendizaje incremental ofrece un marco de trabajo para refinar los tipos de radares conocidos y agregar los desconocidos, en pleno funcionamiento.

En esta aplicación se utiliza una red neuronal fuzzy ARTMAP para clasificar los pulsos en base a los parámetros específicos de clase, y el paradigma del vecino más próximo, basado en un banco de filtros Kalman (Bar-Shalom, Y., & Li, R. A., 1993); (Blackman, 1986), para separar los pulsos a partir de los parámetros específicos de la posición espacial.

1.2. Estructura del trabajo

El presente trabajo está estructurado de la siguiente manera:

En el próximo apartado se presentan los conceptos básicos de un sistema radar, por ser éste el objeto de reconocimiento del sistema propuesto. Se describen las distintas variantes y modos de funcionamiento, así como las clases de radar y sus correspondientes aplicaciones.

En el apartado 3 se exponen los fundamentos de la Inteligencia Electrónica, entendida como el análisis de las señales electromagnéticas, para facilitar la comprensión del sistema de

clasificación. Se hace una reseña de los distintos tipos de análisis que pueden ser aplicados a una señal de radar.

El apartado 4 está dedicado a la Teoría de la Resonancia Adaptativa, paradigma sobre el que se funda el modelo de clasificador presentado más adelante. Se detallan las arquitecturas de redes neuronales que se basan en este concepto, y su evolución hasta la variante fuzzy ARTMAP, que es la empleada por el clasificador.

Del apartado 5 en adelante se siguen los lineamientos de la metodología estructurada CRISP-DM, para el desarrollo de proyectos de minería de datos.

1.3. Terminología y acrónimos

De radar

BW. Beam Width (Ancho de lóbulo). Relativo a antenas, ancho del sector de máxima radiación o recepción, generalmente tomado como el ángulo entre los puntos al 50% de potencia pico, del patrón polar de la antena.

PA. Pulse Amplitud (Amplitud de Pulso). Diferencia de potencia, expresada en dbm, entre la base y el techo del pulso.

PRF: Pulse Repetition Frequency (Frecuencia de repetición de pulsos). Inversa del PRI.

PRI. Pulse Repetition Interval (Intervalo de repetición de pulsos). Tiempo transcurrido entre los flancos delanteros de dos pulsos consecutivos, tomados al 50% de su amplitud.

PW. Pulse Width (Ancho de pulso). Tiempo entre el flanco delantero y el flanco posterior de un pulso, tomado al 50% de la amplitud.

Radar. Contracción de las palabras *radio detection and ranging* (detección y medición de distancia por radio). Dispositivo electrónico para la detección y localización de objetos, basado en la transmisión y recepción de señales electromagnéticas.

TWS. Track While Scan (sigue mientras barre). Tipo de radar que puede seguir la posición de varios blancos simultáneamente, mientras rota su antena.

De inteligencia electrónica

DOA. Direction Of Arrival (Dirección de llegada). Medida angular de la dirección de llegada de la energía electromagnética, expresada en relación a una referencia universal (como el norte geográfico) o en relación a una referencia propia (como el eje longitudinal de un avión).

ECCM. Electronic Counter Counter Measures. (Contra Contra Medidas Electrónicas). División de la Guerra Electrónica que involucra las acciones tomadas para asegurar el uso efectivo del espectro electromagnético, a pesar de las acciones del enemigo para entorpecerlo.

ECM. Electronic Counter Measures. (Contra Medidas Electrónicas). División de la Guerra Electrónica que involucra las acciones tomadas para evitar o reducir la efectividad del uso del espectro electromagnético, por parte del enemigo.

ELINT. Electronic Intelligence (Inteligencia Electrónica). Proceso de observar las señales transmitidas por los sistemas de radar para obtener información acerca de sus capacidades.

ESM. Electronic Support Measures. (Medidas de Apoyo Electrónico). División de la Guerra Electrónica que involucra las acciones tomadas para la búsqueda, interceptación, localización e inmediata identificación de energía electromagnética, con el propósito de reconocer amenazas.

EW. Electronic Warfare (Guerra Electrónica). Acciones militares que involucran el uso de energía electromagnética para determinar, explotar, reducir o prevenir el uso hostil del espectro electromagnético. Tiene 3 divisiones: ECM, ECCM y ESM.

PDW. Pulse Descriptor Word (Palabra Descriptora del Pulso). Cadena de bits que contiene los valores de todos los parámetros de un pulso.

TOA. Time Of Arrival (Tiempo de llegada). Instante de tiempo en que el pulso es detectado por el receptor, expresado en tiempo real o según una base de tiempo interna.

UAV. Unmanned Aerial Vehicle (Vehículo Aéreo no Tripulado).

De redes neuronales

ART. Adaptive Resonance Theory (Teoría de la Resonancia Adaptativa). Teoría que se inspira en los procesos por los que el cerebro humano continúa aprendiendo y reconociendo el mundo cambiante, de una forma estable, a lo largo de toda la vida. Desarrollada por Gail Carpenter y Stephen Grossberg en 1976. De esta teoría surgen arquitecturas de redes neuronales conocidas como ART 1, ART 2, ARTMAP y fuzzy ARTMAP entre otras.

FD. Familiarity Discrimination (Discriminación de Familiaridad). Una extensión de la red fuzzy ARTMAP que permite la detección de patrones de clases desconocidas.

IVS. Indicator Vector Strategy (Estrategia del Vector Indicador). Variante del algoritmo fuzzy ARTMAP para manejar componentes faltantes en los patrones de entrada o etiquetas de clase faltantes.

LTM. Long Term Memory (Memoria de largo plazo).

LUC. Learning of Unfamiliar Classes (Aprendizaje de Clases Desconocidas). Extensión de la red fuzzy ARTMAP que le permite continuar ajustando sus pesos durante la fase de prueba, a través de un aprendizaje semi supervisado. Es decir continuar el aprendizaje durante la operación.

MT-. Negative Match Tracking (Seguimiento Negativo de la Semejanza). Variante del algoritmo fuzzy ARTMAP que mejora la convergencia de la red en su fase de entrenamiento, evitando el fenómeno de proliferación de categorías.

STM. Short Term Memory (Memoria de corto plazo).

2. PRINCIPIOS BASICOS DE RADAR

2.1. INTRODUCCIÓN

Un radar es un dispositivo electrónico para la detección y localización de objetos, basado en la transmisión y recepción de señales electromagnéticas (Skolnik, 1962).

La figura 2.1.1 muestra un esquema elemental de radar, que consiste en:

- Una antena que emite la radiación electromagnética generada por alguna clase de oscilador, y posteriormente recibe el eco procedente del blanco.
- Un duplexer que es una suerte de conmutador que conecta la antena a la salida del transmisor o a la entrada del receptor, permitiendo así usar la misma antena para transmitir y recibir señales.
- Un elemento detector de energía, o receptor.
- Una pantalla gráfica para visualizar los blancos.

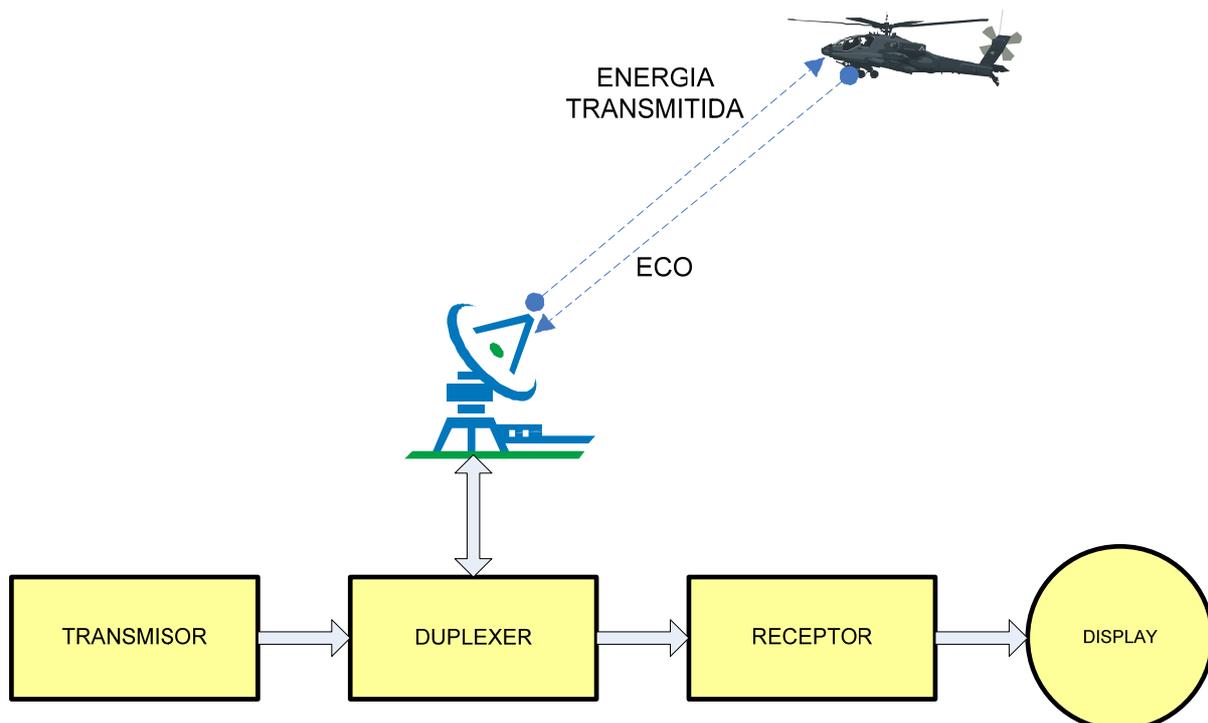


Figura 2. 1.1. Esquema elemental de un radar

El nombre radar refleja el énfasis puesto durante los primeros ensayos en la detección de la presencia y la medición de la distancia (range) de un blanco. Radar es una contracción de las palabras *radio detection and ranging*. Fue desarrollado para advertir la aproximación de aeronaves hostiles y dirigir armamento antiaéreo. Si bien un radar moderno es capaz de extraer mucho más información del blanco que simplemente su distancia, ésta sigue siendo la función más importante de un radar.

La forma de onda radar más común es un tren de pulsos angostos que modulan a una señal sinusoidal (figura 2.1.2). Si bien el pulso normalmente es de forma rectangular, no necesariamente debe serlo y podría haber otras muchas formas posibles.

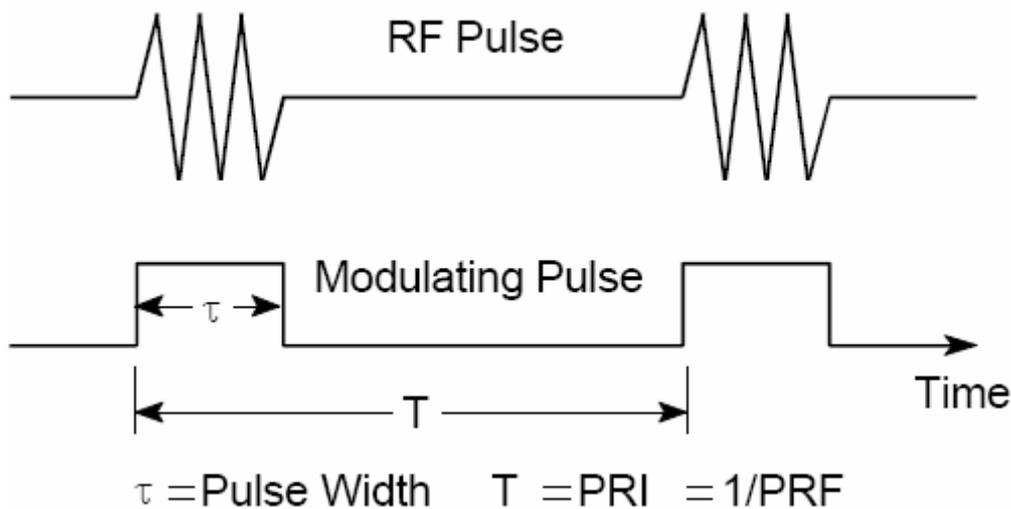


Figura 2.1.2. Forma de onda más común de un radar

2.2. DETERMINACIÓN DE LA POSICIÓN DEL BLANCO

Distancia

La distancia al blanco se determina midiendo el tiempo que le toma a la señal radar salir de la antena, llegar hasta el blanco y volver (Skolnik, 1962). Dado que la energía electromagnética viaja a la velocidad de la luz, la distancia (o range) R viene dada por

$$R = \frac{c\Delta t}{2}$$

La velocidad de la luz c es 3×10^8 m/seg, Δt es el tiempo en segundos que toma la onda en ir y volver. Cada microsegundo de viaje de ida y vuelta de la señal corresponde a una distancia de 150 metros o 0,081 millas náuticas. La milla náutica (1.852 m) es la unidad comúnmente utilizada en sistemas radar.

Una vez que el pulso es transmitido por el radar, debe transcurrir un lapso de tiempo suficiente para que el eco regrese, antes de transmitir el próximo pulso. Por lo tanto la máxima tasa a la que se pueden transmitir los pulsos queda determinada por la mayor distancia a la que se espera detectar un blanco. Si la frecuencia de repetición de pulsos fuera demasiado alta, las señales reflejadas por algunos blancos podrían arribar después de la transmisión del pulso siguiente, resultando en una medición de distancia ambigua. En efecto estos ecos, denominados de segunda vuelta, aparecerían a una distancia mucho menor que la real.

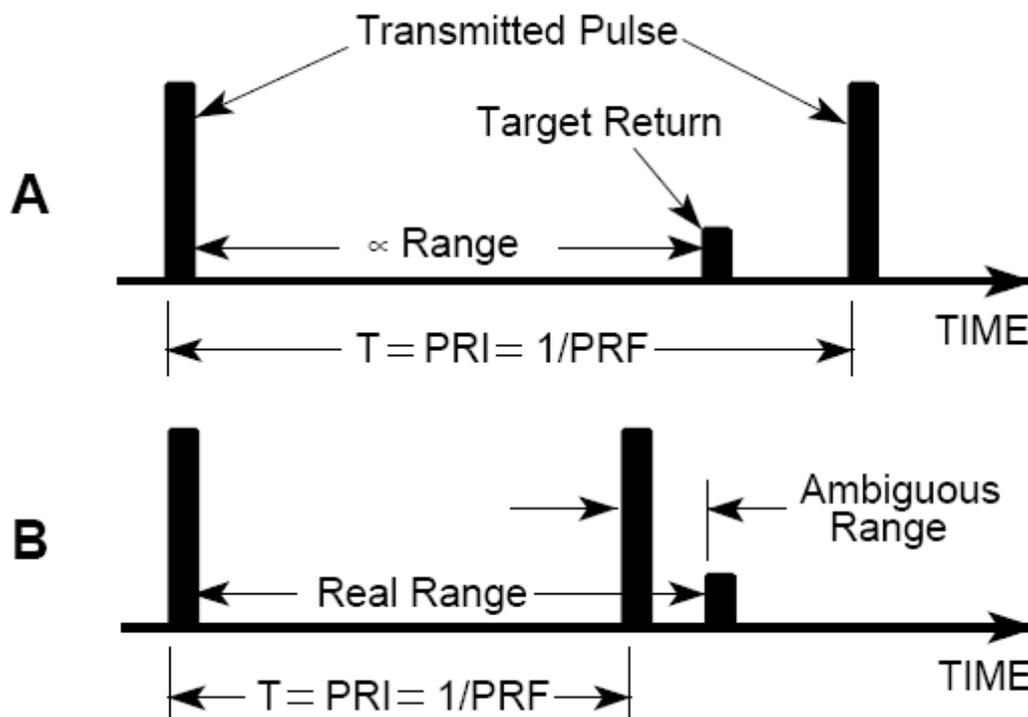


Figura 2.2.1A. Rango real

Figura 2.2.1B. Rango ambiguo por ecos de segunda vuelta

La distancia, superada la cual los blancos aparecen como ecos de segunda vuelta se denomina máxima distancia no ambigua, y está determinada por

$$R_{noamb} = \frac{c}{2PRF}$$

Donde PRF = frecuencia de repetición de pulsos en ciclos por segundo.

Dirección

La dirección, o posición angular del blanco puede determinarse a partir de la directividad de la antena, que es la habilidad de la misma para concentrar la energía transmitida en una dirección particular. Habitualmente se emplea una antena que rota sobre su eje vertical, con un lóbulo de irradiación muy angosto en el plano horizontal. De esta manera la dirección del blanco queda dada por la dirección en la que está apuntando la antena cuando se recibe el eco. La relación entre la energía que se emite realmente en el eje del lóbulo, con respecto a la que irradiaría una antena isotrópica se conoce como ganancia de antena (Skolnik, 1962). La figura 2.2.2 ilustra el patrón de irradiación típico de una antena radar en coordenadas polares.

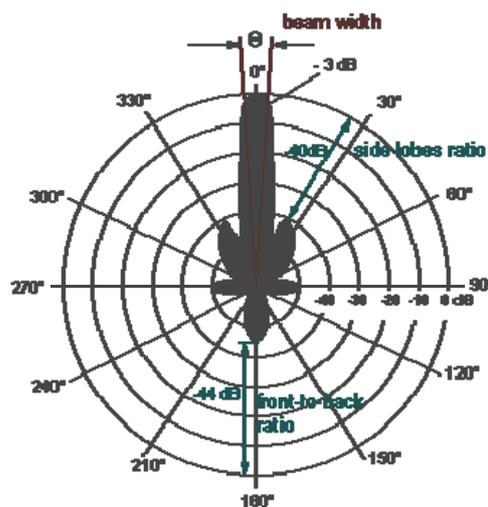


Figura 2.2.2. Patrón de irradiación en coordenadas polares

Altura

De la misma manera, si la antena rota sobre un eje horizontal, con un lóbulo de radiación angosto en el plano vertical se puede determinar el ángulo de elevación ε del blanco con respecto al plano horizontal. Con el ángulo de elevación y la distancia se calcula la altura (figura 2.2.3).

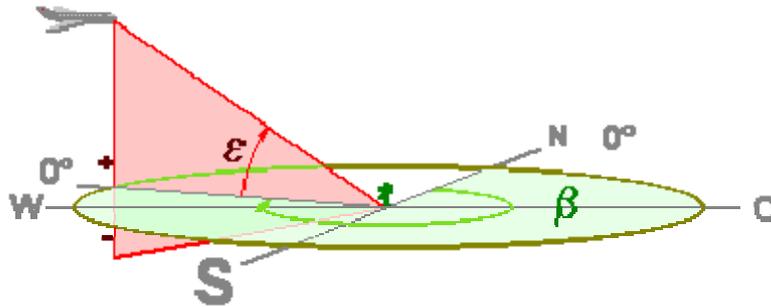


Figura 2.2.3. Definición del ángulo de elevación

Algunos radares utilizan dos antenas, una con lóbulo horizontal y otra con lóbulo vertical para la determinación simultánea de acimut, distancia y altitud del blanco, con lo que queda éste ubicado espacialmente (figura 2.2.4).

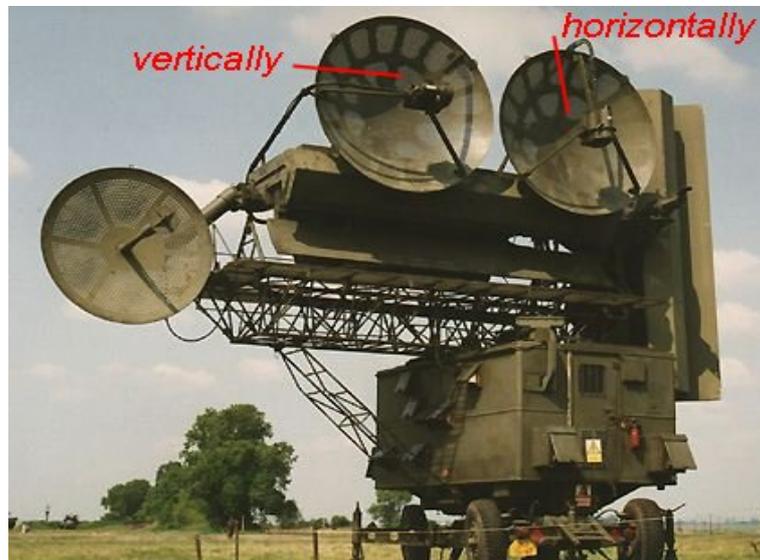


Figura 2.2.4. Radar con 2 antenas para determinación de distancia y altura

Movimiento

Si existe un movimiento relativo entre el blanco y el radar, habrá un corrimiento en la frecuencia de la portadora de la señal reflejada (efecto doppler), que es una medida de la

velocidad relativa radial del blanco. Este efecto se utiliza para distinguir entre blancos móviles y estacionarios. El corrimiento en frecuencia viene dado por:

$$f_d = \frac{2v_r}{\lambda}$$

Donde f_d = frecuencia doppler en cps.

v_r = velocidad relativa entre el blanco y el radar en m/seg.

λ = longitud de onda de la portadora radar en metros.

2.3. FRECUENCIAS DE RADAR

Existen diversos sistemas de designación de bandas de frecuencias. En los comienzos de la era del radar se empleaban letras, tales como S, X, L, etc. para designar las bandas de frecuencias de radar. Si bien la idea original de utilizar letras tenía el propósito de guardar el secreto militar, estas designaciones se mantuvieron en tiempos de paz, por fuerza del hábito y de la necesidad de contar con una nomenclatura abreviada, conservándose en la actualidad con algunas modificaciones. En la figura 2.3.1 se ilustra éste, junto con otros 2 métodos de denominación de bandas de frecuencia. La región de microondas corresponde a las frecuencias donde se utilizan circuitos de constantes distribuidas, en lugar de constantes agrupadas. Ejemplos de dispositivos de constantes distribuidas son las guías de onda, las cavidades resonantes y las antenas altamente direccionales. Una característica de esta región es que el tamaño de los componentes es comparable con la longitud de onda.

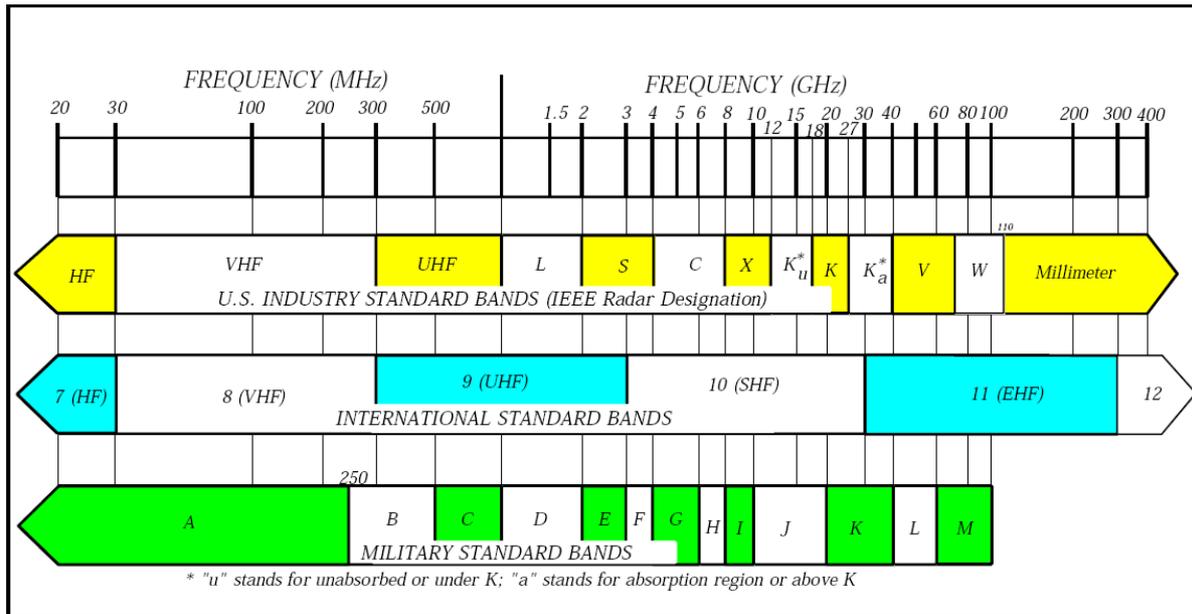


Figura 2.3.1. Espectro electromagnético

Si tenemos en cuenta su evolución histórica, el lugar del radar en el espectro electromagnético se extiende a lo largo de 11 octavas, desde los 25 MHz hasta los 70 GHz, aunque son muy pocos los radares modernos fuera del rango de 200 MHz a 40 GHz. Los primeros radares se operaban a frecuencias bajas por la sencilla razón de que no se disponía de componentes aptos para el manejo de radiofrecuencias más elevadas. Si bien es más simple lograr altas potencias de transmisión en baja frecuencia, la pobre precisión angular y resolución que se obtienen, con antenas de tamaño razonable, obliga a un desplazamiento hacia frecuencias más altas. El ancho de lóbulo de una antena es inversamente proporcional a su tamaño. Por ejemplo, a 70 GHz, con una antena con reflector parabólico de aproximadamente 30 cm de diámetro se obtiene un ancho de lóbulo de 1 grado. A 25 MHz se necesitaría una antena de unos 900 metros de diámetro para obtener el mismo ancho de lóbulo.

2.4. APLICACIONES DEL RADAR

El radar se ha utilizado en tierra, en el aire, en el mar y en el espacio. Los radares con base terrestre se utilizan mayoritariamente para la detección y localización de aviones u objetos espaciales. Los radares navales se usan para la observación de buques o aviones, o como ayuda a la navegación para localizar la línea de costa o boyas de señalización. Los radares aerotransportados se utilizan para detectar otros aviones, buques o vehículos terrestres y

también como instrumento para evitar tormentas. La naturaleza del vehículo que lo transporta y el ambiente en el cual opera, influyen significativamente en el diseño de un radar.

Aplicaciones civiles. El uso más común del radar, fuera del ámbito militar, ha sido la navegación tanto marítima como aérea. Los radares de control de tránsito aéreo vigilan las vecindades de los aeropuertos y las rutas entre terminales aéreas. En condiciones climatológicas desfavorables, el radar ha servido como control de aproximación para guiar a un avión hacia un aterrizaje seguro. En el mar también es una excelente ayuda a la navegación, especialmente en condiciones de baja visibilidad. Otra aplicación muy difundida es la detección temprana de disturbios climáticos tales como tornados y huracanes.

Aplicaciones militares. La mayoría de las aplicaciones civiles mencionadas arriba también tienen su lugar en el campo militar, especialmente en lo que se refiere a la navegación. En este ámbito se le suman las aplicaciones de vigilancia y control de armamento. Los radares de vigilancia detectan y localizan blancos para permitir una respuesta militar adecuada. Ejemplos de radares de control de armamento son los radares de seguimiento de blancos, de los sistemas de defensa antiaérea, y los de auto guiado de misiles.

Aplicaciones científicas. El uso del radar como instrumento de medición por parte de investigadores y científicos, ha incrementado ampliamente nuestro conocimiento sobre la meteorología, auroras, meteoros y objetos del sistema solar. Los radares pueden guiar vehículos espaciales y satélites, y explorar el espacio interplanetario.

2.5. OTROS TIPOS DE RADARES

El efecto Doppler

El radar típico detecta la presencia de un objeto y localiza su posición mediante la transmisión de energía electromagnética y observando el eco de retorno. Un radar pulsado transmite la energía electromagnética en lapsos breves, tras los cuales activa su receptor para esperar al eco. El tiempo transcurrido entre la transmisión del pulso y la recepción del eco es una medida de la distancia al blanco. La separación entre las señales transmitidas y recibidas queda establecida sobre la base de las diferencias en tiempo.

El transmisor radar también puede ser operado en forma continua (figura 2.5.1), en lugar de pulsada, si se haya la forma de separar la intensa señal transmitida del débil eco recibido. Una técnica posible para separar la señal transmitida de la recibida, cuando hay movimiento relativo entre el radar y el blanco, es reconocer el cambio en la frecuencia del eco provocado por el efecto doppler.

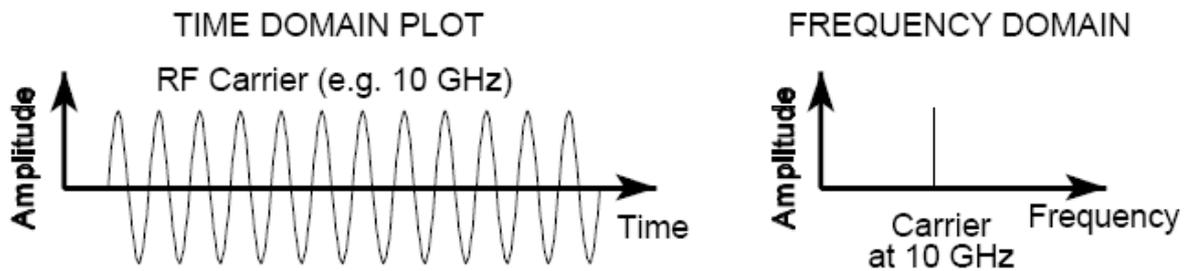


Figura 2.5.1. Onda continua

Es un hecho bien conocido en el campo de la óptica y la acústica, que si la fuente de una onda o su observador se encuentran en movimiento, habrá un cambio aparente en la frecuencia. Este es el denominado efecto doppler, y es la base de los radares de onda continua (CW). Si R es la distancia entre el radar y el blanco, el número total de longitudes de onda λ , a lo largo de la ruta de ida y vuelta es $2R / \lambda$. Dado que una longitud de onda corresponde a una excursión angular de 2π radianes, la excursión angular total Φ experimentada por la onda electromagnética, en su viaje de ida y vuelta al blanco es $4\pi R / \lambda$. Si el blanco está en movimiento, R y la fase Φ varían continuamente. La variación de Φ en el tiempo equivale a una frecuencia angular doppler ω_d dada por:

$$\omega_d = 2\pi f_d = \frac{d\phi}{dt} = \frac{4\pi}{\lambda} \frac{dR}{dt} = \frac{4\pi v_r}{\lambda}$$

Entonces la frecuencia de corrimiento doppler es

$$f_d = \frac{2v_r f_0}{c} = \frac{2v_r}{\lambda}$$

Donde f_0 = frecuencia transmitida

c = velocidad de la luz = 3×10^8 m / seg.

Si f_d se expresa en ciclos por segundo, v_r en kilómetros por hora y λ en centímetros

$$f_d = \frac{55v_r}{\lambda}$$

El Radar de seguimiento (tracking radar)

Un radar de seguimiento mide las coordenadas del blanco y provee información que puede ser utilizada para determinar la trayectoria y predecir su posición futura. Para realizar el seguimiento puede emplearse la totalidad de la información generada por el radar, o sólo una parte de ella, como la distancia, la dirección, la elevación, el corrimiento doppler, o una combinación de estos (Skolnik, 1962).

Los radares pueden ser de seguimiento continuo o del tipo “sigue mientras barre” (Track While Scan TWS). El primero produce información continua de un blanco en particular, mientras que el TWS produce muestras de muchos blancos por cada giro de antena.

En un radar de seguimiento continuo, el haz de antena se posiciona en el ángulo del blanco mediante un servo mecanismo excitado por una señal de error. El radar debe encontrar el blanco antes de poder seguirlo. Algunos radares trabajan en modo búsqueda para encontrar el blanco, y luego conmutan al modo tracking. Esta modalidad tiene ciertas limitaciones operacionales. Obviamente, operando en modo tracking, el radar no tiene conocimiento de otros blancos potenciales. Además, un radar de seguimiento cuenta con un haz de antena sumamente angosto, y si el volumen de búsqueda es amplio se requeriría mucho tiempo para encontrar al blanco. Por esta razón muchos sistemas de seguimiento por radar utilizan otro radar separado para la búsqueda, denominado radar de adquisición.

2.6. PROPAGACIÓN DE ONDAS RADAR

El medio ambiente en el cual opera el radar puede afectar considerablemente la propagación de las ondas electromagnéticas emitidas. La naturaleza de la propagación es importante dado que afecta tanto la cobertura del radar como la precisión de las mediciones. Los dos factores ambientales que más afectan la cobertura y precisión del radar son la superficie de la tierra y su atmósfera. La superficie terrestre produce reflexión de las ondas y la atmósfera, dada su constitución heterogénea, causa refracción y atenuación de las ondas.

Cuando se estudia la propagación de ondas es conveniente distinguir entre dos regiones diferentes. La primera y más importante es la región óptica o de interferencia (figura 2.6.1), que es la línea de visión (observación directa) del radar. La segunda es la región de difracción, llamada así porque está más allá del horizonte radar (figura 2.6.2). La energía electromagnética que se encuentra en esta región es debida a la difracción producida por la curvatura de la tierra o por la refracción de la atmósfera. A distancias aún mayores, la energía se propaga principalmente por dispersión troposférica.

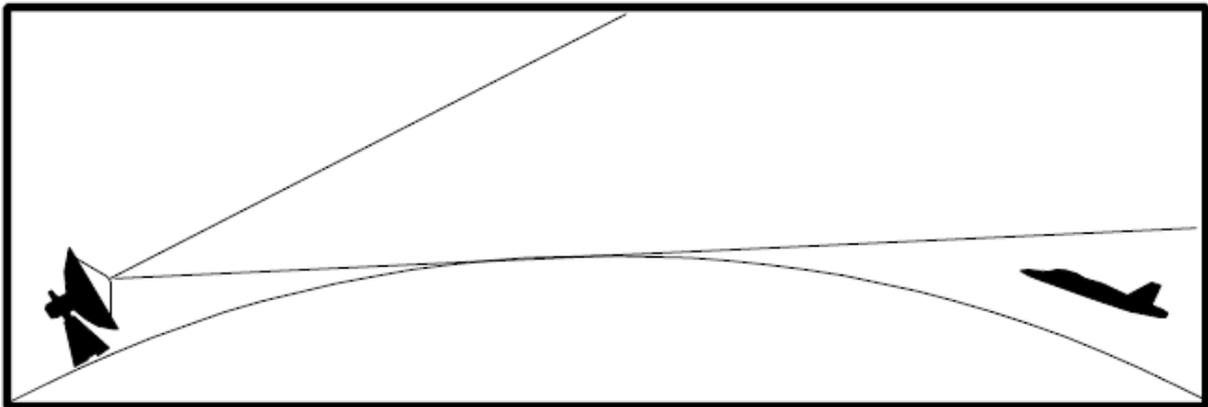


Figura 2.6.1. Región óptica

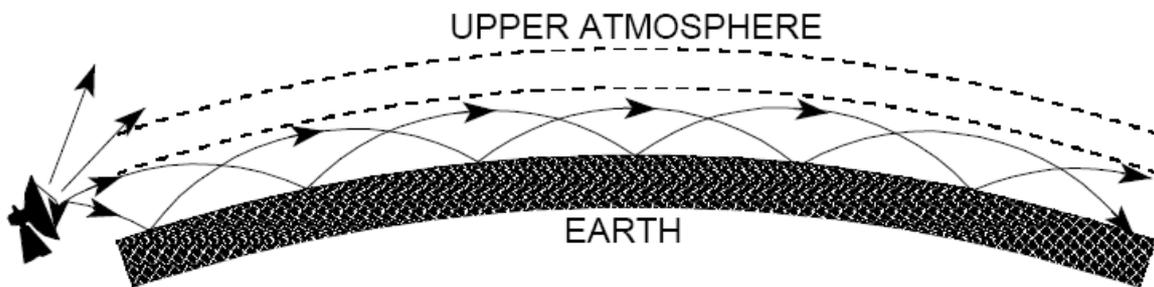


Figura 2.6.2. Región de difracción

3. INTELIGENCIA ELECTRONICA.

3.1. DEFINICIÓN

La Inteligencia Electrónica (ELINT) es el proceso de observar las señales transmitidas por los sistemas de radar para obtener información acerca de sus capacidades. Con ELINT es posible obtener información valiosa, permaneciendo a gran distancia del radar bajo observación. El valor de ELINT está en proveer información a tiempo de sistemas que constituyen una amenaza, como por ejemplo radares que guían aviones o misiles hacia sus blancos (Wiley R. G., 1993).

ELINT se refiere a la información obtenida por interceptación de señales de interés. Además de los radares, otras fuentes de señales que son objetivos de ELINT son boyas (beacons), transponders, radio enlaces y sistemas de navegación. En el sentido amplio ELINT abarca todo lo que no sea específicamente de comunicaciones, que corresponde a otra área de actividad (Wiley R. , 1985).

El sistema ELINT disfruta de una ventaja de distancia y por ende de densidad de potencia disponible, sobre el sistema radar. En efecto, la potencia transmitida por el radar vuelve al mismo en una magnitud proporcional a la recíproca de la cuarta potencia de la distancia que lo separa del blanco, mientras que la potencia disponible para el sistema ELINT es proporcional a la recíproca del cuadrado de la distancia. No obstante esta ventaja de distancia, las señales ELINT suelen ser muy débiles, y analizarlas no es una cuestión sencilla.

Los puntos que siguen describen brevemente los procesos de análisis de los distintos parámetros de la señal radar (Wiley R. G., 1993).

3.2. ANÁLISIS DEL HAZ DE ANTENA

La utilidad de un radar depende fuertemente de su habilidad para determinar la dirección de los blancos de interés, por lo tanto es un aspecto clave en su diseño. La antena de radar generalmente se diseña para focalizar la radiación en una única dirección, para poder localizar direccionalmente el blanco y también para concentrar la energía emitida e

incrementar el alcance de detección. Además de disponer de un rayo lo suficientemente fino, también se necesita un mecanismo para poder apuntarlo con precisión.

Excepto en el caso de estar siguiendo un blanco, el radar generalmente busca en el espacio moviendo su haz direccional en acimut y elevación, ya sea mecánica o electrónicamente. Este movimiento del haz, pasando por una estación ELINT, provee información acerca del patrón de radiación de la antena. La determinación de las propiedades del haz direccional se denomina *análisis del haz*, mientras que la determinación de la velocidad, la amplitud y el tipo de movimiento del haz se denomina *análisis del barrido*.

El patrón de irradiación de una antena se puede caracterizar por parámetros tales como el ancho de lóbulo en acimut y en elevación a 3db, la ganancia y los lóbulos laterales. También puede describirse mediante gráficos de intensidad de campo en función del ángulo, a una distancia fija de la antena.

Básicamente, el campo lejano de un patrón de antena puede considerarse como la suma de la contribución de varias partes del área radiante. Estas contribuciones se suman vectorialmente creando picos y valles en el diagrama de radiación (figura 3.2.1).

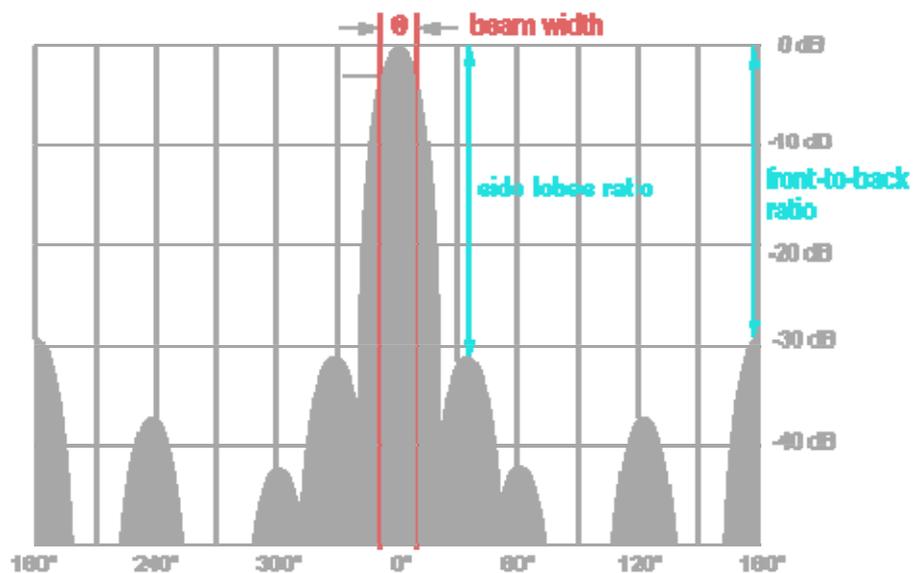


Figura 3.2.1. Patrón de irradiación de un radar

Supongamos como ejemplo que un radar de búsqueda está barriendo su haz circularmente en acimut. En la estación ELINT el nivel de señal varía con la posición angular de la antena, alcanzando un máximo cuando la misma apunta directamente hacia la estación ELINT. Esta

variación se repite en cada giro de antena, siendo el tiempo entre dos picos del lóbulo principal igual al tiempo de rotación del barrido. Registrando con precisión los distintos niveles de señal en todo el rango dinámico es posible reconstruir el patrón de irradiación. Sin embargo no es simple mantener la precisión requerida en todo el rango dinámico. La estructura de lóbulos laterales puede resultar oscurecida por el ruido del receptor o por los efectos de la reflexión. La saturación del receptor puede dificultar la determinación del ancho de lóbulo a 3db. Por estas razones, en la práctica suele utilizarse la ubicación temporal de los picos y valles, que son más fáciles de discernir que los puntos a -3db.

La figura 3.2.2 representa el rol del análisis de haz de antena en el campo de ELINT.

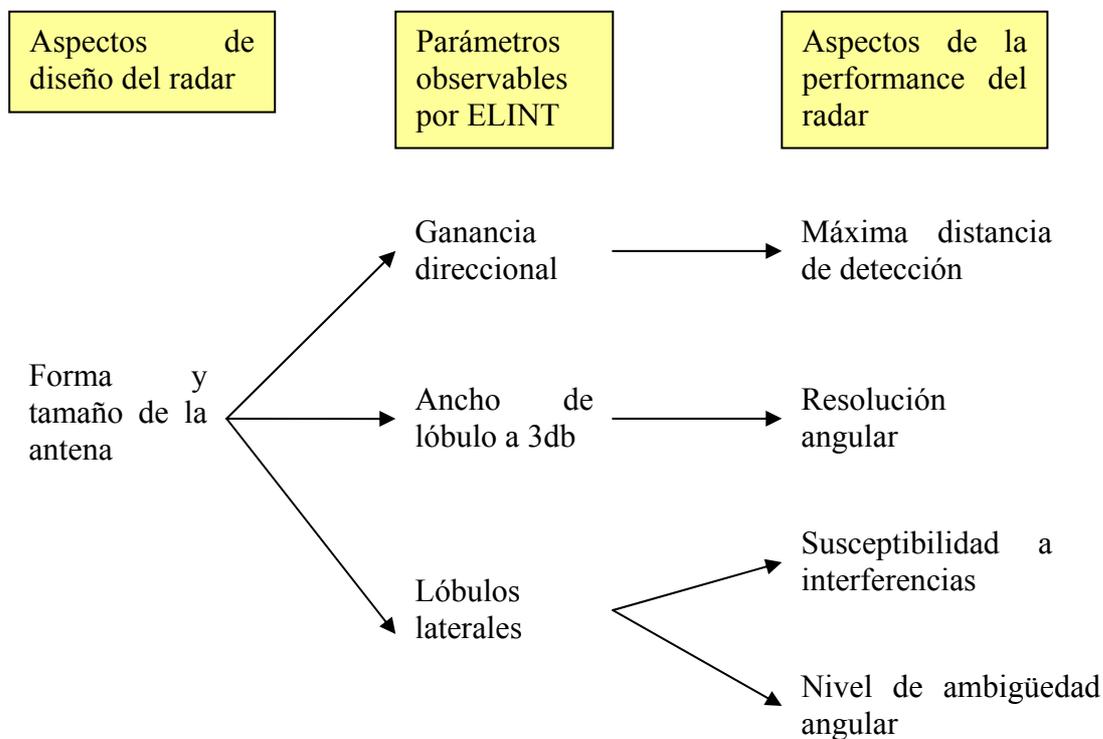


Figura 3.2.2. Rol del análisis de haz de antena

3.3. ANÁLISIS DEL BARRIDO DE ANTENA

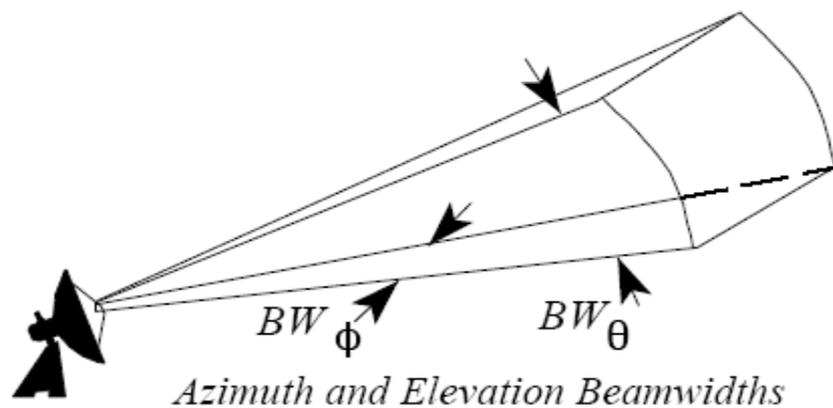


Figura 3.3.1. Anchos del haz de antena

El haz de antena de un radar generalmente cubre solo una pequeña porción de la región de interés. Para un cubrimiento hemisférico se requieren aproximadamente N posiciones independientes del haz:

$$N = \frac{2\pi}{BW_{\phi} \times BW_{\theta}}$$

Donde

BW_{ϕ} = ancho del lóbulo a 3db en acimut (radianes)

BW_{θ} = ancho del lóbulo a 3db en elevación (radianes)

El movimiento del haz, o sea su posición angular en función del tiempo se denomina barrido. El patrón de barrido se diseña para cubrir todo el volumen de interés del radar. El tamaño de este volumen varía en función del propósito del radar a cada momento. Generalmente primero se requiere una búsqueda hemisférica para adquirir un blanco, y luego se usa un volumen menor para refinar la localización. Finalmente si el radar pasa a modo seguimiento el barrido puede cesar por completo. Esta iluminación constante del blanco por parte del radar puede ser un aviso de un ataque inminente.

En radares con barrido mecánico, el patrón de barrido es por lo general periódico. En los sistemas barridos electrónicamente, el patrón de búsqueda puede ser periódico, pero puede cambiar repentinamente en respuesta a eventos del entorno.

Haz abanico: Barrido circular y sectorial

Un haz de antena que es ancho en una dirección y angosto en la dirección perpendicular se denomina haz abanico (fan beam). Este tipo de haz se utiliza para barrer una dirección solamente. El patrón de barrido clásico de un radar de largo alcance es el circular en acimut, para proveer información de dirección y distancia, pero no de elevación. La velocidad del barrido depende del alcance esperado del radar. En efecto, la probabilidad de detección de un blanco depende de la energía que impacta a dicho blanco, que, para radares pulsados, es proporcional al número de pulsos que iluminan el blanco en cada pasada del barrido. Por consiguiente, un parámetro importante en el diseño del radar es el número de pulsos por ancho de haz. Para un barrido circular este parámetro viene dado por:

$$PPBW = \frac{(ScanTime) \times BW_{\phi}}{360^{\circ} \times PRI}$$

Donde

$PPBW$ = pulsos por ancho de haz

$Scan Time$ = tiempo requerido para barrer 360° (una revolución)

BW_{ϕ} = ancho de haz a 3db en acimut (grados)

PRI = Intervalo de repetición de pulsos del radar

El diagrama de amplitud de señal versus tiempo, esperado para un barrido circular, es el representado en la figura 3.3.2

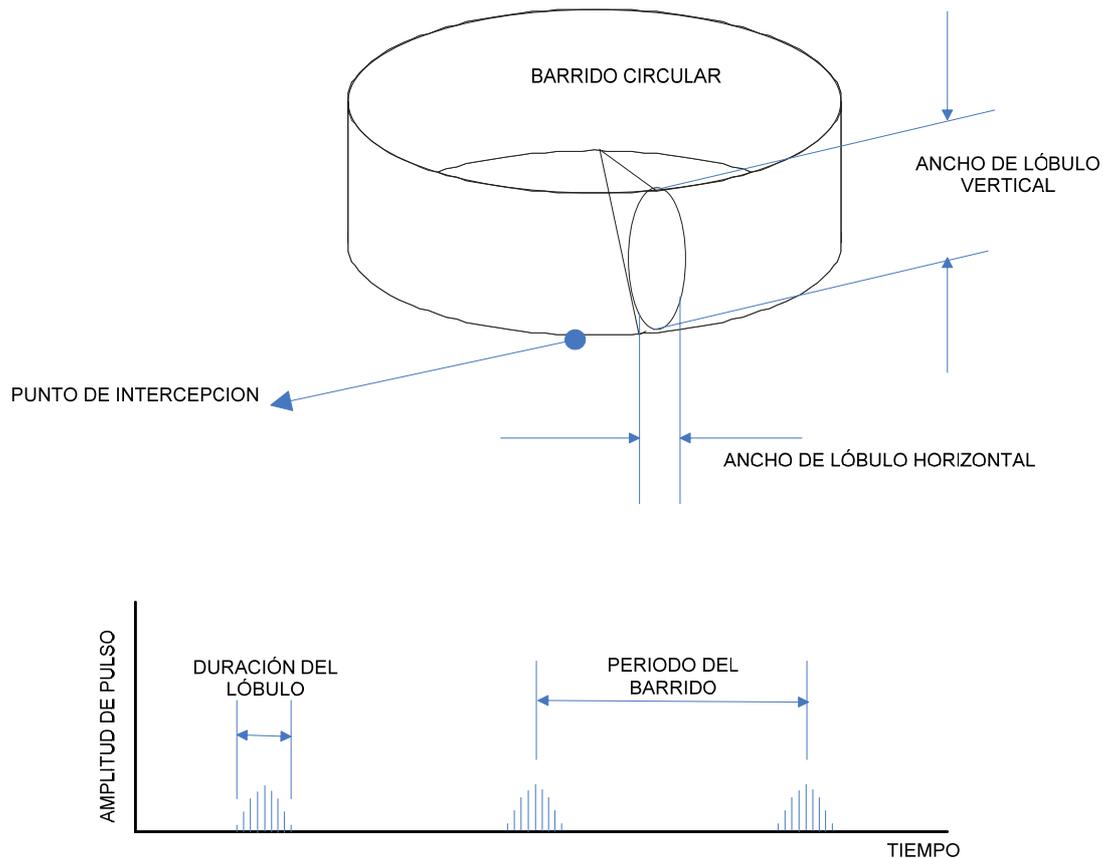


Figura 3.3.2. Diagrama de señal para un barrido circular

Para radares de largo alcance se necesita más energía sobre el blanco, y por ende más pulsos por ancho de haz. Sin embargo, también se requiere un intervalo entre pulsos más largo, para lograr un mayor rango no ambiguo. Ambas condiciones implican un barrido más lento. Los radares típicos de largo alcance (cientos de kilómetros) tienen un tiempo de barrido de entre 10 y 30 segundos.

El barrido circular es simplemente uno de los tantos barridos periódicos utilizados comúnmente. Si solo interesa una porción de toda la circunferencia acimutal, el radar puede utilizar un barrido sectorial. El barrido sectorial puede ser bidireccional o unidireccional. El patrón observado por una estación ELINT, para un barrido sectorial bidireccional, depende de la posición de la estación, tal como se representa en la figura 3.3.3.

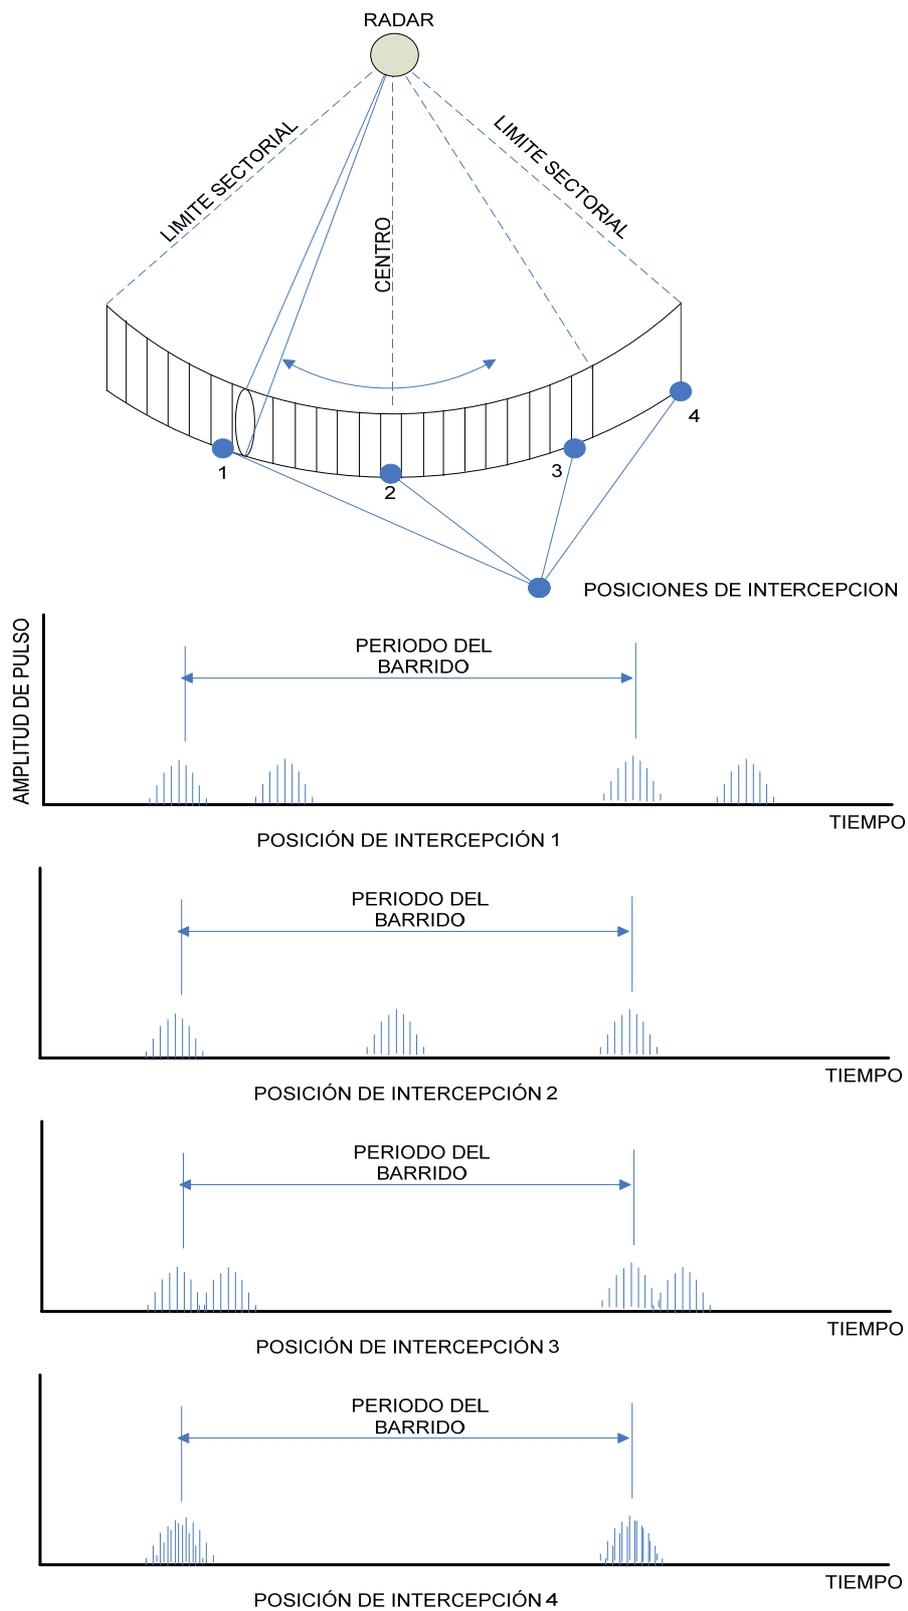


Figura 3.3.3. Patrón observado para un barrido sectorial bidireccional

Haz lápiz: Barrido raster, helicoidal, espiral y cónico

Un haz de antena con anchos aproximadamente iguales en acimut y elevación se denomina haz lápiz. Para una búsqueda efectiva con este tipo de haz se requiere movimiento tanto en acimut como en elevación. Una forma común de movimiento es el barrido raster, donde se barre una línea en acimut en una determinada dirección, sobre un cierto sector, y luego una segunda línea en acimut, en dirección opuesta y a un ángulo de elevación distinto, repitiendo este esquema hasta completar un cuadro.

Otro barrido muy común es el helicoidal, donde el haz lápiz barre circularmente 360° y va variando el ángulo de elevación en cada vuelta una magnitud aproximadamente igual al ancho de haz, tal como se ilustra en la figura 3.3.4

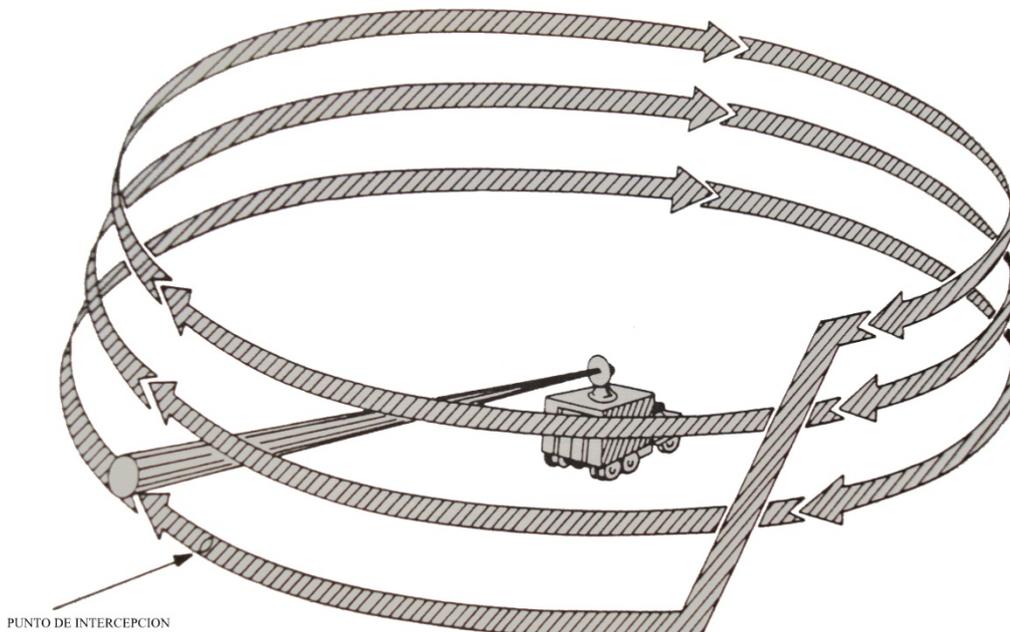


Figura 3.3.4. Barrido helicoidal

Cuando se desea buscar en una zona restringida del espacio se suele utilizar un barrido espiral, que parte de un punto central y recorre una espiral en expansión, para luego volver al punto inicial y comenzar otro ciclo (figura 3.3.5).

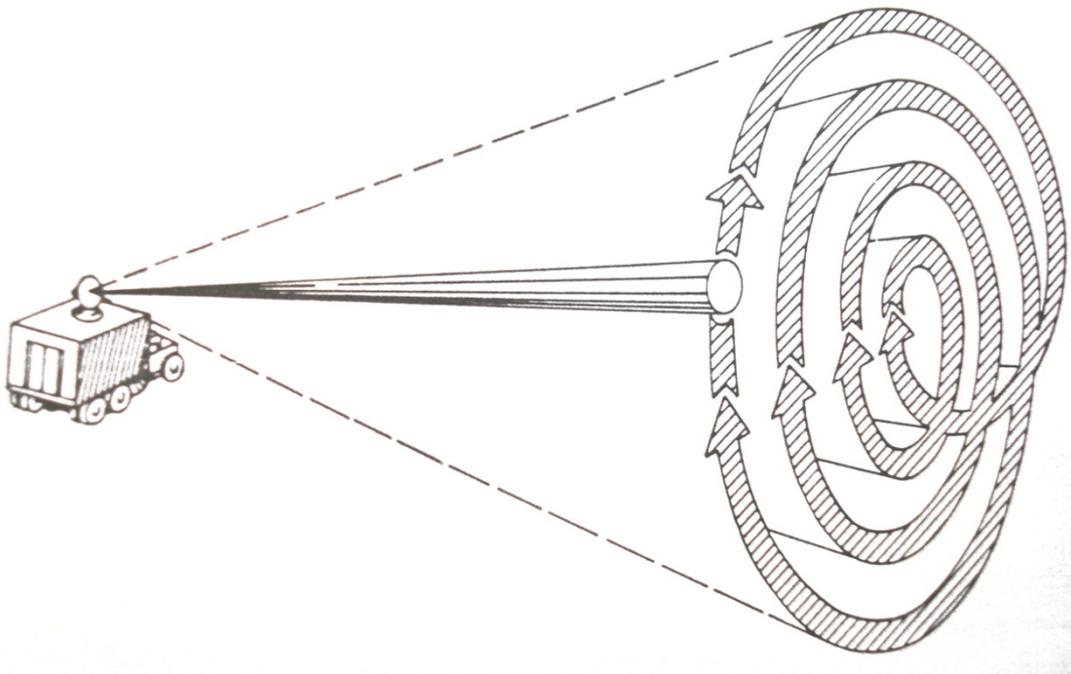


Figura 3.3.5. Barrido en espiral

El diagrama de amplitud versus tiempo puede ser bastante complicado y variar con el punto de observación.

Un radar se dice que está realizando tracking cuando ha localizado un blanco y está siguiendo su movimiento en distancia, elevación y acimut. Una técnica para implementar el tracking es el barrido cónico. Cuando un radar con barrido cónico sigue a un blanco, el pico del lóbulo principal nunca lo impacta directamente, sino que rota circularmente alrededor del mismo. El movimiento del haz forma un cono en el espacio (figura 3.3.6).

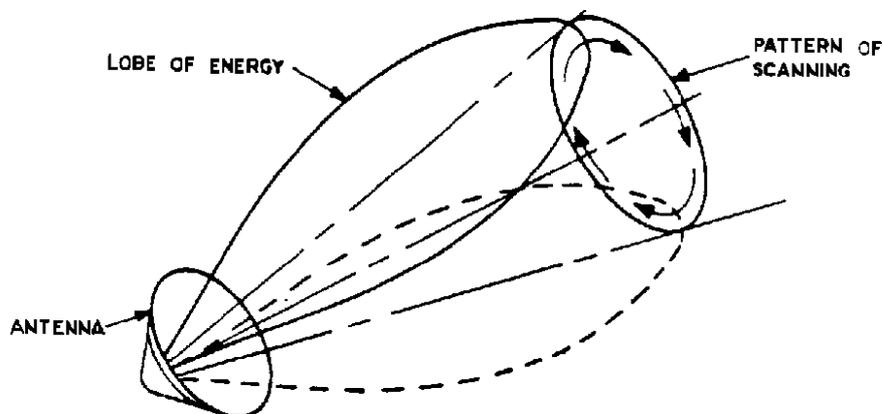


Figura 3.3.6. Barrido cónico

En radares con funciones de búsqueda y seguimiento, después de localizar al blanco el sistema debe realizar una transición del barrido de búsqueda al de seguimiento. Para acelerar el proceso el barrido cónico puede estar activo durante la fase de búsqueda, que a su vez utiliza un barrido raster, helicoidal o espiral. El barrido combinado cónico y helicoidal, denominado Palmer helicoidal (figura 3.3.7), es típico de estos radares.

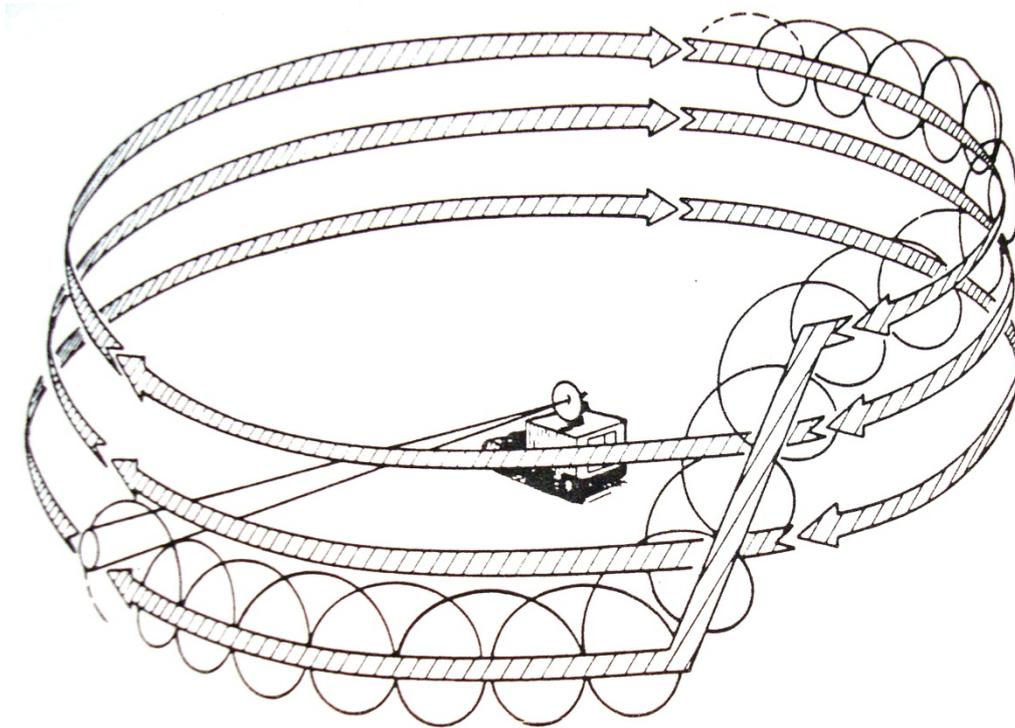


Figura 3.3.7. Barrido Palmer helicoidal

Otra clase de radar de seguimiento es el tipo “sigue mientras barre” (Track While Scan TWS). Un método TWS utiliza dos haces abanico y barridos sectoriales ortogonales para cubrir dos sectores solapados (figura 3.3.8). El blanco bajo seguimiento se mantiene en el centro de las áreas de barrido solapadas.

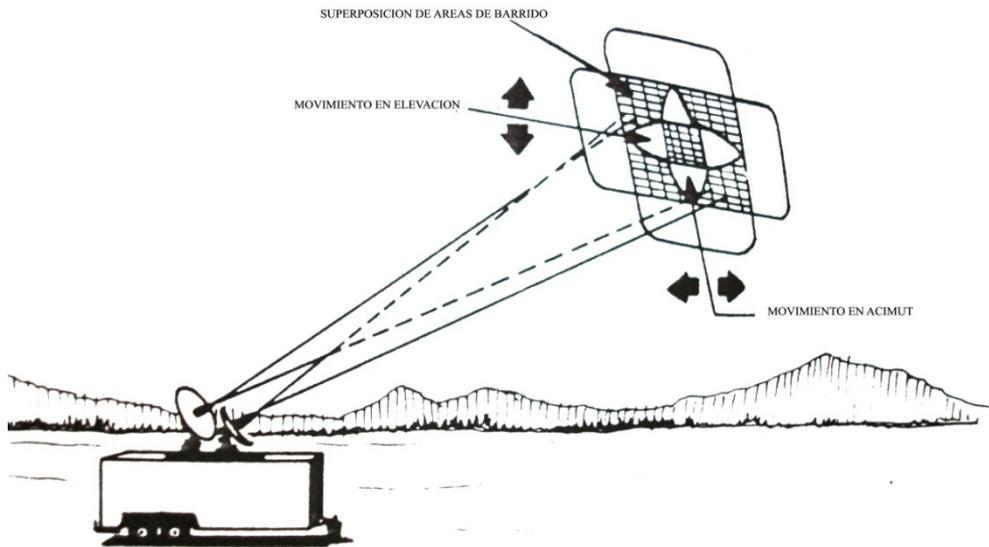


Figura 3.3.8. Mecanismo Track While Scan

Históricamente, el análisis del barrido se realizaba mediante auriculares y un cronómetro, dado que la frecuencia de repetición de pulsos generalmente cae dentro del rango audible (especialmente en radares antiguos). Cuando el lóbulo principal pasaba por la estación ELINT se escuchaba el tono más intenso y allí se lanzaba el cronómetro. Con el próximo paso del lóbulo se detenía el cronómetro y así se determinaba el período de barrido.

Actualmente, con la digitalización y almacenamiento de los parámetros del pulso, se abren muchas posibilidades de análisis. Las técnicas de análisis en el dominio tiempo suelen ser las más útiles por el hecho que el barrido de un radar, diseñado para buscar y seguir, se concibe mejor en el dominio tiempo.

Las técnicas de análisis de barrido tienden a ser intuitivas y heurísticas, más que teóricas.

3.4. ANÁLISIS DE LA FORMA DEL PULSO.

Actualmente la vasta mayoría de sistemas radar usan señales pulsadas. La determinación de la envolvente de los pulsos radar provee una visualización de las funciones del radar y su diseño. En particular con la envolvente del pulso se puede determinar la resolución en distancia del radar.

Para describir la envolvente del pulso es conveniente utilizar descriptores del dominio tiempo, que son más fáciles de medir y pueden relacionarse con el desempeño del radar. Los parámetros típicos son la duración del pulso, los tiempos de subida y bajada y la variación

intencional o no intencional de la duración. La duración del pulso se define como el tiempo entre los puntos al 50% de la potencia pico. Para un detector lineal estos puntos corresponden a 0.707 de la amplitud pico, mientras que para un detector cuadrático los puntos de medición están a 0.5 del la amplitud máxima. De la misma manera, los tiempos de subida y bajada son los tiempos entre los puntos al 10% y 90% de la potencia pico, y el 90% y el 10% respectivamente (figura 3.4.1). En las mediciones digitales automáticas de estos parámetros debe tenerse especial cuidado con las variaciones e irregularidades en la forma del pulso, producidas por ruido o por trayectorias múltiples de la señal.

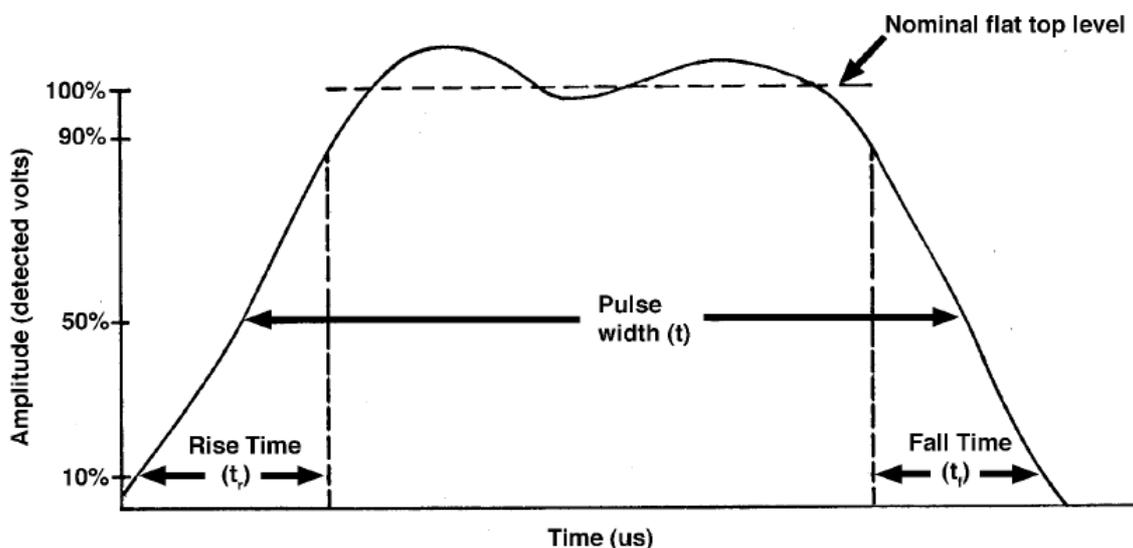


Figura 3.4.1. Ancho y tiempos de subida y caída de un pulso

3.5. ANÁLISIS DEL INTERVALO DE REPETICIÓN DE PULSOS

El intervalo de repetición de pulsos (PRI) es uno de los aspectos más importantes para el análisis con propósitos de inteligencia electrónica. Las capacidades del radar bajo observación dependen significativamente del PRI. Por ejemplo, una de las implicancias de este parámetro, en un radar de PRI constante, es su alcance máximo no ambiguo.

En muchos radares el PRI no es constante, en esos casos se utiliza el término PRI para referirse a la media del tiempo entre los flancos delanteros de dos pulsos consecutivos.

La diversidad de métodos de variación del PRI de un radar es enorme, no obstante existen algunos esquemas que por ser tan ampliamente utilizados, constituyen categorías con nombres propios. A continuación nos referiremos a los más importantes:

PRI constante

El radar se dice que tiene un PRI constante (figura 3.5.1) si la variación máxima no supera el 1% de la media. Estas pequeñas variaciones se consideran incidentales, en el sentido que no sirven para ningún propósito útil. Si las variaciones superaran el 1% podrían estar cumpliendo alguna función particular.

Para usar el PRI promedio a fin de estimar el máximo rango no ambiguo del radar, basta con una precisión en la medición del orden del 1%.

Es común en radares de PRI constante contar con algunos PRI diferentes, que el operador puede seleccionar, generalmente en función de la escala de distancia.

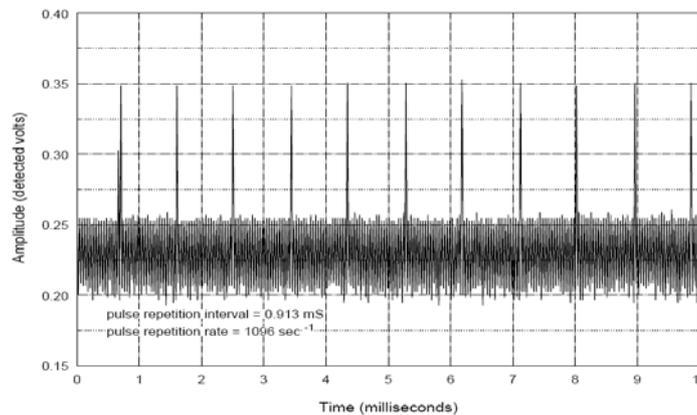


Figura 3.5.1. PRI constante

PRI fluctuante (Jittered PRI)

Las variaciones intencionales del PRI cumplen una variedad de propósitos e implican capacidades que un radar de PRI constante no tiene. El jitter intencional (variación aleatoria del PRI en grandes proporciones) se utiliza como contra medida electrónica (ECCM) en defensa de cierto tipo de interferencias. La extensión y tipo de jitter puede ayudar a identificar la clase de radar que se está analizando. En algunos radares el jitter consiste en la selección aleatoria de valores dentro de un intervalo discreto. Otros pueden tomar cualquier valor dentro de un cierto rango.

PRI permanece y salta (Dwell and Switch PRI)

En este tipo de radar se pueden seleccionar varios, e incluso muchos PRI diferentes para usar. El salto entre los diferentes valores se hace automática y rápidamente. Esta técnica se suele utilizar para eliminar ambigüedades en la distancia o la velocidad, o para suprimir el eclipsado

de blancos (distancias ciegas). Del análisis se desprende que si la secuencia de PRI utilizados es periódica, su objetivo es la eliminación de ambigüedad. Una secuencia no periódica pero que sigue cierto patrón obedece a la necesidad de adaptarse a la situación del blanco, mientras que una secuencia aparentemente aleatoria es indicio de actividad ECCM.

PRI escalonado (Stagger PRI)

PRI stagger consiste en el uso de dos o más PRI en una secuencia fija. La secuencia puede contener varios intervalos antes de repetirse. La secuencia se describe por el número de intervalos diferentes y sus posiciones. Una secuencia stagger muy común es la alternancia entre un intervalo largo y uno corto. Esta secuencia tiene dos intervalos y dos posiciones. Otra secuencia que utilice los mismos 2 intervalos pero con alternancia largo, largo, corto tiene dos intervalos y 3 posiciones. Generalmente el stagger se utiliza para eliminar rangos ciegos en radares medidores de velocidad.

PRI deslizante (Sliding PRI)

Esta variante se caracteriza por un incremento o decremento monótono del PRI, seguido por un salto rápido al alcanzar un extremo, hacia el otro extremo. La aplicación típica es la optimización del barrido en elevación, en radares de determinación de altitud.

En una situación real el haz del radar se mueve pasando por la estación ELINT y produciendo variaciones en la amplitud de pulso. Si el tiempo de llegada de un pulso se determina a un umbral de amplitud fijo, la duración del flanco delantero no nula, junto con las variaciones de amplitud produce errores de medición. En efecto, si la amplitud va aumentando, cada pulso sucesivo cruza el umbral un poco más temprano que el anterior. Esquemas de umbral variable más sofisticados se emplean para reducir este error.

El PRI se suele analizar mediante la confección de histogramas, en conjunto con el análisis de la media y el desvío estándar. Los histogramas son útiles para determinar las estadísticas globales de la secuencia de variación del PRI. Un histograma se construye dividiendo el rango esperado de un parámetro en intervalos (denominados bins) y contando el número de ocurrencias del valor del parámetro en cada bin.

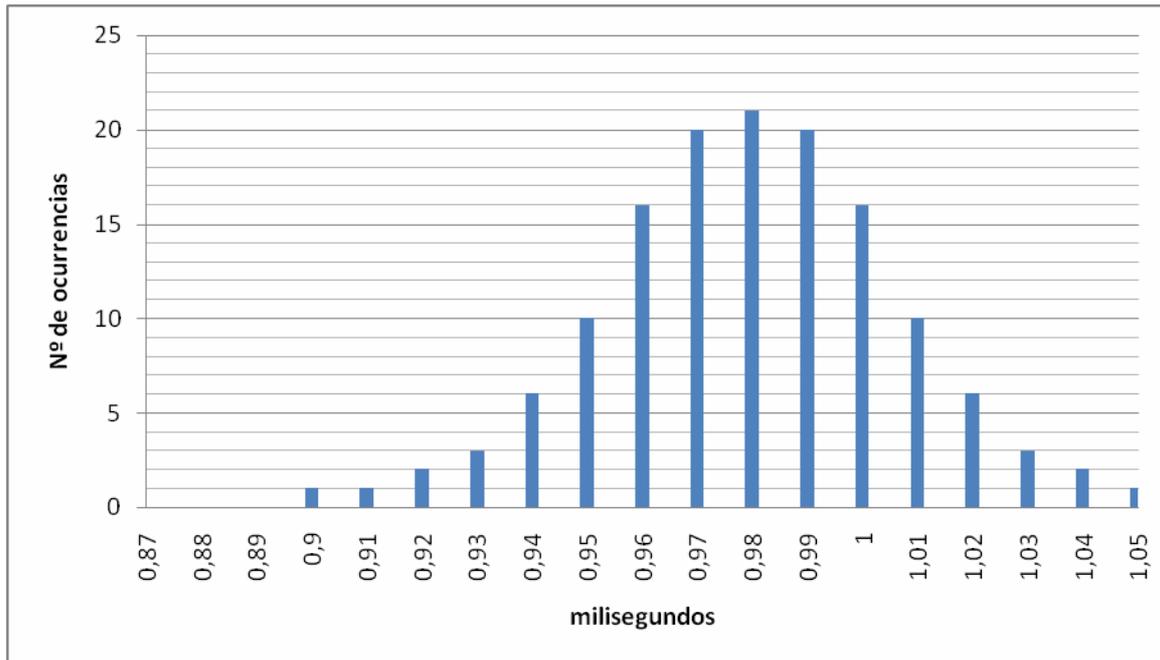


Figura 3.5.2. Histograma para un PRI con distribución Gaussiana

3.6. DESENREDO DE TRENES DE PULSOS (PULSE TRAINS DEINTERLEAVING)

ELINT generalmente debe enfrentarse con trenes de pulsos que están entrelazados. Esto puede deberse a la presencia de señales de interferencia o a la presencia de varias señales de interés al mismo tiempo. Por ejemplo, cuando más de un radar del mismo tipo están emitiendo dentro del alcance del receptor ELINT. En estos casos se debe aislar la señal de interés antes de proceder a su análisis.

Las técnicas de desenredo se clasifican como de tiempo real (analógicas) o computacionales, estas últimas se aplican después de la conversión a formato digital. Las técnicas también pueden clasificarse sobre la base de que parámetro o grupo de parámetros (amplitud, tiempo de llegada, duración, dirección de arribo, frecuencia de RF) utilizan para realizar el deinterleaving.

Desenredo computarizado

Una vez que la información que describe los pulsos recibidos ha sido reducida a formato digital, existe una variedad de algoritmos para realizar la tarea de la separación de los trenes originales. Generalmente un único parámetro, como por ejemplo el tiempo de llegada, no

tiene la información suficiente para agrupar los pulsos que corresponden a los distintos emisores. En la práctica se puede hacer un buen trabajo con el tiempo de llegada solamente si no hay demasiados emisores presentes a la vez.

El resultado final del proceso de desenredo puede interpretarse como un modelo del medio que produjo los trenes de pulsos entrelazados. En otras palabras, es una teoría que pretende explicar la información observada. La mejor teoría es la que predice la mayor cantidad de pulsos correctamente, con la menor complejidad.

Algoritmos basados únicamente en el intervalo

Cuando el digitalizador de pulsos provee solamente el tiempo transcurrido desde el pulso precedente, este constituye el único parámetro que dispone el algoritmo de desenredo. En un entorno con señales de emisores que barren angularmente, los pulsos tienden a arribar en ráfagas. Esto significa que habrá al menos algunos pulsos que no están entremezclados con otros de otro emisor. Una buena aproximación es comenzar a trabajar con estos pulsos que están parcialmente desenredados. Un algoritmo que funciona bien en estos casos es el siguiente:

1. Buscar pulsos separados por intervalos iguales. El número de pulsos debe ser como mínimo 3. La tolerancia de especificación del intervalo debe ser mayor que la resolución de la digitalización.
2. Después de encontrar un conjunto de pulsos que cumplan con lo anterior, tratar de extender el tren hacia delante y hacia atrás en el tiempo para encontrar más pulsos. La extensión se termina cuando se ha alcanzado un cierto número de “pulsos perdidos”.
3. Eliminar aquellos pulsos asociados a un grupo proveniente de un mismo emisor y repetir el proceso.

Este algoritmo es muy confiable en el sentido que difícilmente arme un tren de pulsos que no es real, sin embargo no es eficaz en ambientes muy densos.

El método para extender el grupo de pulsos asociados puede ir desde muy simple hasta muy complejo. Una técnica simple consiste en computar el intervalo promedio entre pulsos y buscar más pulsos separados en tiempo por esa magnitud. Debe admitirse una ventana de tolerancia, basada en la variabilidad observada de los pocos intervalos disponibles.

Otro procedimiento para estimar el valor correcto del intervalo de un grupo de pulsos es el del menor error cuadrático medio. Cualquiera sea el método utilizado, cuando el algoritmo no puede extender más el grupo de pulsos asociados, es fructífero tomar todos esos pulsos, recalcular las posiciones predichas basándose en toda la información, y buscar nuevamente para ver si se encuentran pulsos adicionales. El bucle termina cuando no se pueden agregar más pulsos al grupo. El algoritmo debe permitir una cierta fracción de pulsos faltantes, para no romper los grupos en pequeños segmentos por pulsos perdidos ocasionales.

Existen situaciones donde ningún segmento de ningún tren de pulsos está libre de entrelazamiento, y consecuentemente el procedimiento anterior no puede iniciarse. Entonces debe emplearse otra técnica de arranque. Una muy útil consiste en elegir un pulso (preferentemente cerca del centro del conjunto bajo análisis), y suponer que pertenece al mismo tren que el pulso más cercano. El intervalo entre estos pulsos se usa para intentar proyectar hacia delante y hacia atrás en tiempo, para ver si ese es el intervalo de un tren de pulsos. Si el intervalo no dio resultado, se toma el mismo pulso inicial con el siguiente más cercano y se prueba con este nuevo intervalo. El proceso continúa hasta que el intervalo de prueba alcanza un máximo o hasta que se identifica un tren de pulsos. Si no logra asociarse ningún pulso, se elige otro pulso como punto de partida. El proceso continúa hasta que cada pulso es incluido en un tren o ha sido probado como pulso de partida.

Estos algoritmos sufren limitaciones cuando los trenes de pulsos presentan variaciones de PRI como jitter o stagger.

Algoritmos con múltiples parámetros

Las técnicas de desenredo basadas en el PRI se hacen menos efectivas ante radares con agilidad en PRI. Esto es especialmente cierto en el caso de radares con barrido electrónico o con capacidades de ECCM. También en un medio cargado de emisiones con PRI nominalmente constante resulta útil el uso de parámetros de agrupamiento adicionales. Típicamente estos parámetros son la amplitud, el ancho de pulso y la frecuencia de RF. La amplitud es un parámetro de gran interés que exige sistemas con un rango dinámico amplio, por eso es común el empleo de detectores de respuesta logarítmica.

A primera vista la amplitud no parece ser un parámetro apto para el desenredo, por su variabilidad debida al barrido de antena. Sin embargo la variación de amplitud de un pulso a otro, dentro de un mismo tren, no es muy grande. Es muy probable que pulsos adyacentes con gran diferencia en amplitud no pertenezcan al mismo emisor.

El ancho del pulso se suele utilizar en conjunto con la amplitud. El ancho es menos efectivo como parámetro de deinterleaving porque muchos radares son similares en ese aspecto y además varía con la amplitud.

La frecuencia de RF es un potente parámetro de agrupación. Obviamente radares físicamente muy cercanos uno del otro no pueden ser operados en la misma frecuencia.

4. TEORIA DE LA RESONANCIA ADAPTATIVA

4.1. TEORÍA DE LA RESONANCIA ADAPTATIVA

La Teoría de la Resonancia Adaptativa (Adaptive Resonance Theory ART) fue introducida por Carpenter y Grossberg en 1976, junto con las reglas para el aprendizaje competitivo. La teoría se inspira en los procesos por los que el cerebro humano continúa aprendiendo y reconociendo el mundo cambiante, de una forma estable, a lo largo de toda la vida. La misma sostiene que todos los estados conscientes del cerebro son estados resonantes, y estos estados resonantes disparan el aprendizaje de representaciones sensoriales y cognitivas (Carpenter, G. A., and Grossberg, S., 2002).

La teoría ha evolucionado como una serie de modelos de redes neuronales de tiempo real, que realizan aprendizaje supervisado y no supervisado, reconocimiento de patrones y predicciones. Los modelos de aprendizaje no supervisado incluyen ART 1, para patrones de entrada binarios y ART 2 y Fuzzy ART, para patrones de entrada analógicos. Los modelos ARTMAP combinan dos módulos no supervisados para llevar a cabo aprendizaje supervisado. Además de estas, otras variantes han sido adaptadas para distintas aplicaciones tecnológicas.

El dilema estabilidad – plasticidad

Los humanos experimentan el mundo como un todo. Innumerables señales bombardean incesantemente los sentidos, sin embargo el cerebro de alguna manera las integra en momentos unificados de experiencia consciente, que se cohesionan a pesar de su diversidad. La aparente unidad y coherencia de nuestras experiencias se hace más destacable cuando observamos como el cerebro maneja y procesa los eventos del medio ambiente. En primer lugar estos eventos son altamente sensibles al contexto (Grossberg, 2000). Cuando miramos una escena compleja como un todo, podemos reconocer los objetos y su significado fácilmente, por ejemplo la fotografía de una cara familiar. Si en cambio procesáramos la cara pieza por pieza, como mirando a través de una pequeña abertura, estas perderían significado.

Para poder manejar estos eventos sensibles al contexto, el cerebro procesa la información en paralelo, como patrones de activación, a través de un número enorme de neuronas.

En la visión, las señales provenientes de una escena alcanzan la retina foto sensible al mismo tiempo, y aquí es donde comienza el procesamiento paralelo. En la audición en cambio, cada sonido alcanza el oído en tiempos diferentes. Antes que un patrón de sonido se pueda procesar como un todo, necesita ser recodificado, en una etapa de procesamiento posterior, a la forma de un patrón de activación espacial disponible simultáneamente. Esta etapa de procesamiento se denomina memoria de trabajo, y las activaciones que almacena se denominan trazos de memoria de corto plazo (Short Term Memory STM).

Para determinar cuáles de estos patrones son familiares y cuáles no, el cerebro los compara con representaciones almacenadas de experiencias previas, que fueron adquiridas por aprendizaje. A diferencia de los trazos de STM, las experiencias aprendidas se almacenan en trazos de memoria de largo plazo (Long Term Memory LTM). Una de las diferencias entre STM y LTM tiene que ver con cómo reaccionan ante distracciones. Por ejemplo, si antes de marcar un nuevo número telefónico, nos distrae un ruido, su representación STM puede borrarse y el número es olvidado. Por el contrario, un ruido nunca borrará la representación LTM de nuestro propio nombre.

La pregunta es cómo una nueva información aprendida queda establemente almacenada en LTM. A un nivel sorprendente podemos aprender hechos nuevos en forma rápida, sin vernos forzados a perder con la misma rapidez lo que ya sabíamos. No nos debemos preocupar porque el aprendizaje de la cara de un nuevo amigo, nos hará olvidar de la cara de nuestros padres. Este problema se denomina *olvido catastrófico*.

Muchos algoritmos contemporáneos de aprendizaje sufren de olvido catastrófico. Sin embargo el cerebro es capaz de aprender en forma rápida y estable cantidades enormes de información.

Grossberg denominó el problema por el cual el cerebro aprende en forma rápida y estable, sin olvido catastrófico del conocimiento anterior como el *dilema estabilidad – plasticidad*.

Relación entre aprendizaje, expectativa, atención y resonancia

Para aclarar ideas acerca de cómo usamos las expectativas sensoriales y cognitivas, y cómo se activa un estado resonante, supongamos que nos piden “encontrar la bola amarilla en menos de un segundo y ganaremos un premio”. La activación de la expectativa “bola amarilla” habilita una detección más rápida de la misma, con una respuesta neuronal más enérgica que si no estuviéramos buscándola. Aquí las expectativas sensoriales o cognitivas conducen a una coincidencia estimuladora con la información de confirmación proveniente del entorno. La discrepancia, en cambio, entre las expectativas y la información puede suprimir la parte discordante de la información y focalizar la atención en la parte coincidente o esperada.

Grossberg propuso que esta suerte de coincidencia estimuladora y enfoque de la atención en la información ascendente, usando expectativas descendentes, genera estados resonantes en el cerebro: Cuando hay una concordancia suficiente de los patrones de señales ascendentes y descendentes, entre dos o más niveles de procesamiento, se produce una realimentación positiva que amplifica y prolonga sus activaciones mutuas, conduciendo a un estado resonante. La amplificación y prolongación de las activaciones rápidas del sistema dispara el aprendizaje, a través de la adaptación más lenta de los pesos de conexión entre las células. De aquí que la teoría que describe estos procesos se llama Teoría de La Resonancia Adaptativa. ART propone que para resolver el dilema estabilidad – plasticidad, sólo los estados resonantes pueden lograr aprendizaje rápido y estable.

Aprendizaje basado en semejanza y aprendizaje basado en el error

En el dominio sensorial y cognitivo utilizamos aprendizaje basado en semejanza. Este aprendizaje ocurre solamente cuando hay una buena coincidencia entre la información proveniente del medio, y las expectativas previamente aprendidas y memorizadas como categorías de reconocimiento. Cuando ocurre tal coincidencia aproximada, el conocimiento previo puede ser refinado. Si una información nueva no encaja lo suficiente con las expectativas previas, se inicia una búsqueda en memoria que desemboca en el aprendizaje de una nueva categoría de reconocimiento, en lugar del olvido catastrófico de lo anterior (Grossberg, 2000).

El aprendizaje basado en semejanza es la piedra basal de la estabilidad de los sistemas ART, al permitir que las representaciones en memoria cambien solamente cuando las entradas del

mundo exterior están suficientemente cerca de las expectativas internas, o cuando ocurre algo completamente nuevo.

Como contrapartida, los procesos motores y espaciales utilizan aprendizaje basado en el error, que actualiza constantemente los mapas en memoria para reducir la diferencia entre la salida real y la deseada, más bien que para buscar una semejanza de patrones. El aprendizaje basado en el error es naturalmente apto para problemas de control adaptativo.

4.2. EL CICLO DE FUNCIONAMIENTO DE UN SISTEMA ART

La figura 4.2.1 ilustra las ideas ART con un ejemplo de dos niveles

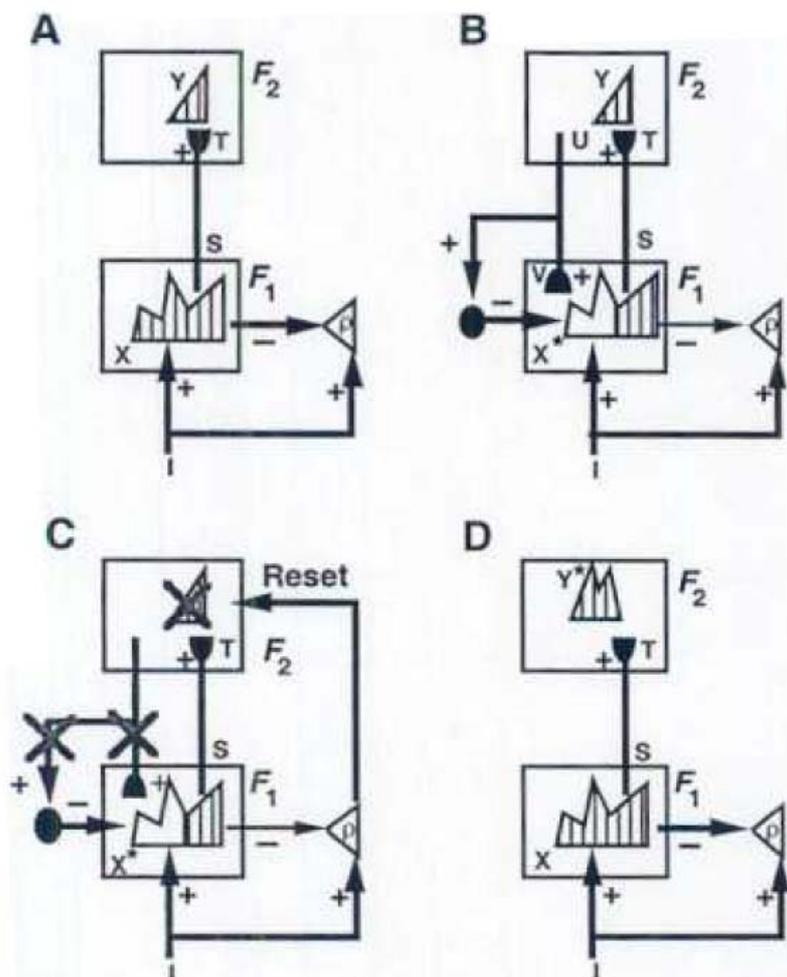


Figura 4.2.1. Ciclo de funcionamiento ART

El patrón de entrada ascendente, o vector, I produce el patrón de activación X en la memoria de corto plazo a nivel F_1 . Por ejemplo X podría ser una escena visual representada por los atributos bordes, textura, color, forma, etc. El gráfico de la figura 4.2.1A representa que existen neuronas con diferentes niveles de activación, en función de los atributos contenidos en el vector de entrada. De F_1 parten las señales S , a través de un filtro adaptativo, hacia un segundo nivel F_2 , donde se activa una representación comprimida Y (también llamada categoría de reconocimiento o símbolo), en respuesta a la entrada distribuida T . T se computa multiplicando el vector S por una matriz de pesos adaptativos, que pueden ser modificados por aprendizaje. La representación Y se obtiene por interacciones competitivas en el nivel F_2 , que solo permiten permanecer activas a un pequeño subconjunto de las células más intensamente activadas, en respuesta a T . El gráfico de Y indica que sólo un pequeño número de categorías se activa, a diferentes niveles. Estas células categóricas envían a su vez las señales U hacia F_1 . El vector U se convierte en el vector de expectativas descendentes V , al ser multiplicado por otra matriz de pesos adaptativos. Cuando V llega a F_1 , se produce una comparación con I que finaliza con la selección de un subconjunto X^* de atributos, que son los “esperados” para la categoría activa Y . La selección de este conjunto de atributos críticos se corresponde con el enfoque de la atención del cerebro.

Representación distribuida y representación simbólica vinculadas mediante la resonancia

Si la expectativa descendente está lo suficientemente cerca del patrón de entrada, entonces el patrón X^* de atributos críticos refuerza la categoría Y , que a su vez refuerza X^* . De esta manera la red se asienta en un estado resonante, mediante la realimentación positiva que vincula dinámicamente los parámetros críticos en X^* con la categoría Y .

Los atributos individuales en F_1 no tienen ningún sentido por sí mismos, como los píxeles de una imagen tomados uno por uno. La categoría o símbolo en F_2 es sensible a la globalidad del patrón de atributos, pero no puede representar el contenido al detalle, dado que es una representación simbólica. La resonancia entre la representación distribuida y la simbólica convierte al patrón de atributos críticos en un estado coherente, sensible al contexto, que está vinculado con su categoría a través de la realimentación.

Resonancia y aprendizaje

En ART es el estado resonante, más que la activación ascendente quién conduce el proceso de aprendizaje. El estado resonante persiste el tiempo suficiente, y a un nivel de actividad suficiente, para dar lugar al proceso de aprendizaje a través de la adaptación de los pesos que vinculan los niveles F_1 y F_2 en ambos sentidos (estos pesos también se denominan trazos de memoria de largo plazo). Este concepto ayuda a explicar cómo los pesos que fueron adaptados en un aprendizaje anterior, pueden regular la actividad presente del cerebro, sin aprender sobre las señales actuales, a menos que puedan iniciar un estado resonante.

Aprendizaje y búsqueda en memoria

Cuando existe una discrepancia suficiente entre la expectativa y la entrada se dispara una búsqueda en memoria. Esta discrepancia en el sistema atencional activa un sistema orientador complementario, que es sensible a los eventos inesperados o no familiares. En los seres humanos este sistema orientador se ubica en el hipocampo (Grossberg, 2000). Las señales de salida del sistema orientador resetean rápidamente la categoría asignada, que produjo la discrepancia (Figura 4.2.1B y 4.2.1C). El evento de reset dispara la búsqueda en memoria de una categoría de reconocimiento diferente, que se asemeje más a la entrada. Si tal categoría no existe, debido a que por ejemplo la entrada representa una experiencia nueva, el proceso de búsqueda automáticamente activa un grupo de neuronas libre, para aprender acerca de la nueva información. Este proceso de aprendizaje trabaja bien tanto en la modalidad supervisada como no supervisada.

Control de la generalización del conocimiento. Ejemplares y prototipos

Un problema clave del conocimiento tiene que ver con qué combinaciones de atributos u otra información se deben incluir en las representaciones de los eventos. Si los humanos debieran memorizar cada experiencia vivida como ejemplares, se produciría una explosión en la capacidad de memoria requerida, y también serios problemas para recuperar la información almacenada. Resulta claro que, además de ejemplares, también podemos aprender prototipos que representan las propiedades del medio ambiente en forma más general.

Los sistemas ART aprenden prototipos, pero la generalidad de estos prototipos es controlada por un proceso de vigilancia, que es influenciado por realimentación del medio ambiente o en forma interna. Valores bajos de vigilancia permiten el aprendizaje de categorías generales,

con prototipos abstractos. Valores altos de vigilancia fuerzan la búsqueda en memoria de una nueva categoría, aún en presencia de una pequeña discrepancia entre un ejemplar y la categoría activada. Como resultado de esto, en el límite más alto de la vigilancia, la categoría del prototipo puede codificar a un ejemplar individual. La vigilancia se computa dentro del sistema orientador del modelo ART (figuras 4.2.1 B-D). Si la relación entre la actividad de los atributos críticos, con la actividad de la totalidad de los atributos en I , es menor que el parámetro de vigilancia ρ (figura 4.2.1B), se activa el proceso de reset y búsqueda de otra categoría para clasificar al ejemplar de entrada (figura 4.2.1C). En otras palabras, el parámetro de vigilancia controla que tan grande debe ser la discrepancia para iniciar la búsqueda de una nueva categoría. Si el parámetro de vigilancia es bajo, muchos ejemplares podrán influir sobre el aprendizaje de un prototipo compartido, descartando los atributos que no son comunes a todos los ejemplares.

La regla más simple para controlar la vigilancia se denomina *seguimiento de la semejanza*. Según la misma, el parámetro de vigilancia se aumenta hasta justo por encima de la relación entre los atributos críticos en F_1 y los atributos totales en I . Es decir que la vigilancia monitorea el grado de semejanza entre el ejemplar de entrada y el prototipo asignado al mismo.

Dado que la vigilancia puede variar de un ciclo de aprendizaje a otro, un único sistema ART puede codificar categorías con diferente grado de generalización o abstracción. Bajando la vigilancia se obtiene una generalización más amplia y prototipos abstractos. Subiendo la vigilancia se obtiene una generalización estrecha y prototipos que representan a pocos ejemplares de entrada, incluso a uno solo.

La vigilancia es un parámetro libre en los modelos no supervisados, mientras que en los supervisados es controlado internamente en respuesta al error de predicción.

4.3. LA RED ART 1

La figura 4.3.1 esquematiza un ejemplo típico de la arquitectura denominada ART 1. Carpenter y Grossberg demostraron matemáticamente que una red ART 1 es capaz de aprender en forma no supervisada y estable, en respuesta a una secuencia arbitraria de patrones binarios de entrada (Carpenter, G. A., and Grossberg S., 1987). Más aún, los pesos adaptativos, o trazos LTM, de un sistema ART 1 a lo sumo oscilan una vez durante el

aprendizaje, sin caer en estados de memoria espurios o mínimos locales. Después que el aprendizaje se estabiliza, los patrones de entrada acceden directamente a los prototipos que los representan.

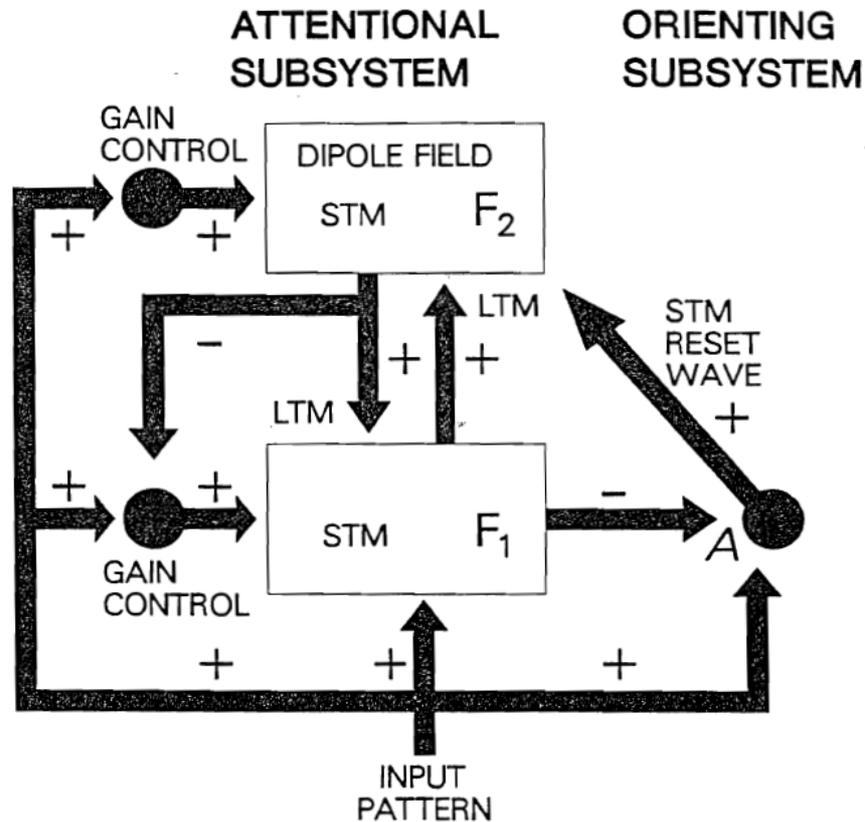


Figura 4.3.1. Arquitectura típica ART 1

Los sistemas ART emplean dos subsistemas, funcionalmente complementarios, para procesar eventos familiares y no familiares. Los eventos familiares se procesan dentro del subsistema atencional. Sin embargo, por sí solo este subsistema no puede simultáneamente mantener representaciones estables de categorías conocidas y crear nuevas categorías para patrones no familiares. En forma aislada el subsistema atencional sería, o bien muy rígido, incapaz de crear nuevas categorías, o bien inestable, recodificando incesantemente las categorías de patrones familiares.

El segundo subsistema es el subsistema orientador, que resetea al subsistema atencional cuando ocurre un evento desconocido. El subsistema orientador es esencial para determinar si un patrón nuevo es familiar y está bien representado por una categoría existente, o no es familiar y requiere la creación de una nueva categoría.

Dos etapas sucesivas, F_1 y F_2 , del subsistema atencional codifican los patrones de activación en memorias de corto plazo STM. Las rutas ascendentes y descendentes entre F_1 y F_2 contienen trazos adaptativos de memoria de largo plazo LTM, que multiplican las señales que pasan por las rutas. El resto del circuito modula estos procesos STM y LTM. La modulación mediante control de ganancia en F_1 permite distinguir entre los patrones ascendentes y descendentes. El control de ganancia en F_2 permite a los nodos de esta capa reaccionar ante las entradas desde F_1 . El subsistema orientador genera una señal de reset hacia F_2 , cuando hay una discrepancia entre los patrones ascendentes y descendentes en F_1 . Esta señal resetea selectivamente las células activas de F_2 hasta que la entrada cambie.

Descripción del funcionamiento

Consideremos las reacciones típicas de la red ante un patrón único I de entrada. El patrón I es recibido por la etapa F_1 del subsistema atencional y transformado en el patrón de activación X en los nodos, o detectores de atributos, de F_1 .

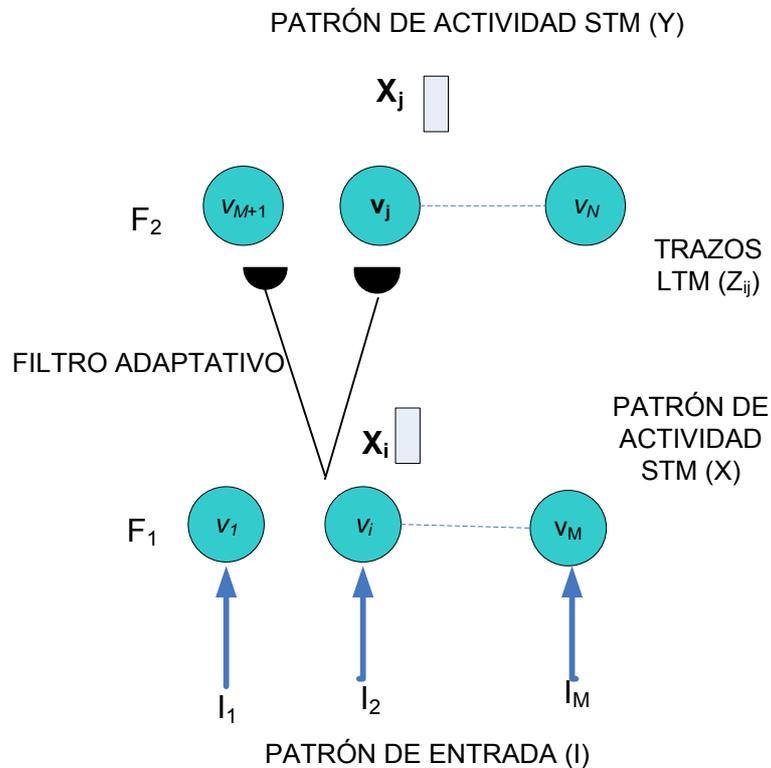


Figura 4.3.2. Etapas de la activación ascendente

v_1, v_2, \dots, v_M son los nodos de F_1

$v_{M+1}, v_{M+2}, \dots, v_N$ son los nodos de F_2

I_i es la entrada al nodo v_i

x_i es la actividad del nodo v_i

z_{ij} es el trazo LTM (peso adaptativo) del enlace entre v_i y v_j

Cada nodo de F_1 , cuya actividad es suficientemente grande, envía señales de excitación por las rutas que lo vinculan con los nodos de destino en la siguiente etapa de procesamiento F_2 . Es decir que F_1 genera el patrón de señales de salida S . En el camino hacia F_2 , S es multiplicado por los trazos LTM. Al llegar a F_2 , cada nodo suma las entradas que recibe. De esta manera el patrón S se convierte, por multiplicación en LTM y suma posterior, en el patrón T , figura 4.3.3a.

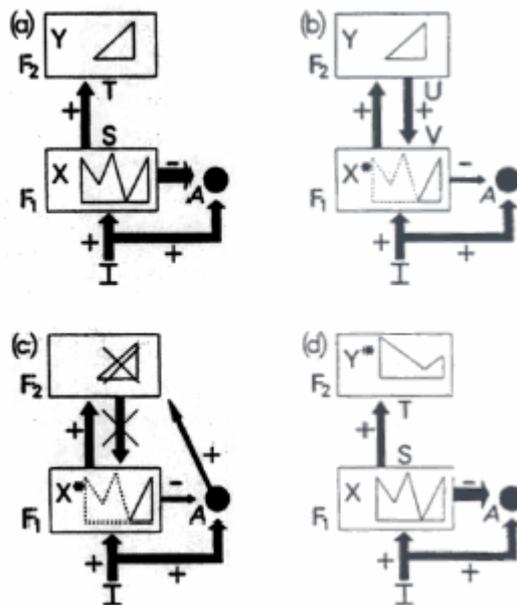


Figura 4.3.3. Secuencia de operación de la red ART 1

La transformación de S a T se denomina filtrado adaptativo. El patrón T es rápidamente transformado por interacción entre los nodos de F_2 . El resultado es un nuevo patrón de activación Y . Todos los trazos del filtro adaptativo, y por consiguiente toda la experiencia anterior de la red, influyeron en la transformación $I \rightarrow X \rightarrow S \rightarrow T \rightarrow Y$.

Ni bien la transformación $X \rightarrow Y$ tiene lugar, F_2 envía el patrón de señal descendente U hacia F_1 (figura 4.3.3b). Solamente los nodos con actividad suficientemente grande envían señales

U. Las señales descendentes también son multiplicadas por trazos LTM y sumadas por los nodos de F_1 , por ende la transformación U a V es también un filtrado adaptativo. El patrón V se denomina modelo descendente o expectativa aprendida.

Dos fuentes de entrada perturban ahora a F_1 : el patrón de entrada I que dio lugar al patrón de actividad original X, y el patrón modelo V, resultante de X. El patrón de actividad X^* inducido en F_1 por acción de I en forma conjunta con V, en general difiere del patrón X que había sido previamente inducido por I solamente.

La secuencia de activación completa $I \rightarrow X \rightarrow S \rightarrow T \rightarrow Y \rightarrow U \rightarrow V \rightarrow X^*$ tiene lugar muy rápidamente, en relación al tiempo que le toma cambiar a los filtrados adaptativos ascendente y descendente. Si bien ningún trazo LTM cambia durante tan corto tiempo, el aprendizaje previo influye fuertemente sobre los patrones STM X^* e Y.

Veamos ahora como la semejanza o discrepancia entre I y V regula el curso del aprendizaje, en respuesta a la entrada I, y en particular como se resuelve el dilema estabilidad – plasticidad.

En la figura 4.3.3a, el patrón de entrada I genera un patrón de actividad X en F_1 . El patrón I también excita al subsistema orientador A, pero el patrón X inhibe a A antes de que pueda generar una señal de salida. En la figura 4.3.3b, F_2 envía el patrón modelo V hacia F_1 . El modelo V difiere de la entrada I, reduciendo en consecuencia la actividad STM en F_1 . La magnitud por la cual la actividad en X es atenuada para generar X^* , depende de que tanto el patrón I encaja en el modelo V. Cuando se atenúa la actividad en F_1 , la señal inhibitoria de F_1 hacia A también se atenúa. Si la atenuación es lo suficientemente grande (en relación al parámetro de vigilancia), la inhibición ya no puede impedir que la fuente A se active. La figura 4.3.3c grafica como la desinhibición de A libera una ráfaga hacia F_2 que excita a todas las células por igual. Las células de F_2 reaccionan a esta estimulación en una forma dependiente de su estado, reseteándose e inhibiéndose selectivamente aquellas que estaban activas. En la figura 4.3.3c, la inhibición de Y remueve el modelo descendente V, y termina por consiguiente la disparidad entre I y V. El patrón de entrada I puede ahora reinstalar al patrón de actividad original X en F_1 , que a su vez genera la salida S de F_1 y la entrada T a F_2 . Dado que la inhibición todavía perdura en F_2 , el patrón T no puede volver a activar el mismo patrón Y que antes. Se genera entonces un nuevo patrón Y^* en respuesta a I (figura 4.3.3d). El nuevo patrón Y^* origina un nuevo modelo descendente V^* . Si todavía hay disparidad en F_1 , el subsistema orientador actúa de nuevo, liberando otra onda de reset a F_2 . De esta manera

pueden sucederse una rápida serie de eventos de comparación y reset. Si bien la memoria STM se resetea secuencialmente en el tiempo, los mecanismos que controlan la búsqueda LTM son interacciones paralelas de la red y no algoritmos seriales. La búsqueda LTM, gobernada por la discrepancia, termina cuando el patrón en F_2 arroja un modelo descendente que se asemeja a I , con el grado de precisión establecido por el parámetro de vigilancia.

Control de la ganancia atencional y preparación atencional

Consideremos por ejemplo una situación donde F_2 es activado por otro nivel distinto a F_1 (figura 4.3.4a). En esta situación F_2 envía un modelo descendente a F_1 . El nivel F_1 entonces se prepara o sensibiliza para recibir una entrada ascendente que puede o no asemejarse a la expectativa activa. Como se muestra en la figura 4.3.4a, F_1 se prepara para recibir una entrada, sin que la salida de sus nodos supere el umbral de activación.

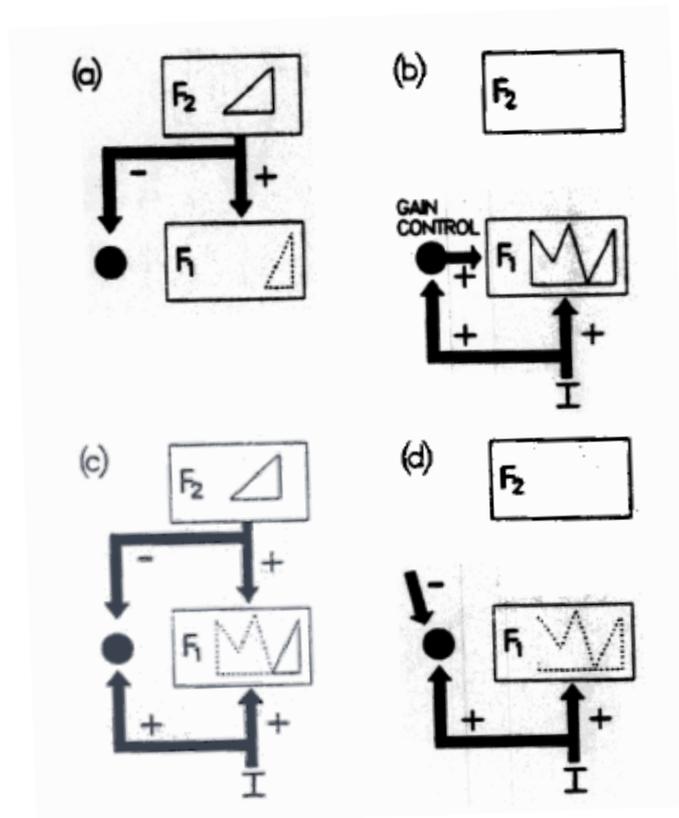


Figura 4.3.4. La regla 2/3

Por otra parte, el patrón de entrada debe poder generar un nivel de actividad por sobre el umbral, aún en ausencia de expectativa (figura 4.3.4b). ¿Cómo sabe F_1 que debe generar una

reacción por sobre el umbral para patrones ascendentes pero no para descendentes? En ambos casos las señales estimulan las células de F_1 . Se necesita un mecanismo auxiliar para distinguir entre las entradas ascendentes y descendentes. Este mecanismo auxiliar se denomina control de ganancia atencional, para diferenciarlo de la preparación atencional en sí. La consecuencia natural de esta diferenciación es una regla denominada *regla de los 2/3*. La misma dice que 2 de las 3 fuentes de señal posibles deben estimular a un nodo de F_1 para que pueda generar una salida por sobre el umbral de activación. Los nodos de F_1 reciben entradas desde 3 fuentes posibles: dos específicas, el modelo descendente y el patrón de entrada I, y una no específica (es decir común a todos los nodos) desde el canal de control de ganancia. En la figura 4.3.4c, durante la comparación de los patrones ascendentes y descendentes, la señal de control de ganancia a F_1 está inhibida, permitiendo que los nodos con entradas suficientemente altas desde ambos patrones se puedan activar.

La figura 4.3.5 esquematiza el aprendizaje en respuesta a 20 presentaciones del alfabeto, simulado por computadora. Después de la vigésima entrada se reconocen 9 categorías con $\rho = 0.8$ y sólo 4 categorías con $\rho = 0.5$

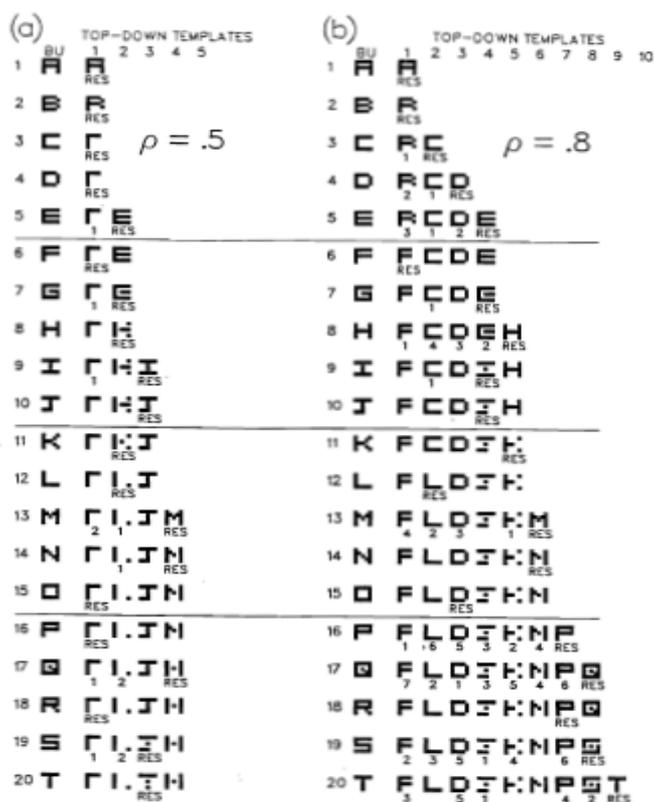


Figura 4.3.5. Ejemplo de aprendizaje del alfabeto por un sistema ART 1

4.4. LA RED ART 2

Las redes ART 2 reconocen categorías en forma no supervisada, como respuesta a una secuencia arbitraria de patrones analógicos de entrada, así como de patrones digitales. Un sistema de reconocimiento de categorías, para entradas analógicas, requiere tener la capacidad de extraer señales embebidas en el ruido de fondo (Carpenter, G. A., Grossberg, S., 1987).

La figura 4.4.1 ilustra una arquitectura típica ART 2. Para aprender secuencias analógicas en forma estable, el campo de representación de atributos F_1 incluye varios niveles de procesamiento y de control de ganancia. Los patrones ascendentes y descendentes se reciben en locaciones distintas de F_1 . Lazos de realimentación positiva dentro de F_1 refuerzan las señales y suprimen el ruido. Dado que ART 2 se usa para categorizar entradas tanto analógicas como digitales, es muy común el agregado de un pre procesador a la entrada. Se han desarrollado sistemas ART 2 para satisfacer múltiples objetivos de diseño o condiciones de procesamiento. Se han identificado al menos tres variantes en la arquitectura ART 2, capaces de satisfacer estas condiciones. En realidad, el foco del análisis de ART 2 consiste en descubrir cómo, las diferentes combinaciones de los mecanismos de la red trabajan en conjunto para generar las propiedades deseadas.

En cada arquitectura ART 2, las combinaciones de los procesos de normalización, control de ganancia, comparación y aprendizaje se entrelazan de forma generalmente similar. Si bien la forma en que esto se realiza puede diferir, en todas las variantes de ART 2 empleadas hasta ahora, F_1 incluye diferentes niveles para recibir y transformar los patrones de entradas ascendentes y de expectativas descendentes.

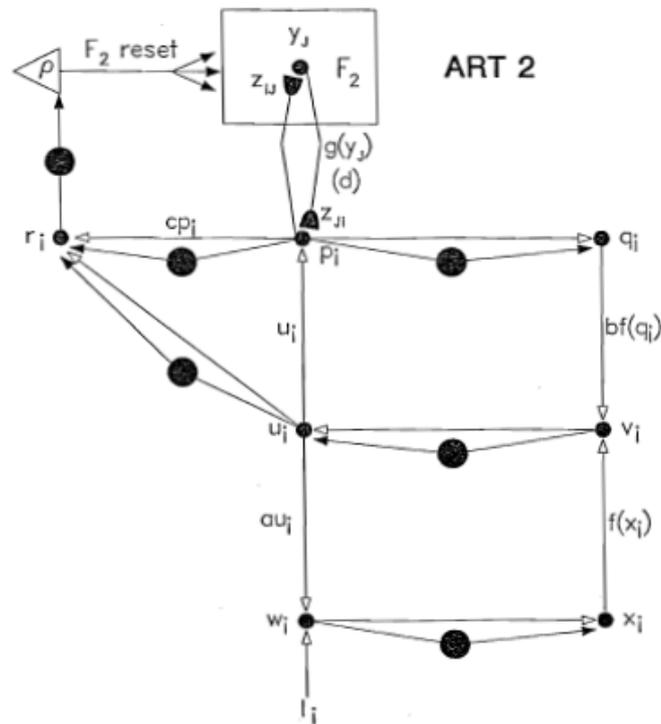


Figura 4.4.1. Arquitectura ART 2 típica

Una mirada más en profundidad del proceso comparación – reset, aclara porque F_1 está compuesto por varios niveles internos de procesamiento. Supongamos que antes de que un nodo libre de F_2 sea activado por primera vez, sus trazos LTM de la vía $F_2 \rightarrow F_1$ son iguales a cero. En el primer intento de aprendizaje del nodo, sus trazos LTM aprenderán progresivamente el patrón generado por el nivel superior de F_1 . En este aprendizaje no debe permitirse que, a causa de una discrepancia, se resetee F_2 , puesto que los trazos LTM todavía no han aprendido ningún patrón. Esta propiedad se logra diseñando los niveles medio e inferior de F_1 , de manera que sus patrones de actividad STM no cambien cuando los trazos LTM aprenden sus primeros valores positivos. Para expresarlo en forma más general, F_1 se diseña para que la llegada de un patrón previamente aprendido desde F_2 , que encaja perfectamente en el patrón del nivel superior de F_1 , no cambie los patrones STM circulantes por los niveles medio e inferior de F_1 . Esta propiedad de invariancia permite a los niveles medio e inferior de F_1 transformar no linealmente el patrón de entrada, de manera que permanezca estable durante el aprendizaje. En particular permite que se mejore la señal y se suprima el ruido.

La propiedad de invariancia STM conduce al uso de múltiples niveles en F_1 , debido a que los nodos de F_1 a los que llega la actividad LTM, reciben una entrada adicional cuando las

señales descendentes están activas, que cuando no lo están. Los niveles adicionales de F_1 brindan un grado de libertad computacional para leer la actividad LTM descendente y normalizar el patrón total STM en el nivel superior de F_1 , antes de que este patrón normalizado pueda interactuar con el nivel medio, donde se produce la comparación. De forma similar, el nivel inferior de F_1 habilita la normalización del patrón de entrada, antes de interactuar con el nivel medio. Sin esta normalización, podría haber confusión entre patrones útiles y fluctuaciones espurias de la línea base, que podrían entorpecer el aprendizaje y desestabilizar a la red.

Si bien la llegada de un patrón LTM que se asemeje perfectamente al patrón del nivel superior de F_1 , nunca puede producir un reset de F_2 , aún una muy pequeña disparidad entre estos patrones es suficiente para resetear F_2 , si el parámetro de vigilancia está muy alto. El nivel medio de F_1 juega un rol muy importante en el disparo del evento reset.

Un ejemplo muy claro de este reset inducido por la discrepancia, ocurre cuando uno o varios, pero no todos los trazos LTM descendentes son iguales o muy cercanos a cero, y los correspondientes nodos de F_1 tienen actividad STM positiva. Cuando esto sucede, la actividad STM de estos nodos de F_1 se suprime. Si la supresión STM total es suficientemente grande para resetear F_2 , la red busca una mejor semejanza. Si la supresión no es suficientemente grande para resetear F_2 , los trazos LTM descendentes permanecerán con valores bajos durante el aprendizaje en curso, debido a que están muestreando los bajos valores de STM que ellos mismos han provocado. Esta propiedad es una versión de la regla de los 2/3, fuente de la estabilidad del aprendizaje de un sistema ART 1. En ART 1 esta propiedad se lograba por el uso de un canal de control de ganancia. En ART 2 en cambio se realiza como parte de la estructura interna de niveles de F_1 .

Las señales analógicas pueden estar embebidas en diferentes niveles de ruido de fondo. La combinación de la normalización con el proceso realimentado no lineal dentro de F_1 , es lo que permite al sistema separar la señal del ruido. El grado de mejora de la señal y de supresión del ruido está determinado por el grado de no linealidad en las realimentaciones de F_1 . Se pueden utilizar diferentes esquemas para normalizar la activación de patrones de F_1 . Uno muy común es la inhibición inespecífica entre neuronas, representados en la figura como círculos rellenos.

4.5. LA RED ARTMAP

La red ARTMAP, denominada también ART predictiva, es una arquitectura que aprende a clasificar una secuencia arbitraria de vectores de entrada, en categorías, basándose en el éxito de la predicción. Este sistema de aprendizaje supervisado se construye a partir de un par de módulos ART 1, denominados ART_a y ART_b (Carpenter, G. A., Grossberg, S., & Reynolds, J. H., 1991). Durante la fase de entrenamiento el módulo ART_a recibe una secuencia de patrones de entrada $[\mathbf{a}^{(p)}]$, y ART_b otra secuencia de patrones de entrada $[\mathbf{b}^{(p)}]$, donde $\mathbf{b}^{(p)}$ es la clase correcta de $\mathbf{a}^{(p)}$. Estos módulos están vinculados por una red de aprendizaje asociativo y un controlador interno, que asegura la operación autónoma del sistema en tiempo real. Durante la fase de prueba se presentan patrones adicionales $\mathbf{a}^{(p)}$, sin $\mathbf{b}^{(p)}$, y se comparan las predicciones de ART_b con $\mathbf{b}^{(p)}$.

La arquitectura se denomina ARTMAP porque la transformación de los vectores de entrada en los de salida, pasa por un campo de mapeo donde se correlacionan los pares $\{\mathbf{a}^{(p)}, \mathbf{b}^{(p)}\}$, de la secuencia de vectores presentados a la red. Por ejemplo $\mathbf{a}^{(p)}$ podría codificar diferentes tipos de manzanas y $\mathbf{b}^{(p)}$ predecir su sabor.

Los elementos principales de una red ARTMAP se muestran en la figura 4.5.1. Dos módulos ART_a y ART_b leen los vectores de entrada \mathbf{a} y \mathbf{b} . Si los módulos ART_a y ART_b estuviesen desconectados, cada uno agruparía las entradas por separado. ART_a y ART_b están conectados por un módulo de interconexión, que incluye un campo de mapeo (map field) que asocia las categorías reconocidas por ART_a con las reconocidas por ART_b . Este campo no asocia directamente ejemplares \mathbf{a} y \mathbf{b} , sino más bien las representaciones simbólicas de las categorías a las que pertenecen \mathbf{a} y \mathbf{b} . El campo de mapeo también controla el parámetro de vigilancia de ART_a . Una discrepancia en el map field entre la categoría de ART_a , activada por la entrada \mathbf{a} , y la categoría de ART_b , activada por la entrada \mathbf{b} , aumenta la vigilancia de ART_a , justo lo suficiente para buscar, y si es necesario crear, una nueva categoría en ART_a , que se asemeje más a la categoría en ART_b . El reseteo de la vigilancia es una forma de retro propagación, pero diferente a la que ocurre en las redes backpropagation. Por ejemplo, se podría aprender una nueva clase de “manzanas verdes”, basándose en la realimentación del “sabor”. Sin embargo estos eventos no propagan hacia atrás el atributo sabor, dentro de la representación visual de las manzanas, como ocurriría en una red backpropagation. En su lugar, el

mecanismo de seguimiento de la semejanza reorganiza la forma en que los atributos visuales se agrupan, se aprenden y se clasifican para producir el sabor esperado.

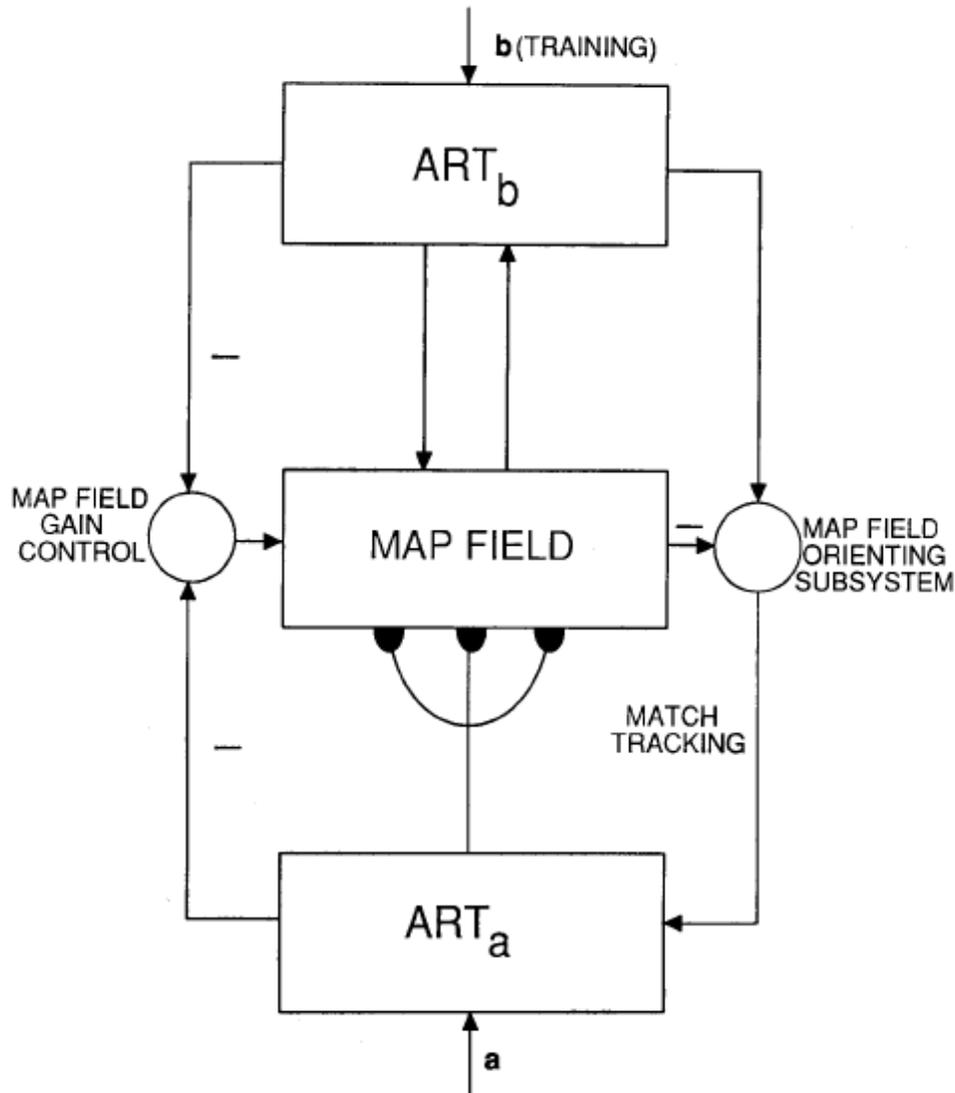


Figura 4.5.1. Diagrama en bloques de una red ARTMAP

Cualquier módulo ART puede usarse para constituir ART_a y ART_b , en este caso consideraremos la aplicación de módulos ART 1. En esta arquitectura, un patrón de entrada \mathbf{I} se representa en el campo F_1 , y la categoría de \mathbf{I} en el campo F_2 . El campo F_1 de M nodos, con vector de salida $\mathbf{x} = (x_1, x_2, \dots, x_M)$, es el que recibe desde F_0 el vector de entrada $\mathbf{I} = (I_1, I_2, \dots, I_M)$. Cada nodo de F_1 puede recibir entrada desde tres fuentes: la entrada ascendente $F_0 \rightarrow F_1$; el control de ganancia común para todos los nodos; y las señales descendentes desde los N nodos de F_2 , a través del filtrado adaptativo $F_2 \rightarrow F_1$. Se dice que un nodo está activo si genera una señal de salida igual a 1. La salida de nodos inactivos es 0. En ART 1 un nodo

estará activo si por lo menos 2 de las 3 entradas son altas. Esta regla para la activación de F_1 se denomina regla de los $\frac{2}{3}$.

Regla de los $\frac{2}{3}$

En su forma más simple y adimensional se materializa de la siguiente manera: El nodo i de F_1 será activo si su entrada neta excede un umbral fijo

$$x_i \begin{cases} 1 & \text{si } I_i + g_1 + \sum_{j=1}^N y_j z_{ji} > 1 + \bar{z} \\ 0 & \text{en caso contrario} \end{cases} \quad (4.5.1)$$

Donde I_i es la entrada binaria $F_0 \rightarrow F_1$, g_1 es el control de ganancia común de F_1 , $\sum y_j z_{ji}$ es la suma de las señales y_j desde F_2 , a través de los pesos adaptativos z_{ji} , y \bar{z} es una constante tal que

$$0 < \bar{z} < 1 \quad (4.5.2)$$

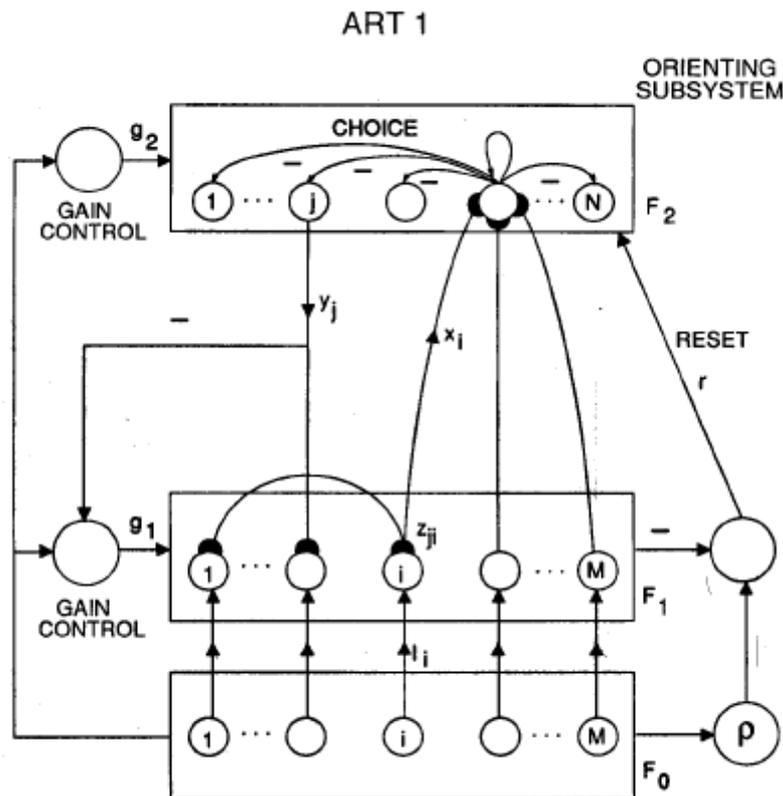


Figura 4.5.2. Diagrama esquemático de un módulo ART 1

Control de ganancia de F_1

La señal de control de ganancia se define como

$$g_l \begin{cases} 1 & \text{si } F_0 \text{ está activo y } F_2 \text{ inactivo} \\ 0 & \text{en caso contrario} \end{cases} \quad (4.5.3)$$

Nótese que la actividad F_2 inhibe la ganancia de F_1 , como se muestra en la figura 4.5.2. Estas leyes para la activación de F_1 implican que, si F_2 está inactivo,

$$x_i \begin{cases} 1 & \text{si } I_i = 1 \\ 0 & \text{en caso contrario} \end{cases} \quad (4.5.4)$$

Si exactamente un solo nodo J está activo en F_2 , la suma $\sum y_j z_{ij}$ en (4.5.1) se reduce al término z_{ij} , entonces

$$x_i \begin{cases} 1 & \text{si } I_i = 1 \text{ y } z_{ij} > \bar{z} \\ 0 & \text{en caso contrario} \end{cases} \quad (4.5.5)$$

Selección de F_2

Sea T_j la entrada total desde F_1 , al nodo j de F_2 , dada por

$$T_j = \sum_{i=1}^M x_i Z_{ij} \quad (4.5.6)$$

Donde Z_{ij} denota los pesos adaptativos $F_1 \rightarrow F_2$. La elección de F_2 por el índice J se define por

$$T_j = \max\{T_j: j = 1 \dots N\} \quad (4.5.7)$$

En el caso típico, J está unívocamente definido. Entonces el vector de salida de F_2 $\mathbf{y} = (y_1, \dots, y_N)$ cumple con

$$y_j \begin{cases} 1 & \text{si } j = J \\ 0 & \text{si } j \neq J \end{cases} \quad (4.5.8)$$

Reglas de aprendizaje

En aprendizaje rápido de ART 1 los pesos adaptativos alcanzan su nueva asíntota en cada presentación de la entrada. Una forma apta para describir convenientemente las leyes del aprendizaje, así como las reglas de selección y búsqueda, es utilizando la siguiente notación.

Si \mathbf{a} es un vector M dimensional, la norma de \mathbf{a} es

$$|\mathbf{a}| \equiv \sum_{i=1}^M a_i \quad (4.5.9)$$

Si \mathbf{a} y \mathbf{b} son dos vectores binarios, un tercer vector $\mathbf{a} \cap \mathbf{b}$ queda definido por

$$(\mathbf{a} \cap \mathbf{b}) = 1 \Leftrightarrow a_i = 1, b_i = 1 \quad (4.5.10)$$

Finalmente sea \mathbf{a} un subconjunto de \mathbf{b} ($\mathbf{a} \subseteq \mathbf{b}$) si y solo si $\mathbf{a} \cap \mathbf{b} = \mathbf{a}$

Todo aprendizaje en ART 1 está regulado por la actividad en F_2 , es decir que los pesos adaptativos z_{ji} y z_{ij} solamente pueden cambiar cuando el nodo J está activo. Tanto los pesos $F_1 \rightarrow F_2$ como $F_2 \rightarrow F_1$ son función del vector \mathbf{x} :

Aprendizaje descendente

Los pesos descendentes $F_2 \rightarrow F_1$ aprenden \mathbf{x} cuando el nodo J de F_2 está activo

$$z_{ji} \rightarrow x_i \quad (4.5.11)$$

Todos los otros z_{ji} permanecen constantes. Expresada como ecuación diferencial, esta regla de aprendizaje es

$$\frac{d}{dt}z_{ji} = y_i(x_i - z_{ji}) \quad (4.5.12)$$

El aprendizaje es regulado por y_j . Cuando $y_j > 0$ comienza el aprendizaje y z_{ji} es atraído hacia x_i . En términos vectoriales, si $y_j > 0$ entonces $\mathbf{z}_j \equiv (z_{j1}, \dots, z_{jM})$ se aproxima a \mathbf{x} . Esta ley se denomina aprendizaje por el mayor gradiente regulado. También se la denomina *regla outstar*, y fue introducida en 1969.

Inicialmente todos los z_{ji} son máximos

$$z_{ji}(0) = 1 \quad (4.5.13)$$

De esta manera, con aprendizaje rápido, el vector de pesos descendentes \mathbf{z}_j es un vector binario al comienzo y al final de cada presentación de entrada. Por las ecuaciones (4.5.4), (4.5.5), (4.5.10), (4.5.11), y (4.5.13), el vector de actividad de F_1 se puede describir como

$$\mathbf{x} = \begin{cases} \mathbf{I} & \text{si F2 está inactivo} \\ \mathbf{I} \cap \mathbf{z}_j & \text{si el nodo } J \text{ de F2 está activo} \end{cases} \quad (4.5.14)$$

Por las ecuaciones (4.5.5) y (4.5.12), cuando el nodo J está activo, el aprendizaje hace que

$$\mathbf{z}_j \rightarrow \mathbf{I} \cap \mathbf{z}_j^{(\text{old})} \quad (4.5.15)$$

donde $\mathbf{z}_j^{(\text{old})}$ denota \mathbf{z}_j al comienzo de cada presentación de entrada. Por las ecuaciones (4.5.11) y (4.5.14), \mathbf{x} permanece constante durante el aprendizaje, aún cuando $|\mathbf{z}_j|$ puede disminuir.

La primera vez que el nodo J de F_2 se activa, se dice que está libre o no comprometido. Luego por las ecuaciones (4.5.13) – (4.5.15), durante el aprendizaje

$$\mathbf{z}_j \rightarrow \mathbf{I} \quad (4.5.16)$$

De aquí en más se dice que J está ocupado o comprometido.

Aprendizaje ascendente

En el entrenamiento conviene asignar valores a los pesos adaptativos $F_1 \rightarrow F_2$, Z_{ij} , de forma tal que los nodos de F_2 se activen inicialmente en el orden $j = 1, 2, \dots$. Esto se puede lograr haciendo

$$Z_{ij}(0) = \alpha_i \quad (4.5.17)$$

donde

$$\alpha_1 > \alpha_2 > \dots > \alpha_N \quad (4.5.18)$$

Al igual que el vector de pesos descendentes \mathbf{z}_j , el de pesos ascendentes $\mathbf{Z}_j \equiv (Z_{1j}, \dots, Z_{Mj})$ también es proporcional al vector \mathbf{x} de salida de F_1 , cuando el nodo J de F_2 está activo. Sin embargo, además los pesos ascendentes son escalados inversamente a $|\mathbf{x}|$, o sea

$$Z_{ij} \rightarrow \frac{x_i}{\beta + |\mathbf{x}|} \quad (4.5.19)$$

Donde $\beta > 0$. Esta ley de aprendizaje para los pesos $F_1 \rightarrow F_2$, denominada *regla de Weber*, realiza una competencia entre los pesos \mathbf{z}_j , adyacentes al nodo dado J . Por las ecuaciones (4.5.14), (4.5.15) y (4.5.19), durante el aprendizaje tenemos

$$Z_j \rightarrow \frac{I \cap \mathbf{z}_j^{(old)}}{\beta + |I \cap \mathbf{z}_j^{(old)}|} \quad (4.5.20)$$

Los valores iniciales de Z_{ij} deben ser lo suficientemente bajos como para que una entrada \mathbf{I} que encaje perfectamente con un vector \mathbf{Z}_j previamente aprendido, seleccione al nodo J de F_2 en lugar de uno libre. Esto se da suponiendo que se cumple

$$0 < \alpha_j = Z_{ij}(0) < \frac{1}{\beta + |I|} \quad (4.5.21)$$

para todas las entradas \mathbf{I} . Cuando \mathbf{I} se presenta por primera vez, $\mathbf{x} = \mathbf{I}$, entonces por las ecuaciones (4.5.6), (4.5.15), (4.5.17) y (4.5.20), el vector de F_1 a F_2 , $\mathbf{T} \equiv (T_1, T_2, \dots, T_N)$ está dado por

$$T_j = \sum_{i=1}^M I_i Z_{ij} = \begin{cases} |\mathbf{I}| \alpha_j & \text{si } j \text{ es un nodo libre} \\ |\mathbf{I} \cap \mathbf{z}_j| / (\beta + |\mathbf{z}_j|) & \text{si } j \text{ es un nodo comprometido} \end{cases} \quad (4.5.22)$$

β debe ser tan pequeño como para que, entre los nodos comprometidos, T_j esté determinado por el valor de $|\mathbf{I} \cap \mathbf{z}_j|$ relativo a $|\mathbf{z}_j|$. Si β fuese grande, T_j dependería principalmente de $|\mathbf{I} \cap \mathbf{z}_j|$. Además, los valores de α_j deben ser pequeños también para que un nodo libre genere el máximo valor de T_j en la ecuación (4.5.22), solo si $|\mathbf{I} \cap \mathbf{z}_j| = 0$ para todos los nodos comprometidos. Valores más altos de α_j y β le dan un sesgo al sistema hacia selecciones más tempranas de nodos libres, cuando se encuentra una semejanza insuficiente dentro de los nodos ocupados.

Búsqueda y eventos nuevos

De las ecuaciones (4.5.7), (4.5.21) y (4.5.22) se desprende que un nodo comprometido J puede resultar seleccionado, aún cuando la semejanza entre \mathbf{I} y \mathbf{z}_j sea pobre, ya que la semejanza debe ser simplemente la mejor disponible. Si la semejanza es demasiado pobre ART 1 inicia la búsqueda de una categoría más apropiada en F_2 . Este proceso de búsqueda es impuesto por el subsistema orientador, que puede resetear los nodos de F_2 en respuesta a semejanzas deficitarias en F_1 . El subsistema orientador funciona como una especie de detector de eventos nuevos, que mide la certeza del sistema. Si el grado de semejanza entre la entrada \mathbf{I} y el vector de pesos descendentes \mathbf{z}_j es demasiado pobre, la certeza del sistema en la asignación del nodo J es inadecuada. En otras palabras, la entrada \mathbf{I} es demasiado inesperada en relación a las expectativas materializadas por \mathbf{z}_j .

Vigilancia y aprendizaje resonante

Como quedo expresado, el grado de semejanza entre la entrada \mathbf{I} y la expectativa \mathbf{z}_j es evaluado por el subsistema orientador, que mide la certeza con que la categoría J representa a la entrada \mathbf{I} . Cuando la certeza cae por debajo de un parámetro adimensional ρ , denominado *parámetro de vigilancia*, se dispara una señal de reset. El parámetro de vigilancia calibra la sensibilidad del sistema a las expectativas no conformadas.

Una de las principales razones del éxito de una red ARTMAP para clasificar secuencias de datos no estacionarios, es su habilidad para recalibrar el parámetro de vigilancia, basándose en el acierto de las predicciones.

En un sistema ART 1 el proceso de búsqueda ocurre de la siguiente manera:

Paso 1- Seleccionar un nodo J de F_2 que maximice T_j en (4.5.22), y generar el vector de pesos descendentes \mathbf{z}_j .

Paso 2- Con J activo, comparar el vector de salida de F_1 , $\mathbf{x} = \mathbf{I} \cap \mathbf{z}_j$, con el vector de entrada \mathbf{I} (figura 4.5.2).

Paso 3A- Supongamos que $\mathbf{I} \cap \mathbf{z}_j$ no se asemeja a \mathbf{I} , al nivel requerido por el criterio de vigilancia, es decir

$$|\mathbf{x}| = |\mathbf{I} \cap \mathbf{z}_j| < \rho|\mathbf{I}| \quad (4.5.23)$$

Entonces se produce el reset de F_2 . J es desactivado por la duración del intervalo que \mathbf{I} está presente. El índice del nuevo nodo seleccionado de F_2 toma el valor del correspondiente a la siguiente entrada más alta T_j . Con el nuevo nodo activo se repiten los pasos 2 y 3A hasta que el nodo elegido cumple con el criterio de resonancia del paso 3B. Nótese que el reset nunca ocurriría si

$$\rho \leq 0 \quad (4.5.24)$$

Cuando se cumple (4.5.24) un sistema ART actúa como si no tuviera un subsistema orientador.

Paso 3B- Supongamos que $\mathbf{I} \cap \mathbf{z}_j$ cumple el criterio de resonancia, es decir

$$|\mathbf{x}| = |\mathbf{I} \cap \mathbf{z}_j| \geq \rho|\mathbf{I}| \quad (4.5.25)$$

Entonces la búsqueda concluye y el último nodo elegido J permanece activo hasta que desaparezca la entrada \mathbf{I} (o hasta que ρ aumente). En este estado, denominado resonancia,

tanto los pesos adaptativos $F_1 \rightarrow F_2$ como $F_2 \rightarrow F_1$ adquieren nuevos valores si $\mathbf{I} \cap \mathbf{z}_j^{(\text{old})} \neq \mathbf{z}_j^{(\text{old})}$. Nótese que la resonancia no puede ocurrir si $\rho > 1$.

Control de ganancia de F_2

Por simplicidad, los módulos ART 1 se exponen a presentaciones en intervalos discretos, durante los cuales la entrada se mantiene constante, y al final de los cuales las actividades de F_1 y F_2 se hacen nulas. Las presentaciones a intervalos discretos se implementan por medio de los controles de ganancia g_1 y g_2 , de F_1 y F_2 respectivamente (figura 4.5.2). El control de ganancia g_2 , al igual que g_1 en la ecuación (4.5.3), se hace 0 si F_0 está inactivo. Luego, cuando F_0 se activa, los umbrales de las señales g_2 y F_2 han de caer en un rango donde el nodo de F_2 que recibe la señal más grande, es el que se activa.

Cuando un sistema ART 1 está embebido en una estructura jerárquica, F_2 puede recibir señales desde otras fuentes distintas a F_1 . Este es el caso de una red ARTMAP.

El campo de mapeo

El campo de mapeo vincula los campos F_2 de los módulos ART_a y ART_b . La figura 4.5.3 ilustra los componentes principales del campo de mapeo.

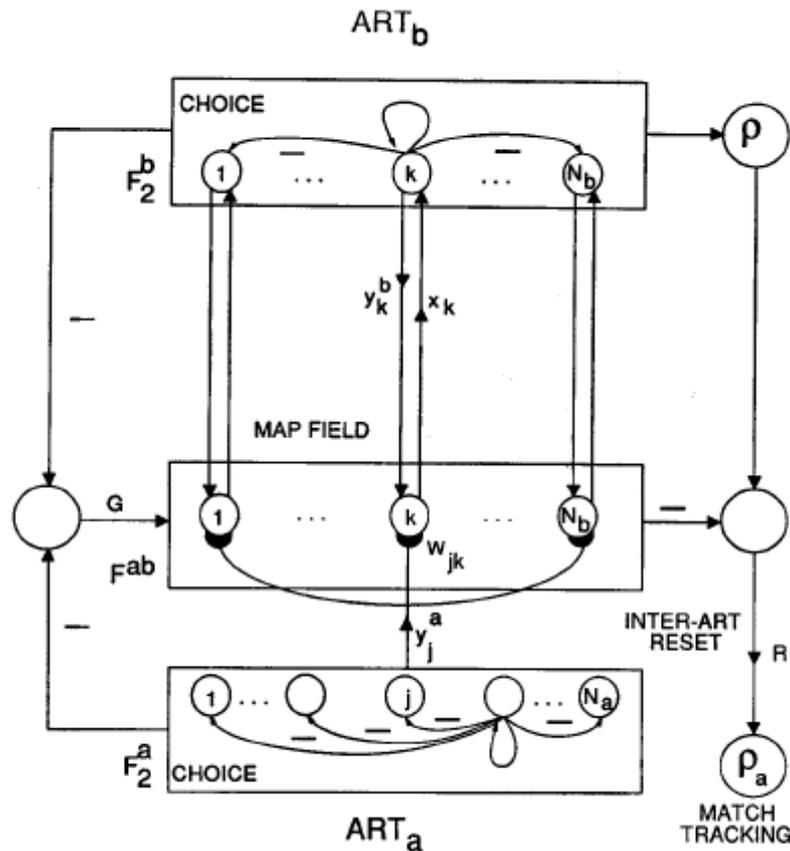


Figura 4.5.3. Campo de mapeo de una red ARTMAP

En lo sucesivo, los términos y variables correspondientes a los módulos ART_a y ART_b se identificarán mediante los superíndices a y b respectivamente, mientras que los correspondientes al campo de mapeo no llevarán superíndice.

En la discusión siguiente sobre el campo de mapeo, los nodos F_2^a , indexados con $j = 1, \dots, N_a$, tienen señales de salida binarias y_j^a ; y los nodos F_2^b , indexados con $k = 1, \dots, N_b$, tienen señales de salida binarias y_k^b . De la misma manera, J es el nodo activo de F_2^a y K el nodo activo de F_2^b . Como el campo de mapeo es la interface donde interactúan las señales desde F_2^a y F_2^b , se denota con F^{ab} . Los nodos de F^{ab} tienen el mismo índice k que los nodos de F_2^b porque hay una correspondencia uno a uno entre estos dos conjuntos de nodos. La salida de los nodos F^{ab} se denotan como x_k .

La regla de los $\frac{2}{3}$ en el campo de mapeo

Cada nodo de F^{ab} puede recibir entrada desde tres fuentes: F_2^a , F_2^b , y el control de ganancia del campo de mapeo G . El vector x de salida de F^{ab} cumple con la regla de los $\frac{2}{3}$ de ART 1

$$x_k = \begin{cases} 1 & \text{si } y_k^b + G + \sum_{j=1}^{N_a} y_j^a w_{jk} > 1 + \bar{w} \\ 0 & \text{caso contrario} \end{cases} \quad (4.5.26)$$

Donde y_k^b es la señal de salida de F_2^b , G es una señal binaria de control de ganancia, el

término $\sum_{j=1}^{N_a} y_j^a w_{jk}$ es la suma de las señales de y_j^a multiplicadas por los pesos adaptativos w_{jk} , y \bar{w} es una constante tal que

$$0 < \bar{w} < 1 \quad (4.5.27)$$

Control de ganancia F^{ab}

Comparando las ecuaciones (4.5.1) y (4.5.26) se aprecia una analogía de los campos F_2^b , F^{ab} y F_2^a de una red ARTMAP, con los campos F_0 , F_1 y F_2 de un módulo ART 1. La diferencia radica en las conexiones bidireccionales no adaptativas entre F_2^b y F^{ab} en el campo de mapeo, en comparación con las conexiones bidireccionales adaptativas entre los campos F_1 y F_2 de un módulo ART 1. Este esquema de conectividad diferente requiere reglas diferentes para las señales de control de ganancia G y g_1 .

La señal de control de ganancia G del campo de mapeo obedece la ecuación

$$G = \begin{cases} 0 & \text{si } F_2^a \text{ y } F_2^b \text{ están ambos activos} \\ 1 & \text{caso contrario} \end{cases} \quad (4.5.28)$$

G es una señal persistentemente activa, que se desactiva sólo cuando ART_a y ART_b están activos.

Activación del campo de mapeo

El campo de mapeo tiene las siguientes propiedades.

Si ART_a y ART_b están ambos activos dan lugar a que se produzcan las asociaciones $ART_a \rightarrow ART_b$ en F^{ab} .

Si ART_a está activo pero ART_b no, se exhibe en F^{ab} cualquier predicción anterior.

Si ART_b está activo pero ART_a no, la categoría elegida por ART_b se representa en F^{ab} .

Si ni ART_a ni ART_b están activos, F^{ab} estará desactivado.

Reset del campo de mapeo y seguimiento de la semejanza

El campo de mapeo provee el control que permite a un sistema ARTMAP, establecer categorías diferentes para entradas muy similares en ART_a , a la vez que permite que entradas muy diferentes en ART_a hagan la misma predicción. En particular, el subsistema orientador del campo de mapeo se vuelve activo solamente cuando ART_a hace una predicción que es incompatible con la entrada actual de ART_b . Esta discrepancia activa una estrategia de control, denominada seguimiento de la semejanza, que modula al parámetro de vigilancia de ART_a para evitar que el sistema cometa errores repetidos. Como se ilustra en la figura 4.5.3, una discrepancia en F^{ab} mientras F_2^b está activo dispara una señal R de reset inter ART, hacia el subsistema orientador de ART_a .

El seguimiento de la semejanza opera hasta que la categoría expuesta por ART_a satisface el criterio de semejanza de ART_a y también el del campo de mapeo. El seguimiento va aumentando la vigilancia de ART_a por la mínima cantidad, necesaria para abortar una predicción $ART_a \rightarrow ART_b$ incorrecta, e iniciar la búsqueda de una nueva categoría en ART_a que arroje una mejor predicción.

4.6. RED ARTMAP DIFUSA (FUZZY ARTMAP)

La red Fuzzy ARTMAP es una arquitectura capaz de realizar aprendizaje incremental supervisado de categorías y mapas multidimensionales, en respuesta a una secuencia arbitraria de patrones de entrada binarios o analógicos, que representen conjuntos definidos o difusos de atributos. Los valores de entrada, comprendidos entre 0 y 1, indican el grado en que cada atributo está presente (Carpenter, G.A., Grossberg, S., Markuzon, N., Reynolds, J. H., & Rosen, D. B., 1992).

Esta generalización se lleva a cabo reemplazando los módulos ART 1 de un sistema ARTMAP con módulos fuzzy ART. Mientras que la dinámica de ART 1 se describe en términos de la teoría de conjuntos, la dinámica de fuzzy ART se describe en términos de la teoría de conjuntos difusos. De allí el nombre de esta variante.

También se introduce en esta variante de ARTMAP una estrategia de votación. Esta estrategia surge de la observación que una red ARTMAP generalmente conduce a diferentes categorías

de reconocimiento, cuando se cambia el orden de presentación de los patrones del conjunto de entrenamiento, aún cuando se mantenga la precisión global de todas las predicciones. Según esta estrategia, el sistema ARTMAP se entrena varias veces, con diferentes ordenamientos del conjunto de entrenamiento. La predicción final de un ítem dado es la que se obtuvo mayor cantidad de veces en todas las simulaciones. Dado que los ítems erróneamente clasificados varían de una simulación a otra, la votación cancela muchos de los errores.

En la discusión de fuzzy ARTMAP es conveniente sustituir la notación de teoría de conjuntos aplicada en ART 1, por la función de inclusión o notación lógica, donde cada componente de un patrón de longitud fija representa en qué medida el atributo correspondiente está presente. De esta manera, el operador de intersección (\cap) que describe la dinámica de ART 1, se

reemplaza por el operador difuso AND (\bigwedge).

Reemplazando las operaciones lógicas por sus contrapartidas difusas se obtiene una versión más potente que ART1. Mientras que ART 1 admite solamente entradas binarias, fuzzy ART admite tanto binarias como analógicas.

En la tabla 4.6.1 se ilustra la sustitución de los operadores lógicos en cada operación de la red

	ART1 (BINARIA)	FUZZY ART (ANALOGICA)
Selección de la categoría	$T_j = \frac{[\cap w_j]}{\alpha + w_j }$	$T_j = \frac{[\bigwedge w_j]}{\alpha + w_j }$
Criterio de semejanza	$\frac{[\cap w_j]}{ w_j } \geq \rho$	$\frac{[\bigwedge w_j]}{ w_j } \geq \rho$
Aprendizaje rápido	$w_j^{(new)} = \cap w_j^{(old)}$	$w_j^{(new)} = \bigwedge_j^{(old)}$

Tabla 4.6.1. Sustitución de operadores lógicos

En fuzzy ART el aprendizaje siempre converge porque los pesos adaptativos varían en forma monótona decreciente. Sin procesamiento adicional, esta propiedad, útil para la estabilidad, puede conducir a la propiedad no deseada de proliferación de categorías, al haber demasiados pesos adaptativos que convergen hacia cero. Para evitar la proliferación de categorías se utiliza un pre procesamiento denominado *codificación complementaria*. La codificación

complementaria normaliza los vectores de entrada, preservando las amplitudes de los atributos individuales. Sin codificación complementaria, un vector de categoría representa el grado en que los atributos críticos de esa categoría están consistentemente presentes en los ejemplares de entrenamiento. Con codificación complementaria el vector de categorías representa tanto el grado de presencia como de ausencia de los atributos. Los

correspondientes procesos de cómputo emplean los operadores difusos OR (\vee , máximo) y AND (\wedge , mínimo)

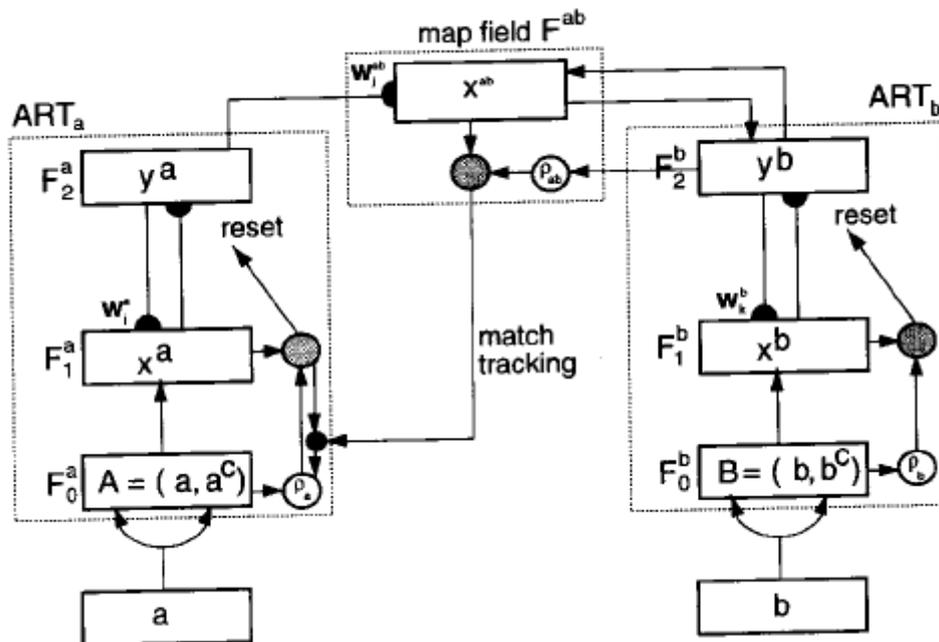


Figura 4.6.1. Arquitectura Fuzzy ARTMAP

Resumen del modelo Fuzzy ART

Vectores de actividad Todo sistema ART incluye un campo F₀ de nodos que representan un vector de entrada. Un campo F₁ que recibe entradas ascendentes desde F₀ y descendentes desde un campo F₂, que representa el código activo o categoría (figura 4.6.1).

El vector de actividad de F₀ se denota como $\mathbf{I} = (I_1, \dots, I_M)$, con cada componente I_i en el intervalo [0, 1].

El vector de actividad de F₁ se denota como $\mathbf{x} = (x_1, \dots, x_M)$.

El vector de actividad de F_2 se denota como $\mathbf{y} = (y_1, \dots, y_N)$. El número de nodos en cada campo es arbitrario.

Vector de pesos Asociado con cada nodo $j = 1, \dots, N$ de F_2 hay un vector de pesos adaptativos o trazos LTM $\mathbf{w}_j \equiv (w_{j1}, \dots, w_{jM})$. Inicialmente se cumple que

$$w_{j1}(0) = \dots = w_{jM}(0) = 1 \quad (4.6.1)$$

se dice entonces que cada categoría está libre o no comprometida. Después que una categoría es elegida para representar a una entrada pasa a denominarse ocupada o comprometida. Cada trazo LTM w_{ji} es monótonamente decreciente en el tiempo y por lo tanto converge hacia un límite. El vector de pesos fuzzy ART incluye ambos vectores de pesos ascendentes y descendentes de ART 1.

Parámetros La dinámica de Fuzzy ART queda determinada por los parámetros de selección $\alpha > 0$; tasa de aprendizaje $\beta \in [0, 1]$; y vigilancia $\rho \in [0, 1]$.

Selección de categoría Para cada entrada \mathbf{I} y nodo j de F_2 , la función de selección T_j se define por

$$T_j(\mathbf{I}) = \frac{|\mathbf{I} \wedge \mathbf{w}_j|}{\alpha + |\mathbf{w}_j|} \quad (4.6.2)$$

donde el operador difuso AND se define como

$$(\mathbf{p} \wedge \mathbf{q})_i \equiv \min(p_i, q_i) \quad (4.6.3)$$

y donde la norma se define por

$$|\mathbf{p}| = \sum_{i=1}^M |p_i| \quad (4.6.4)$$

para cualquier vector M dimensional \mathbf{p} y \mathbf{q} . Para simplicidad de notación, $T_j(\mathbf{I})$ se expresa como T_j cuando la entrada \mathbf{I} es fija.

Se dice que el sistema hace una selección de categoría cuando solo un nodo de F_2 se vuelve activo, en un instante de tiempo dado. La categoría elegida tiene índice J , donde

$$T_j = \max\{T_j : j = 1 \dots N\} \quad (4.6.5)$$

Si más de un T_j es máximo, se elige la categoría con menor índice j . En particular, los nodos se comprometen en el orden $j = 1, 2, 3, \dots$. Cuando se elige la categoría J , $y_J = 1$ e $y_j = 0$ para todo $j \neq J$. En presencia de una elección, el vector de actividad \mathbf{x} cumple con la ecuación

$$\mathbf{x} = \begin{cases} \mathbf{I} & \text{si } F_2 \text{ está inactivo} \\ \mathbf{I} \wedge w_J & \text{si el nodo } J \text{ de } F_2 \text{ fue elegido} \end{cases} \quad (4.6.6)$$

Resonancia o reset La resonancia ocurre si la función semejanza $|\mathbf{I} \wedge w_J| / |\mathbf{I}|$ de la categoría elegida cumple con el criterio de vigilancia

$$\frac{|\mathbf{I} \wedge w_J|}{|\mathbf{I}|} \geq \rho \quad (4.6.7)$$

es decir que por (4.6.6), cuando se elige la categoría J , la resonancia ocurre si

$$|\mathbf{x}| = |\mathbf{I} \wedge w_J| \geq \rho |\mathbf{I}| \quad (4.6.8)$$

El reset por discrepancia ocurre si

$$\frac{|\mathbf{I} \wedge w_J|}{|\mathbf{I}|} < \rho \quad (4.6.9)$$

esto es si

$$|\mathbf{x}| = |\mathbf{I} \wedge \mathbf{w}_J| < \rho |\mathbf{I}| \quad (4.6.10)$$

Entonces el valor de la función de selección T_j se establece en 0 mientras dure la presentación de la información, para prevenir la selección persistente de la misma categoría durante la búsqueda. Luego se elige un nuevo índice J , de acuerdo a (4.6.5). La búsqueda continúa hasta que el J elegido satisface (4.6.7).

Aprendizaje Una vez que finaliza la búsqueda, se actualiza el vector de pesos \mathbf{w}_J de acuerdo a la ecuación

$$\mathbf{w}_J^{(\text{new})} = \beta (\mathbf{I} \wedge \mathbf{w}_J^{(\text{old})}) + (1-\beta) \mathbf{w}_J^{(\text{old})} \quad (4.6.11)$$

El aprendizaje rápido corresponde al caso cuando $\beta = 1$

Opción compromiso rápido y recodificación lenta Para la eficiente codificación de conjuntos de entrada ruidosos, es conveniente establecer $\beta = 1$ cuando J es un nodo libre, y luego hacer $\beta < 1$, cuando la categoría quedó comprometida. En este caso $\mathbf{w}_J^{(\text{new})} = \mathbf{I}$ para la primera vez que se activa la categoría J . En ciertos sistemas ART analógicos puede ocurrir el problema de la proliferación de categorías, cuando un gran número de entradas degrada la norma de los vectores de pesos. La codificación complementaria resuelve este problema.

Normalización de la entrada y codificación complementaria En los sistemas fuzzy ART, la proliferación de categorías se evita si se normalizan las entradas, es decir, si para cierto $\gamma > 0$

$$|\mathbf{I}| \equiv \gamma \quad (4.6.12)$$

para todas las entradas \mathbf{I} . La normalización puede lograrse pre procesando cada vector entrante \mathbf{a} , por ejemplo haciendo

$$\mathbf{I} = \frac{\mathbf{a}}{|\mathbf{a}|} \quad (4.6.13)$$

La codificación complementaria es una regla de normalización que preserva la amplitud de la información. La codificación complementaria representa tanto la presencia como la ausencia de un atributo en los vectores de entrada. Para definir la operación en la forma más simple, sea el mismo \mathbf{a} la representación de la presencia. El complemento de \mathbf{a} , denotado como \mathbf{a}^c , representa la ausencia, donde

$$a_i^c \equiv 1 - a_i \quad (4.6.14)$$

La entrada \mathbf{I} al campo F_1 con codificación complementaria es un vector de $2M$ dimensiones

$$\mathbf{I} = (\mathbf{a}, \mathbf{a}^c) \equiv (a_1, \dots, a_M, a_1^c, \dots, a_M^c) \quad (4.6.15)$$

Nótese que

$$\|\mathbf{I}\| = \|\mathbf{a}, \mathbf{a}^c\| = \sum_{i=1}^M a_i + \left(M - \sum_{i=1}^M a_i \right) = M \quad (4.6.16)$$

Es decir que las entradas pre procesadas con codificación complementaria son normalizadas automáticamente. Cuando se utiliza codificación complementaria, la condición inicial (4.6.1) se reemplaza por

$$w_{j1}(0) = \dots = w_{j,2M}(0) = 1 \quad (4.6.17)$$

Dinámica de un sistema Fuzzy ART

En un sistema ART 1 con aprendizaje rápido, si el parámetro de selección α en (4.6.2) se establece cercano a 0, entonces la primer categoría elegida por (4.6.5) será siempre la categoría cuyo vector de pesos \mathbf{w}_J es el mayor subconjunto codificado del vector de entradas \mathbf{I} , si tal categoría existe. La función de selección T_j en (4.6.2) puede entonces interpretarse como la función difusa de pertenencia de la entrada \mathbf{I} a la categoría J . El límite $\alpha \rightarrow 0$ se denomina límite conservativo porque los valores pequeños de α tienden a minimizar la recodificación durante el aprendizaje.

Para vectores analógicos, el grado en el que q es un subconjunto difuso de p está dado por

$$\frac{|p \wedge q|}{|q|} \quad (4.6.18)$$

En el límite conservativo de un sistema fuzzy ART, la función de selección T_j en (4.6.2) refleja principalmente en qué medida el vector de pesos w_j es un subconjunto difuso del vector de entradas I . Si

$$\frac{|I \wedge w_j|}{|w_j|} = 1 \quad (4.6.19)$$

entonces w_j es un subconjunto difuso de I , y la categoría j se dice que es subconjunto difuso de selección para la entrada I . Cuando existe un subconjunto difuso de selección de categoría, siempre resulta elegido por sobre otras opciones. En este caso, al ser seleccionado j no se produce recodificación ya que $I \wedge w_j = w_j$. Si más de una categoría es un subconjunto difuso de selección, el parámetro α (pequeño pero positivo) rompe el empate, seleccionando el J que maximice $|w_j|$.

La resonancia depende del grado en que I es un subconjunto difuso de w_j , por (4.6.7) y (4.6.9). En particular, si la categoría j es un subconjunto difuso de selección, entonces el valor de la función de semejanza está dado por

$$\frac{|I \wedge w_j|}{|I|} = \frac{|w_j|}{|I|} \quad (4.6.20)$$

Así, eligiendo J para maximizar $|w_j|$ entre todos los subconjuntos difusos de selección, también se maximiza la posibilidad de resonancia en (4.6.7). Si se produce el reset para el nodo que maximiza $|w_j|$, también se producirá para los demás subconjuntos. En el límite conservativo ($\alpha \approx 0$), con aprendizaje rápido ($\beta = 1$) y entradas normalizadas, se produce un aprendizaje denominado mono estable. Esto significa que en tales condiciones no se produce ningún cambio de peso o búsqueda, después que cada ítem del conjunto de entradas fue

presentado sólo una vez, aunque algunas entradas puedan seleccionar categorías diferentes en intentos posteriores. El aprendizaje mono estable se da en módulos fuzzy ART con vigilancia constante. En fuzzy ARTMAP, donde la vigilancia varía cuando se producen errores de predicción, la representación repetida de entradas puede conducir a un nuevo aprendizaje, por lo que el aprendizaje mono estable no necesariamente ocurre.

Un sistema fuzzy ART con codificación complementaria puede interpretarse geoméricamente. Para ejemplificar, sea la entrada un conjunto de vectores 2-dimensional \mathbf{a} , pre procesado con codificación complementaria a la forma 4-dimensional. Es decir

$$\mathbf{I} = (\mathbf{a}, \mathbf{a}_c) = (a_1, a_2, 1-a_1, 1-a_2) \quad (4.6.21)$$

En este caso, cada categoría se puede representar por un rectángulo R_j , de la siguiente manera. Según (4.6.21), el vector de pesos \mathbf{w}_j se puede escribir en formato de codificación complementaria:

$$\mathbf{w}_j = (\mathbf{u}_j, \mathbf{v}_j^c) \quad (4.6.22)$$

donde \mathbf{u}_j y \mathbf{v}_j son vectores 2-dimensionales. Estos vectores definen los vértices del rectángulo R_j (figura 4.6.2a).

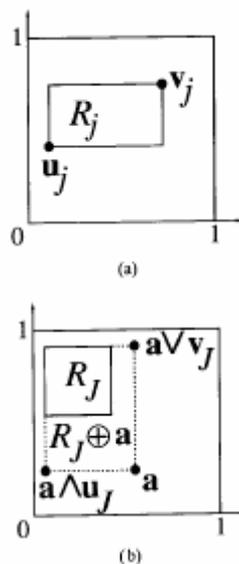


Figura 4.6.2 Representación geométrica de los pesos en Fuzzy ART

El tamaño de R_j está definido por

$$|R_j| \equiv |v_j - u_j| \quad (4.6.23)$$

Que es igual a la altura más el ancho de R_j en la figura 4.6.2a. En aprendizaje rápido, con $\beta = 1$ en (4.6.11), $w_j^{(new)} = \mathbf{I} = (\mathbf{a}, \mathbf{a}^c)$ cuando J es un nodo libre. Los vértices de $R_j^{(new)}$ están dados por \mathbf{a} y $(\mathbf{a}^c)^c = \mathbf{a}$. Por consiguiente $R_j^{(new)}$ se reduce al punto \mathbf{a} . El aprendizaje aumenta el tamaño de cada R_j . De hecho, el tamaño de R_j aumenta a medida que el de w_j se reduce durante el aprendizaje, quedando el tamaño máximo de R_j determinado por el parámetro de vigilancia ρ .

Durante cada ciclo de aprendizaje rápido, R_j se expande hasta $R_j \oplus \alpha$, el menor rectángulo

que contiene a R_j y \mathbf{a} (figura 4.6.2b). Los vértices de $R_j \oplus \alpha$ están dados por $\mathbf{a} \bigvee_{\square} v_j$ y $\mathbf{a} \bigwedge_{\square} u_j$ y \mathbf{a}

OR, \bigvee_{\square} , está definido por

$$(\mathbf{p} \bigvee_{\square} \mathbf{q})_i \equiv \max(p_i, q_i) \quad (4.6.24)$$

Entonces por (4.6.23), el tamaño de $R_j \oplus \alpha$ está dado por

$$|R_j \oplus \alpha| \equiv |(\mathbf{a} \bigvee_{\square} v_j) - (\mathbf{a} \bigwedge_{\square} u_j)| \quad (4.6.25)$$

Sin embargo, el reset lleva a la elección de otra categoría si $|R_j \oplus \alpha|$ es demasiado grande. En resumen, con aprendizaje rápido, cada R_j iguala al menor rectángulo que encierra a todos los vectores \mathbf{a} que eligieron a la categoría j , con la condición que $|R_j| \leq 2(1-\rho)$.

En general, si \mathbf{a} tiene dimensión M , R_j es un hiper rectángulo de tamaño

$$|R_j| = M - |w_j| \leq (1 - \rho) M \quad (4.6.26)$$

Valores altos de ρ obtienen rectángulos más pequeños y viceversa.

En conclusión, un sistema fuzzy ART con codificación complementaria, aprendizaje rápido y vigilancia constante forma categorías híper rectangulares que convergen hacia límites, como respuesta a una secuencia arbitraria de vectores analógicos de entrada. Los híper rectángulos crecen monótonamente en todas las dimensiones. El tamaño $|R_j|$ de un híper rectángulo es igual a $|M - w_j|$, donde w_j es el correspondiente vector de pesos. El tamaño tiene un límite superior dado por $M(1-\rho)$.

5. LA METODOLOGIA CRISP-DM

La metodología CRISP-DM (Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R., 2000) consta de cuatro niveles de abstracción, organizados de forma jerárquica en tareas que van desde el nivel más general hasta los casos más específicos.

A nivel más general, el proceso está organizado en seis fases, estando cada fase a su vez estructurada en varias tareas generales de segundo nivel. Las tareas generales se proyectan a tareas específicas, donde se describen las acciones que deben ser desarrolladas para situaciones específicas. Así, si en el segundo nivel se tiene la tarea general “limpieza de datos”, en el tercer nivel se describen las tareas que tienen que desarrollarse para un caso específico, como por ejemplo, “limpieza de datos numéricos”, o “limpieza de datos categóricos”. El cuarto nivel, recoge el conjunto de acciones, decisiones y resultados sobre el proyecto de Data Mining específico.

La metodología CRISP-DM proporciona dos documentos distintos como herramienta de ayuda en el desarrollo del proyecto de Data Mining: el modelo de referencia y la guía del usuario. El modelo de referencia describe de forma general las fases, tareas y salidas de un proyecto de Data Mining. La guía del usuario suministra información más detallada sobre la aplicación práctica del modelo de referencia a proyectos de Data Mining específicos,

proporcionando consejos y listas de comprobación sobre las tareas correspondientes a cada fase.

La metodología CRISP-DM estructura el ciclo de vida de un proyecto de Data Mining en seis fases, cuya sucesión no es rígida, y se puede mover entre ellas siempre que se requiera. La figura 5.1 esquematiza el ciclo de vida de un proyecto de explotación de datos. Las flechas indican las dependencias más importantes y frecuentes entre las fases. El círculo exterior simboliza la naturaleza cíclica de los proyectos de Explotación de Datos.

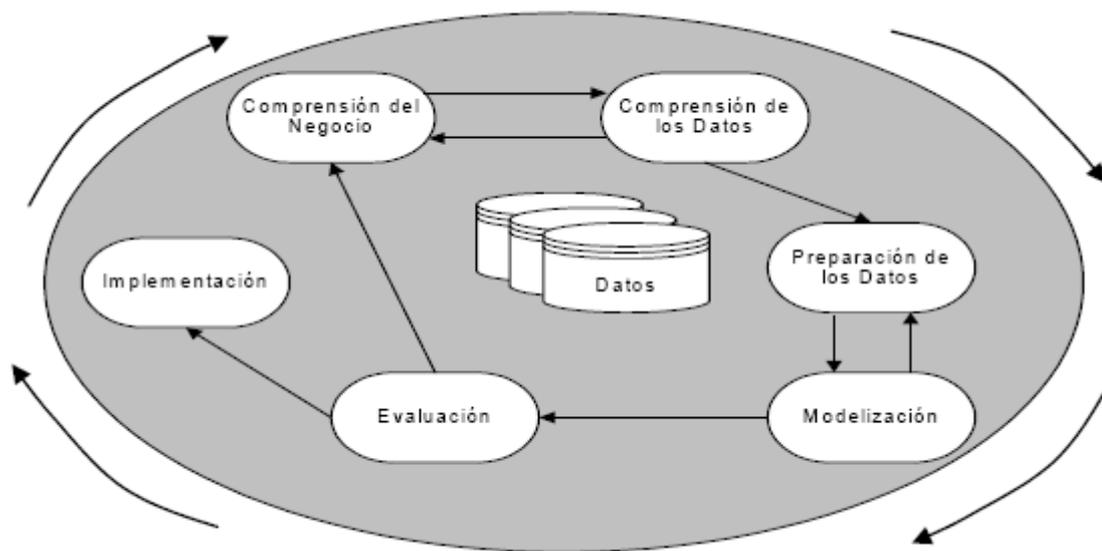


Figura 5.1. Ciclo de vida de un proyecto de Explotación de Datos

La primera fase, comprensión del negocio, incluye la visión de los objetivos y requerimientos del proyecto desde una perspectiva empresarial, con el fin de convertirlos en objetivos técnicos y en una planificación.

La segunda fase, comprensión de los datos, alcanza la recolección inicial de datos, con el objeto de hacer un primer contacto con el problema, identificando la calidad de los datos y buscando las relaciones más evidentes que permitan establecer las primeras hipótesis.

Una vez realizado el análisis de datos, la metodología indica que se proceda a la preparación de los datos, de tal forma que puedan ser tratados por las técnicas de modelado. La preparación de datos incluye las tareas generales de selección de datos (variables y muestras), limpieza de los datos, generación de variables adicionales, integración de diferentes orígenes y cambios de formato. La fase de preparación de los datos, se encuentra muy relacionada con

la fase de modelado, puesto que en función de la técnica que vaya a ser utilizada los datos necesitan ser procesados en diferentes formas. Por lo tanto las fases de preparación y modelado interactúan de forma sistemática.

En la fase de modelado se seleccionan las técnicas más apropiadas para el proyecto de Data Mining específico. Las técnicas a utilizar en esta fase se seleccionan en función de los siguientes criterios:

- Ser apropiada al problema.
- Disponer de datos adecuados.
- Cumplir los requerimientos del problema.
- Tiempo necesario para obtener un modelo.
- Conocimiento de la técnica.

Antes de proceder a la creación del modelo se debe de establecer un método de evaluación del mismo, que permita cuantificar el grado de alcance de los objetivos propuestos. Una vez realizadas estas tareas genéricas se procede a la generación y evaluación del modelo. Los parámetros utilizados en la generación del modelo dependen de las características de los datos.

En la fase de evaluación, se valora el modelo, no desde el punto de vista de los datos, sino del cumplimiento de los criterios de éxito del problema. Se debe revisar el proceso seguido, teniendo en cuenta los resultados obtenidos, para repetir algún paso en el que, a la vista del desarrollo posterior del proceso, se hayan cometido errores. Si el modelo generado es válido en función de los criterios de éxito establecidos en la primera fase, se procede a la implementación del modelo.

Por tratarse éste de un proyecto académico, cuya implementación práctica por ejemplo está fuera de alcance, sólo se desarrollarán las fases aplicables.

6. Fase 1: Comprensión del negocio

6.1. DETERMINACIÓN DE LOS OBJETIVOS DEL NEGOCIO

Objetivos del negocio

El proyecto de explotación de datos, objeto del presente trabajo, tiene aplicación en el ámbito de acción de las Fuerzas Armadas. El objetivo de estas instituciones está estipulado en la Ley 23.554 de Defensa Nacional. Dicho instrumento jurídico expresa que la Defensa Nacional es la integración y la acción coordinada de todas las fuerzas de la Nación para la solución de aquellos conflictos que requieran el empleo de las Fuerzas Armadas, en forma disuasiva o efectiva, para enfrentar las agresiones de origen externo. Tiene por finalidad garantizar de modo permanente la soberanía e independencia de la Nación Argentina, su integridad territorial y capacidad de autodeterminación; proteger la vida y la libertad de sus habitantes.

Bajo este objetivo primario se alinean todas las actividades de las fuerzas y sus componentes. Los principales usuarios del sistema de explotación de datos propuesto, son aquellos componentes de las Fuerzas Armadas, que para el cumplimiento de su misión deban ingresar en zonas de crisis o conflicto bélico, en vehículos ya sea terrestres, marítimos o aéreos. Las fuerzas militares modernas dependen estrechamente de los sistemas electromagnéticos para vigilancia, control de armamento, comunicaciones y navegación. Implementado bajo la forma de un equipo ESM, el sistema de Data Mining constituye una herramienta para analizar los datos presentes en el espectro electromagnético y colaborar con el cumplimiento de los objetivos, y la supervivencia de quienes lo operan.

Background

ESM aproximación clásica

La funcionalidad básica de las aproximaciones ESM actuales se puede descomponer en tres tareas: recepción de las señales radar, agrupación de los pulsos de acuerdo al emisor e identificación del tipo de radar correspondiente.

Las señales radar son interceptadas en forma pasiva por la etapa receptora del sistema ESM. En un teatro de operaciones típico, las señales interceptadas son una mezcla de pulsos electromagnéticos transmitidos desde varias fuentes. La iluminación simultánea de estas fuentes produce solapamiento y “enredo” de los pulsos recibidos. Tras la detección del pulso, la mayoría de los receptores mide la amplitud del pulso (Pulse Amplitud PA), el ancho de pulso (Pulse Width PW), radiofrecuencia de la onda portadora (RF) y tiempo de llegada (Time Of Arrival TOA). Los receptores que tienen capacidad de goniometría también miden la dirección de arribo (Direction Of Arrival DOA), y los más sofisticados también analizan la modulación del pulso (Modulation On Pulse MOP). Una vez que los parámetros del pulso fueron medidos, se digitalizan y ensamblan en una estructura denominada palabra descriptora del pulso (Pulse Descriptor Word PDW).

Las sucesivas PDW son enviadas a un módulo de agrupación, que realiza el desenredo por TOA, o el ordenamiento, o ambos. En síntesis este módulo busca recuperar los trenes de pulsos originales, con su estructura inter pulso, para proceder a su posterior análisis. Esto incluye el agrupamiento progresivo de pulsos que aparentan provenir del mismo emisor. Un emisor es una instancia de un tipo de radar, y es común observar varios emisores del mismo tipo activos a la vez en el teatro de operaciones. A su vez, un mismo radar puede operar en diferentes modos, para realizar distintas funciones. A cada grupo de pulsos se le asocia un rastro (track). Un track consiste en los parámetros contenidos en la PDW más los que se obtienen de la secuencia de PDW, como por ejemplo el intervalo de repetición de pulsos (Pulse Repetition Interval PRI).

Las técnicas de agrupación de pulsos explotan la diferencia de TOA entre los pulsos, o bien los parámetros de la PDW. El separador por TOA intenta descubrir patrones consistentes en el TOA de los pulsos, usando técnicas como los histogramas (Davies, C. L., & Hollands, P., 1982); (Wiley R. G., 1993). Si se encuentran consistencias en el TOA, y estas se correlacionan con las definiciones de radares compiladas en las librerías ESM, entonces los pulsos correspondientes se agrupan y se quitan del conjunto de entrada.

La técnica de ordenamiento en cambio trata de agrupar los pulsos basándose en la similitud de los parámetros de sus PDW, tales como RF, PW y DOA. Los métodos de clustering (Anderberg, 1973); (Wilkinson, M. A., and Watson, M. A., 1985) son comúnmente usados para este fin.

El proceso de identificación utiliza la librería ESM, donde están almacenadas las descripciones paramétricas de los radares conocidos, e intenta asignar un único tipo de radar a cada track. Incidentalmente, los rangos paramétricos de distintos tipos de la librería se pueden superponer, dando lugar a múltiples candidatos para el mismo track. Esta situación se denomina *ambigüedad*. En estos casos el sistema reporta una lista de radares probables para cada track, junto con el porcentaje de confianza, el nivel de amenaza y la última DOA recibida. Un mayor análisis puede ayudar al operador de ESM a revelar otros datos como la ubicación espacial y la plataforma portante.

Problemas a resolver

Las señales de radar presentan cada vez más agilidad en sus parámetros, a la vez que emplean elaborados esquemas de manejo de la potencia emitida, con formas de onda de baja probabilidad de intercepción. Las librerías ESM son difíciles de mantener. Las plataformas no tripuladas requieren sistemas ESM autónomos. Todas estas tendencias motivan aproximaciones de ESM más potentes.

La multiplicidad de los modos de funcionamiento de un radar es el resultado del control computarizado de los mismos, y de la facilidad con que los parámetros como RF y PRI pueden ser variados. La agilidad en RF Y PRI puede convertir a la agrupación de pulsos en una tarea en extremo compleja.

Tiempos de respuesta más cortos implican algoritmos de agrupamiento más rápidos y que empleen menos pulsos para lograr la identificación. Además, al trabajar con bajas potencias de emisión, se pueden perder pulsos que están por debajo del umbral de detección del receptor, por consiguiente el agrupamiento de pulsos debe funcionar satisfactoriamente con información incompleta. El tiempo de respuesta es crítico para evadir una amenaza, ya sea por lanzamiento de señuelos, acción evasiva o generación de interferencia electrónica.

Mantener actualizada una librería ESM que refleje con exactitud cada ambiente operacional es complejo y oneroso. La construcción de la librería requiere el modelado explícito de todos los sistemas de radar conocidos, basado en información previa y que no fue necesariamente extraída del ambiente donde se está operando. La tarea es compleja y tediosa, además de proclive a errores dado que algunos tipos de radar son difíciles de describir.

Debido a la multiplicación de modos de trabajo es común que una librería esté incompleta o contenga errores. Sumado a esto, las amenazas podrían deliberadamente reservar algunos de sus modos para usar durante tiempos de guerra. La identificación del tipo de radar debe ser tolerante a todos estos inconvenientes. La aproximación paramétrica clásica de clasificación de patrones pierde efectividad en estos casos.

El despliegue de sistemas ESM sobre plataformas autónomas, tales como vehículos aéreos no tripulados (Unmanned Aerial Vehicle UAV), aumentan las expectativas sobre éstos. Sin un operador que interprete la salida del ESM y provea discernimiento, es el propio sistema quién debe lograr un alto estándar de precisión y confiabilidad.

Criterios de éxito del negocio

La valoración previa de un sistema de uso militar es difícil de establecer debido a la imposibilidad de reproducir fielmente las circunstancias en que debe operar, es decir una guerra o situación de crisis. Ante esta limitación, el criterio de éxito más aceptable es evaluar las respuestas del sistema en un ambiente electromagnético simulado. Para este fin se habrá de elaborar un plan de pruebas que contemple la mayor diversidad posible de situaciones. En las evaluaciones se ponderará el correcto reconocimiento de señales que impliquen mayor grado de amenaza o peligrosidad.

6.2. EVALUACIÓN DE LA SITUACIÓN

Inventarios de recursos

Por tratarse de un proyecto de finalidad académica, los recursos humanos y materiales son limitados, pero suficientes para tal fin.

Los participantes en el proyecto son el autor y su tutor.

Los recursos materiales consisten en:

Dos computadoras personales con sistema Microsoft Windows, una con el paquete Office 2007 para desarrollo del proyecto y otra con el software Matlab 6.1 con varios toolboxes para simulación y prueba del modelo.

Archivos electrónicos de datos de radares sobre plataformas y sistemas operativos obsoletos o propietarios. Los datos también están disponibles en forma impresa en papel.

Requisitos, supuestos y restricciones

El requisito más condicionante es lograr el acceso al archivo electrónico de datos, y para ello se supone que se logrará implementar una interface de hardware y software, que permita la migración a un formato de bases de datos de uso corriente y actual.

Pesa una restricción legal sobre este trabajo, que por ser de acceso público no puede contener información clasificada. El autor fue autorizado a utilizar los datos para desarrollar el proyecto, pero no a publicarlos, por esta razón no se mencionan valores reales de los parámetros de radares. La restricción también abarca los algoritmos de software, que son referidos en forma más o menos genérica, sin traspasar los límites legales. Esta restricción no impide la cabal comprensión y evaluación de los conceptos expuestos, ni de los resultados obtenidos.

Riesgos y contingencias

El principal riesgo que se vislumbra es no lograr la migración automática de los datos en tiempo y forma. En ese caso la solución alternativa es transcribir los datos a mano, a partir de los registros impresos. Si se da esa situación se construirá una herramienta de software para minimizar los errores tipográficos y se solicitará la participación de personal auxiliar para la carga de datos.

Terminología

Es muy habitual en la comunidad de radar e inteligencia electrónica, referirse a parámetros y procesos muy utilizados según sus acrónimos en inglés. En este trabajo se respeta esa costumbre y por esa razón se incluye en el Apartado 1 un glosario con la definición de cada uno de ellos.

6.3. DETERMINACIÓN DE LOS OBJETIVOS DEL DATA MINING

Las metas del Data Mining

Los principales objetivos del sistema, desde el punto de vista de explotación de datos, son:

Requerimiento 1. Poseer capacidad de aprendizaje rápido para aprender incrementalmente información de radares conocidos o desconocidos, sin necesidad de un re entrenamiento completo.

Requerimiento 2. Tomar decisiones de clasificación sobre la base de un único pulso, o para mayor precisión, sobre la base de una cadena de pulsos que se han determinado como provenientes de un mismo emisor. Esta determinación se realizará mediante un separador basado en el tiempo de llegada (Time Of Arrival TOA), o cuando ésta no es practicable, por un filtro Kalman que rastrea la dirección de llegada y la amplitud de los pulsos. De esta forma el sistema constituye un ejemplo de red neuronal que combina información temporal, espacial y distintiva para arribar a su decisión.

Requerimiento 3. Extender la funcionalidad del algoritmo de reconocimiento para permitir al sistema, no solamente detectar los pulsos de tipos de radares desconocidos (no presentados durante el entrenamiento), sino también para permitir el aprendizaje en tiempo real de clases desconocidas.

Requerimiento 4. Lograr el entrenamiento y validación sobre conjuntos de datos incompletos, es decir con atributos o etiquetas de clase faltantes.

Criterios de éxito del Data Mining

Los criterios de éxito del data mining se basan en la evaluación de la precisión del modelo, su rendimiento y complejidad.

La precisión mínima que se espera del modelo queda expresada por una tasa de clasificación de 95% o superior.

El rendimiento mínimo que se espera del modelo queda expresado por un tiempo de convergencia no superior a 5 y una tasa de compresión superior a 200.

La complejidad máxima que se espera del modelo queda expresada por una cantidad de registros de memoria no superior a 800.

Los parámetros tasa de clasificación, tiempo de convergencia, tasa de compresión y registros de memoria se definen en el Apartado 9, donde se aborda la fase de modelado de la metodología CRISP-DM

7. FASE 2: ENTENDIMIENTO DE LOS DATOS

7.1. RECOLECCIÓN DE LOS DATOS INICIALES

Los datos necesarios para entrenar la red pueden ser tomados de los archivos de inteligencia electrónica de las Fuerzas Armadas. Estos archivos contienen datos que fueron recogidos en campo y compilados a mano por especialistas. La gran mayoría de los datos están contenidos en archivos electrónicos sobre plataformas y sistemas operativos obsoletos o propietarios, que no permiten una migración trivial a sistemas actuales de uso corriente. La información también se encuentra impresa en papel.

El caso de data mining que nos ocupa es diferente al caso clásico de aplicaciones comerciales, donde se trata de analizar bases de datos históricas que pueden ser enormes y donde el tiempo de procesamiento no es una variable crítica. En esta aplicación el volumen de datos a manejar es relativamente reducido, pero el verdadero desafío es obtener la clasificación de los pulsos en tiempo real.

7.2. DESCRIPCIÓN DE LOS DATOS

Cada pulso es identificado con dos etiquetas, una con el tipo de radar y otra con el modo de trabajo. Los atributos empleados son DOA, PA, PRI, PW y RF. A continuación se describe cada uno de ellos.

DOA (Direction of Arrival). Valor angular de la dirección de incidencia de la energía electromagnética respecto del norte geográfico. Rango de valores de 0 a 359°, resolución 8 bits.

PA (Pulse Amplitude). Amplitud del pulso expresada en dbm (0 dbm equivale a 1 mW sobre 50 ohm). Rango dinámico de -60 dbm a +10 dbm. Resolución 8 bits = 0,27 dbm

PRI (Pulse Repetition Interval). Intervalo de tiempo entre pulsos consecutivos de un mismo emisor. Rango de valores de 10 microsegundos a 20 milisegundos. Resolución 16 bits. (Nótese que este no es un atributo propio de un solo pulso sino que es un parámetro inter pulso).

PW (Pulse Width). Ancho de pulso expresado como el tiempo entre el flanco ascendente y el flanco descendente, tomado al 50% de la amplitud. Rango de valores de 50 nanosegundos a 100 microsegundos. Resolución 16 bits.

RF (Radio Frequency). Frecuencia de la señal portadora. Rango de valores de 2 a 18 Giga Hertz. Resolución 13 bits.

Todos los atributos juntos, representados como una cadena de bits, se denominan Pulse Descriptor Word (PDW). Los parámetros PRI, PW y RF son específicos de tipo, pues identifican un tipo de radar. En cambio los parámetros DOA y PA tienen que ver con la posición en el espacio del emisor radar respecto del receptor ESM.

De aquí en más denotaremos una PDW como $(\mathbf{a}; \mathbf{b})$. Los parámetros de las cadenas específicas de tipo y espaciales quedan definidos por $\mathbf{a} = (\text{PRI}, \text{PW}, \text{RF})$ y $\mathbf{b} = (\text{DOA}, \text{PA})$ respectivamente.

8. FASE 3: PREPARACIÓN DE LOS DATOS

8.1. PREPARACIÓN DE LOS DATOS DEL PULSO RADAR

DOA, PA, PW y RF son atributos automáticamente producidos por el receptor para cada pulso individual, el PRI en cambio es derivado de la diferencia en TOA entre pulsos del mismo emisor. Debe notarse que, cómo se requieren al menos dos pulsos sucesivos para computar el valor de PRI, el primer patrón de cada emisor activo será omitido en las simulaciones. De la misma manera, debido al barrido de los radares, los pulsos se reciben en ráfagas. El primer pulso de cada barrido o ráfaga también será omitido.

Finalmente los parámetros son normalizados linealmente de manera que $a_i, b_j \in [0, 1]$, para $i = 1, 2, 3$ y $j = 1, 2$.

El cúmulo de información empleada para entrenar la red debe ser acorde a las especificaciones de precisión que se le imponen. Para lograr un desempeño aceptable, en un escenario de mediana densidad electromagnética, el conjunto de entrenamiento debería contener no menos de 50.000 muestras pertenecientes a no menos de 30 modos de trabajo, de un mínimo de 15 emisores diferentes. Nótese que en un teatro de operaciones bélico estas muestras pueden obtenerse en un lapso muy breve de tiempo (menos de 20 segundos). Es conveniente que los datos contengan múltiples emisores del mismo tipo, modos con parámetros que se superpongan, radares con esquemas de PRI complejo y agilidad en RF, para lograr un entrenamiento más general de la red.

9. FASE 4: MODELO

9.1. SELECCIÓN DE LA TÉCNICA DE MODELADO

Se describe aquí una nueva aproximación para el reconocimiento automático del tipo de radar. Cuando las plataformas recolectoras de datos se envían a un teatro de operaciones, previo a una intervención militar, éstas pueden obtener datos de los radares de interés. Las plataformas recolectoras pueden ser aviones o buques tácticos, UAV o aviones preparados para guerra electrónica. La información recogida previamente, o durante un conflicto es analizada online u offline en una estación ELINT. Mientras que habitualmente estos datos son combinados con información previa de otros ambientes, y volcados por expertos en librerías, en este trabajo exploraremos su utilización para entrenar un sistema de reconocimiento basado en una red neuronal artificial. Una vez entrenada con los datos, la red puede clasificar los pulsos sin el proceso de agrupamiento. Esta aproximación ofrece varias ventajas potenciales.

En primer lugar entrenar con información real, extraída en el campo puede arrojar una mayor precisión en la clasificación. Los algoritmos de aprendizaje adaptativo utilizados para entrenar redes neuronales constituyen una alternativa interesante al modelado explícito, actualmente utilizados en las librerías ESM, dado que pueden estimar las funciones de mapeo de entradas desconocidas a clases de reconocimiento, directamente del conjunto de entrenamiento. El proceso de aprendizaje supervisado intenta aproximar funciones de mapeo desconocidas. El mapeo se usa luego para generalizar, es decir para predecir la clase de salida (tipo de radar) que corresponde a un patrón desconocido de entrada (pulsos).

En segundo lugar, otra característica atractiva de las redes neuronales es su habilidad intrínseca para manejar descripciones incompletas de los tipos de radares. Dado que es imposible contar con un conjunto exhaustivo de datos para entrenar la red, es importante tener la capacidad de reconocer nuevos radares encontrados durante la fase de operación. Los clasificadores basados en redes neuronales con capacidad de aprendizaje incremental online, constituyen un marco de trabajo consistente para refinar automáticamente la descripción de

radares conocidos, a la vez que para detectar nuevos y aprender sus descripciones, mientras se desarrolla la operación.

Finalmente, la arquitectura paralela masiva de una red neuronal, cuando se implementa sobre el hardware apropiado puede proveer un procesamiento de las PDW extremadamente rápido y tolerante a fallos. La implementación puede ser también, en cierta medida, tolerante a información incompleta y ruidosa, exhibiendo una aceptable degradación en su desempeño. La naturaleza online de las redes también elimina la necesidad de acumular pulsos como paso previo al procesamiento.

9.2. CONSTRUCCIÓN DEL MODELO

Una posible materialización de una red neuronal en un sistema de reconocimiento ESM se ilustra en la figura 9.2.1 (Granger, E., Rubin, M. A., Grossberg, S., & Lavoie, P., 2000).

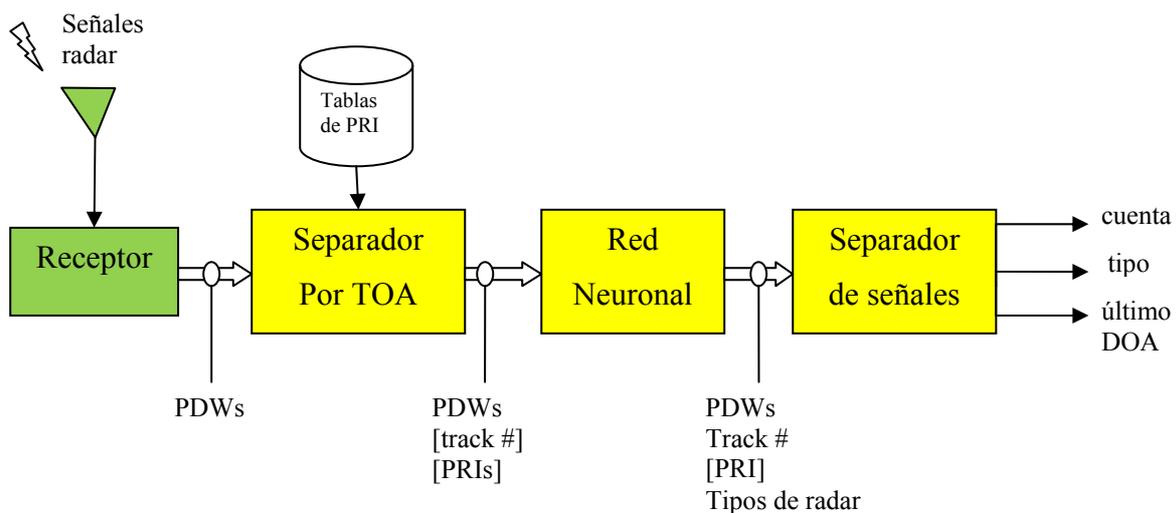


Figura 9.2.1. Diagrama en bloques de un sistema ESM (los corchetes indican que el campo puede estar vacío para algunos pulsos)

En primer lugar un separador por TOA descubre periodicidades en el TOA de las PDW entrantes. Si la agrupación de pulsos resulta posible, forma tracks y les asigna un número de track y PRI a cada pulso del grupo. El desenredo por TOA continúa jugando un papel importante en ESM, dado que es suficiente para agrupar pulsos de emisores que tienen patrones simples de PRI, como muchos de los radares Doppler. Además los valores de PRI por sí mismos son muy útiles para la clasificación de los pulsos.

La red neuronal recibe todas las PDW, algunas de las cuales tienen número de track y parámetros de PRI. La red ya ha sido entrenada offline con datos de radares conocidos. Los pesos de la red reemplazan a la librería ESM, y pueden actualizarse periódicamente aprendiendo de la información de radar recibida durante la operación. La red neuronal realiza una predicción del tipo de radar para cada PDW, y le asigna un número de track a las que no lo recibieron del separador por TOA. La asignación de tracks es autónoma y tiene lugar independientemente de la clasificación del tipo de radar. La clasificación en cambio sí toma en cuenta el número de track asignado.

El módulo restante de la figura 9.2.1 es un separador de señal, que recibe todas las PDW junto con su número de track, tipo de radar y cuando están disponible, los parámetros de PRI. El separador de señal es el responsable de la asignación final del número de track, y de asentar la secuencia de PDW en reportes que son actualizados periódicamente. La asignación final toma en cuenta el reconocimiento previamente efectuado por la red neuronal, del tipo de radar. El reporte de emisores contiene, entre otros datos, el tipo y la última dirección de arribo.

Arquitectura del modelo

Las PDW se pueden particionar en dos cadenas. Una cadena constituye los parámetros que caracterizan los aspectos funcionales del radar. Estos parámetros incluyen la RF, el PW y PRI, y son los que habitualmente se compilan en las librerías ESM porque son directamente útiles para reconocer el tipo de radar. La otra cadena consiste en los parámetros específicos del contexto, tales como la DOA y la amplitud, que reflejan la posición del emisor en el espacio. Estos parámetros son menos útiles que los anteriores para el reconocimiento del tipo de radar, pero son importantes para agrupar los pulsos en tracks o trayectorias.

Procesamiento diferencial de las dos cadenas

La arquitectura interna de la red neuronal se muestra en la figura 9.2.2. Está compuesta por tres subsistemas: el clasificador (red neuronal en sí), el de agrupamiento (clustering) y el de acumulación de evidencia.

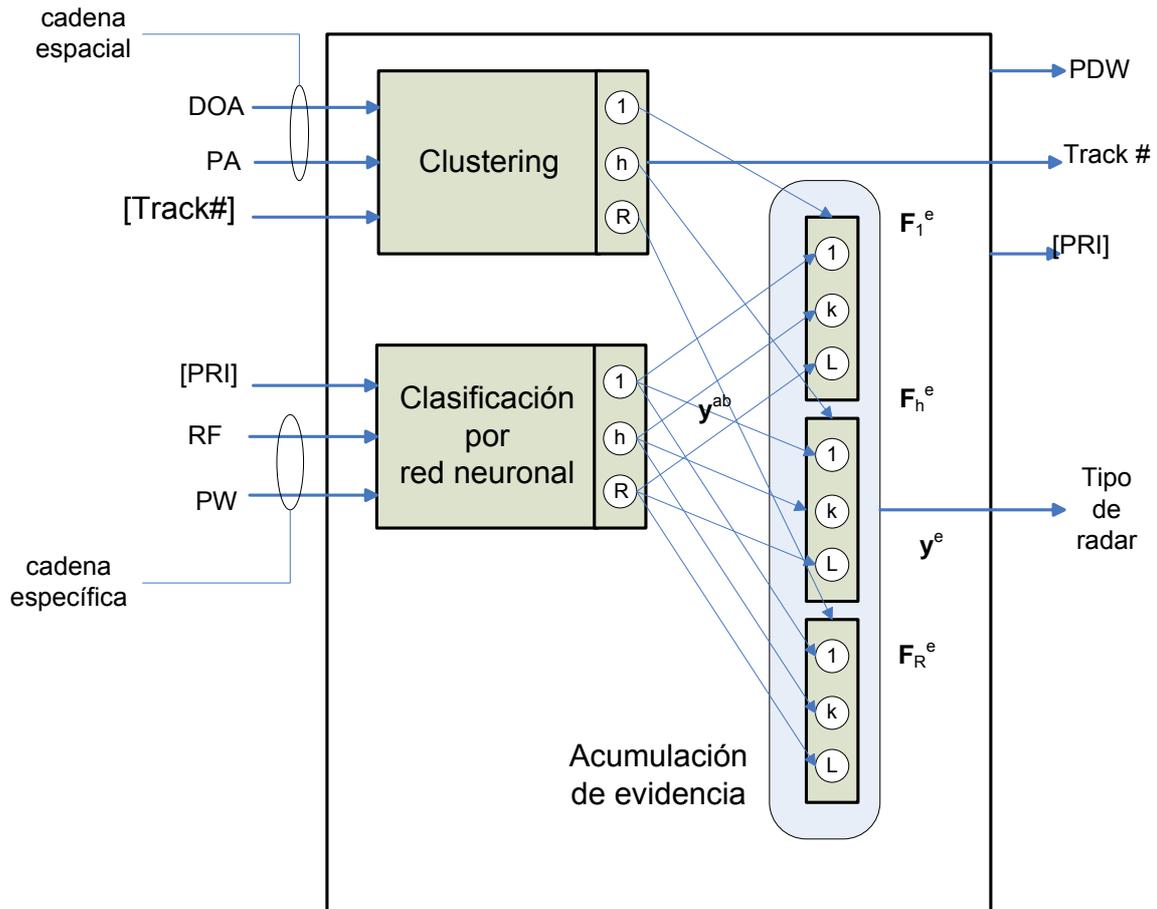


Figura 9.2.2. Arquitectura interna de la red neuronal

Estos tres subsistemas cooperan para predecir el tipo de radar más probable para cada pulso entrante.

Antes de la operación en línea, el módulo de clasificación se entrena mediante aprendizaje supervisado, usando datos de radares colectados en el campo y etiquetados con su respectivo tipo de radar. Sólo los parámetros específicos de tipo se utilizan en el entrenamiento, incluyendo el PRI si está disponible.

Durante la operación online, el sistema de reconocimiento acepta la secuencia de PDW correspondiente a los pulsos interceptados, así como el número de track y PRI de cada pulso agrupado por el separador por TOA. Los parámetros de cada PDW predefinidos como específicos de tipo o espaciales se separan y envían a la red neuronal y al subsistema de clustering respectivamente.

Para cada pulso, el subsistema de clasificación acepta los parámetros específicos de tipo, incluyendo el PRI si está disponible, y emite una predicción del tipo de radar. Esta predicción tiene la forma de un patrón denotado por y^{ab} . Mientras tanto, el subsistema de clustering

intenta agrupar los pulsos en tracks basándose en los parámetros espaciales. Si el número de track ya fue provisto por el separador por TOA, la salida de este subsistema es descartada. Ya sea que el subsistema produzca un número de track por sí mismo, o lo reciba del separador, mantiene una imagen actualizada del número y la actividad de los emisores que iluminan el sistema ESM.

Acumulación de evidencia

En los sistemas ESM convencionales, la información espacial se utiliza antes en la cadena de procesamiento (por ejemplo en la formación del track), para reducir el cúmulo de información y subsecuentemente los costos computacionales. La red neuronal materializa una alternativa que integra los parámetros específicos de tipo y espaciales, para un mejor reconocimiento, antes de la reducción de datos.

La fusión de las respuestas de los subsistemas de clasificación y de clustering se realiza en el módulo de acumulación de evidencia. Los patrones de respuesta y^{ab} obtenidos por el subsistema de clasificación son acumulados a lo largo del tiempo según los tracks, es decir según los agrupamientos surgidos de la información espacial.

Los números de track obtenidos en el módulo de clustering indican los emisores a los que se asocian las PDW, conduciendo la acumulación de evidencia.

La acumulación de evidencia se implementa como un conjunto de campos de acumulación de evidencia, donde cada campo F_h^e corresponde a un track $h = 1, 2, \dots, R$. La asignación de un track $h = H$ a una PDW activa un campo de acumulación de evidencia F_H^e que acumula los patrones de salida y^{ab} del módulo de clasificación. La acumulación produce el patrón de respuesta del tipo de radar y^e , para cada PDW, que se obtiene de una o más respuestas y^{ab} .

La red ARTMAP para clasificación

ARTMAP refiere a una familia de redes neuronales capaces de realizar aprendizaje rápido, incremental, online, supervisado o no supervisado (Carpenter, G.A., Grossberg, S., Markuzon, N., Reynolds, J. H., & Rosen, D. B., 1992). Las redes ARTMAP presentan varias características atractivas para ser empleadas en sistemas ESM.

- Pueden aprender en forma rápida y estable a partir de eventos nuevos encontrados en campo. Las redes neuronales clásicas, como el Perceptrón Multicapa y Radial Basis Function (Chen, S., Cowan, C. F. N., & Grant, P. M., 1991) requieren un re

entrenamiento offline de todo el conjunto completo de datos, a través de un proceso lento e iterativo, para aprender nuevos tipos de radares.

- Las redes ARTMAP también realizan “discriminación de familiaridad”, para evitar predicciones carentes de sentido de clases de radar desconocidas (Carpenter, G. A., Rubin, M. A., & Streilein, W. W., 1997a).
- Pueden representar un tipo de radar usando uno o más prototipos, lo cual resulta deseable para manejar radares con varios modos de operación.
- La arquitectura ARTMAP se presta naturalmente para el procesamiento paralelo de alta velocidad, hecho que resulta crítico para la identificación en tiempo real.

Fuzzy ARTMAP

La arquitectura fuzzy ARTMAP es aplicada generalmente en la versión simplificada mostrada en la figura 9.2.3.

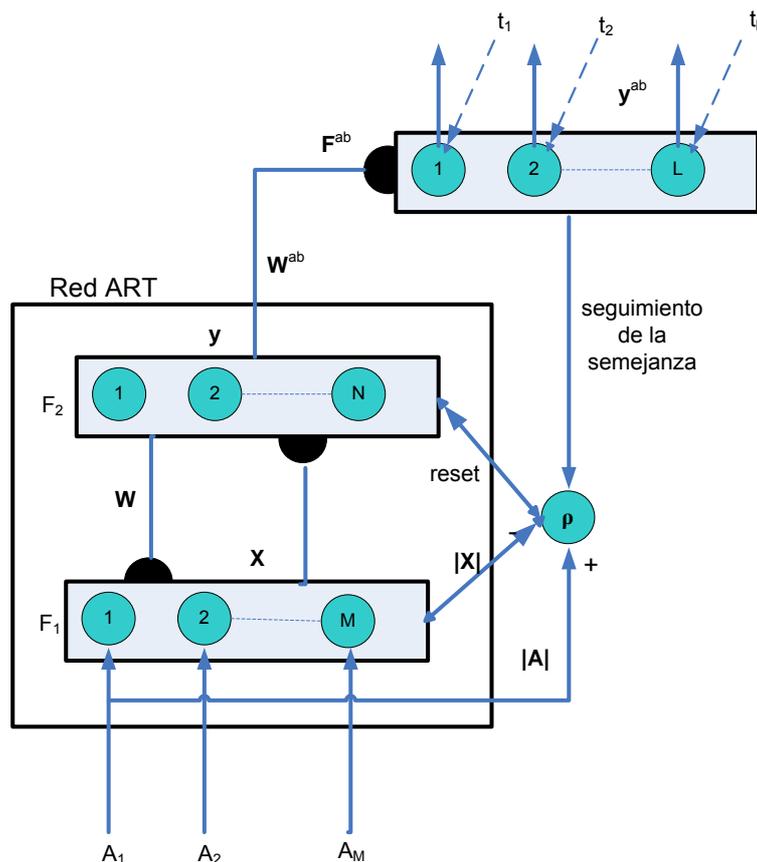


Figura 9.2.3. Arquitectura fuzzy ARTMAP especializada en reconocimiento de patrones

Se obtiene combinando una red ART no supervisada con un campo de mapeo. Una arquitectura fuzzy ARTMAP puede procesar información tanto analógica como digital, empleando fuzzy ART como red. Una red neuronal Fuzzy ART consiste de dos capas de nodos totalmente conectados: una capa de entrada F_1 con M nodos, y una capa competitiva F_2 con N nodos. Un conjunto de pesos, de valores reales $\mathbf{W} = \{w_{ij} \in [0, 1]: i = 1, 2, \dots, M; j = 1, 2, \dots, N\}$ es asociado con las conexiones entre las capas F_1 y F_2 . Cada nodo j de F_2 representa una categoría de reconocimiento que aprende un vector prototipo $\mathbf{w}_j = (w_{1j}, w_{2j}, \dots, w_{Mj})$. La capa F_2 está conectada, a través de vínculos asociativos, a un campo de mapeo F^{ab} de L nodos, donde L es el número de clases en el espacio de salida. Un conjunto de pesos binarios $\mathbf{W}^{ab} = \{w_{jk}^{ab} \in [0, 1]: j = 1, 2, \dots, N; k = 1, 2, \dots, L\}$ se asocia con las conexiones de F_2 a F^{ab} . El vector $w_j^{ab} = (w_{j1}^{ab}, w_{j2}^{ab}, \dots, w_{jL}^{ab})$ vincula el nodo j de F_2 con una de las L clases de salida. Durante el entrenamiento la red hace aprendizaje supervisado del mapeo entre los vectores de entrenamiento $\mathbf{a} = (a_1, a_2, \dots, a_m)$ y las salidas $\mathbf{t} = (t_1, t_2, \dots, t_L)$, donde $t_K = 1$ si K es la clase para \mathbf{a} , y cero en caso contrario.

La siguiente secuencia describe el algoritmo de aprendizaje fuzzy ARTMAP (figura 9.2.4):

1. **Inicialización.** Inicialmente todos los nodos F_2 están libres, todos los pesos w_{ij} son iguales a 1 y todos los pesos w_{jk}^{ab} son iguales a 0. Un nodo de F_2 pasa a ser comprometido cuando es seleccionado para codificar a un vector de entrada \mathbf{a} , y es entonces vinculado a un nodo de F^{ab} . Los parámetros de la tasa de aprendizaje $\beta \in [0, 1]$, la selección $\alpha > 0$ y la vigilancia $\rho \in [0, 1]$ son establecidos a su valor inicial.
2. **Codificación del patrón de entrada.** Cuando un par de vectores de entrenamiento (\mathbf{a}, \mathbf{t}) es presentado a la red, \mathbf{a} sufre una transformación denominada codificación complementaria, que duplica el número de sus componentes. El patrón de entrada así codificado tiene $M = 2m$ dimensiones y está definido por $\mathbf{A} = (\mathbf{a}, \mathbf{a}^c) = (a_1, a_2, \dots, a_m; a_1^c, a_2^c, \dots, a_m^c)$, donde $a_i^c = (1-a_i)$, y $a_i \in [0, 1]$. El parámetro de vigilancia ρ es reseteado a su valor base.
3. **Selección del prototipo.** El patrón \mathbf{A} activa la capa F_1 y se propaga a través de los pesos de conexión \mathbf{W} a la capa F_2 . La activación de cada nodo j en la capa F_2 está determinada por la función de selección de Weber:

$$T_j(\mathbf{A}) = \frac{|\mathbf{A} \wedge \mathbf{w}_j|}{\alpha + |\mathbf{w}_j|} \quad (9.2.1)$$

Donde $|\cdot|$ es el operador norma, $|\mathbf{w}_j| = \sum_{i=1}^M |w_{ij}|$
 \bigwedge es el operador difuso AND, $(\mathbf{A} \bigwedge \mathbf{w}_j)_i \equiv \min(A_i, w_{ij})$
 α es el parámetro de selección definido por el usuario.

La capa F_2 produce, por medio de una competencia winner-take-all, un patrón binario de actividad $\mathbf{y} = (y_1, y_2, \dots, y_N)$ tal que solamente el nodo $j = J$ con el mayor valor de activación $J = \operatorname{argmax}\{T_j : j = 1, 2, \dots, N\}$ permanece activo; entonces $y_J = 1$ e $y_j = 0, j \neq J$. Si más de un T_j es máximo, es seleccionado el nodo j con el menor índice. El nodo J propaga su expectativa descendente, o vector prototipo \mathbf{w}_j , de vuelta hacia F_1 y se realiza la prueba de vigilancia. Esta prueba compara el grado de semejanza entre \mathbf{w}_j y \mathbf{A} contra el parámetro de vigilancia adimensional ρ :

$$\frac{|\mathbf{A} \wedge \mathbf{w}_j|}{M} \geq \rho \quad (9.2.2)$$

Si se pasa la prueba el nodo J permanece activo, y se dice que se alcanzó la resonancia. De lo contrario, la red inhibe el nodo activo de F_2 (o sea T_j es puesto a 0 hasta que sea presentado a la red el próximo par de entrenamiento (\mathbf{a}, \mathbf{t})) y busca otro nodo J que pase la prueba de vigilancia. Si ese nodo no existe, se activa un nodo libre. La profundidad de la búsqueda, antes de que se seleccione un nodo libre está determinada por el parámetro de selección α .

4. **Predicción de clase.** El patrón \mathbf{t} es enviado directamente al campo de mapeo F^{ab} , mientras la categoría y de F_2 aprende a activar el campo de mapeo a través de los pesos asociativos \mathbf{W}^{ab} . La capa F^{ab} genera un patrón binario de actividad $\mathbf{y}^{ab} = (y_1^{ab}, y_2^{ab}, \dots, y_L^{ab})$, en el cual el nodo K más activo produce la predicción de clase $K = k(J)$. Si el nodo K constituye una predicción de clase incorrecta, una señal de seguimiento de la semejanza aumenta el

parámetro de vigilancia ρ , justo lo suficiente para inducir otra búsqueda entre los nodos de F_2 , en el paso 3. Esta búsqueda continúa hasta que es activado un nodo libre de F_2 (y el aprendizaje sigue con el paso 5), o hasta que se active un nodo J que haya aprendido previamente la predicción correcta.

5. **Aprendizaje.** El aprendizaje de la entrada \mathbf{a} involucra la actualización del vector prototipo \mathbf{w}_j , y si J corresponde a un nodo recientemente comprometido, la creación de un vínculo asociativo con F^{ab} . El vector prototipo J de F_2 es actualizado de acuerdo a

$$\mathbf{w}'_J = \beta(\mathbf{A} \wedge \mathbf{a}) + (1 - \beta)\mathbf{w}_J \quad (9.2.3)$$

donde β es la tasa de aprendizaje fija. El algoritmo puede configurarse para aprendizaje lento con $0 < \beta < 1$, o para aprendizaje rápido con $\beta = 1$. Con codificación complementaria y aprendizaje rápido, fuzzy ART representa a una categoría j como un hiper rectángulo R_j m -dimensional, que tiene el tamaño justo para contener el cluster del patrón de entrenamiento \mathbf{a} , al que ha sido asignado. Para aprender una nueva asociación entre el nodo J de F_2 y el nodo K de F^{ab} ($k(J) = K$), se hace $w_{Jk}^{ab} = 1$ para $k = K$, donde K es la clase deseada para \mathbf{a} , o cero para $k \neq K$. Una vez que los pesos \mathbf{W} han convergido para el conjunto de patrones de entrenamiento, ARTMAP puede predecir la clase para un patrón de entrada cualquiera, ejecutando los pasos 2, 3, y 4 sin ninguna vigilancia, o prueba de semejanza.

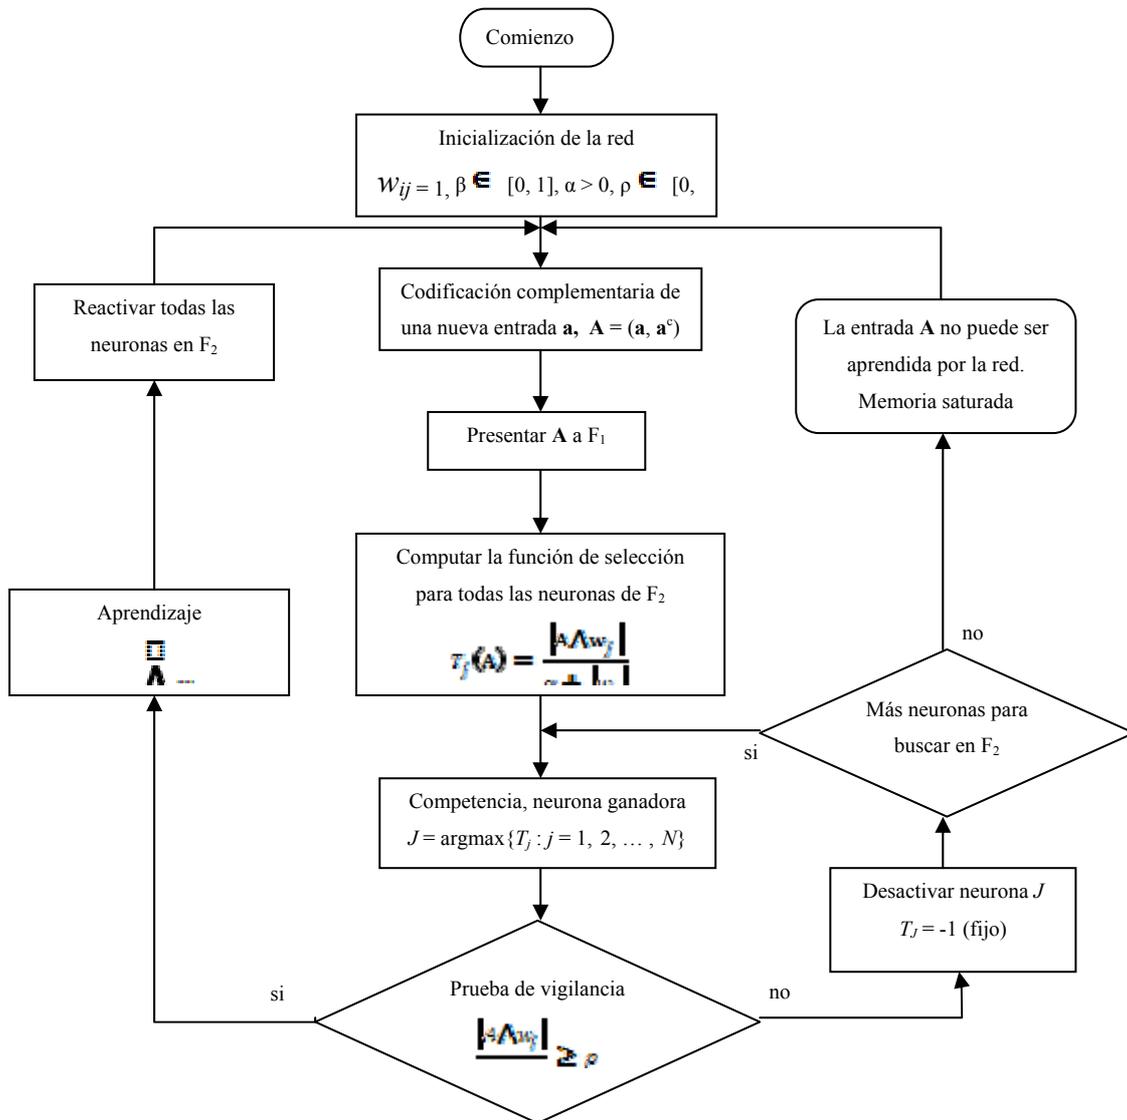


Figura 9.2.4. Diagrama de flujo del algoritmo fuzzy ARTMAP

9.3. AGRUPAMIENTO DE PATRONES

El objetivo del módulo de clustering en la arquitectura de reconocimiento ilustrada en la figura 9.2.2, es agrupar en tracks los patrones de la cadena espacial. Las señales entrantes contienen información acerca del estado del emisor, que puede cambiar con el tiempo. Es deseable que este clustering online tenga la capacidad de inicializar nuevos tracks cada vez que es detectado un emisor nuevo, de ajustar los tracks en respuesta a los cambios de los emisores y de eliminar tracks cuando los emisores desaparecen o dejan de transmitir.

$$s_h(\mathbf{b}) = \frac{1}{(2\pi)^{\frac{M}{2}} |\Lambda_h|^{\frac{1}{2}}} \exp\left\{-\frac{1}{2}(\mathbf{b} - \hat{\mathbf{x}}_h)^T \Lambda_h^{-1} (\mathbf{b} - \hat{\mathbf{x}}_h)\right\} \quad (9.2.4)$$

Donde M es el número de dimensiones en el entorno espacial, y $\hat{\mathbf{x}}_h$ y Λ_h son respectivamente la posición predicha y la matriz de covarianza para el track h . Suponiendo que todos los tracks tienen igual probabilidad a priori, el track $h = H$ que maximiza la ecuación (9.2.4) es asociado con el patrón \mathbf{b} :

$$\mathbf{H} = \operatorname{argmax}_h \{s_h(\mathbf{b}) : h = 1, 2, \dots, R\} \quad (9.2.5)$$

El filtrado Kalman es utilizado para predecir la próxima posición $\hat{\mathbf{x}}_h$ y la matriz de covarianza Λ_h de cada track h . Recordemos que el clustering es obviado cuando \mathbf{b} corresponde a una PDW que ha sido asignada a un track previamente establecido por el separador por TOA. En ese caso \mathbf{b} retiene su track y no se realizan la asociación de datos ni el mantenimiento de track. El filtrado y predicción Kalman sin embargo se sigue realizando para sustentar una descripción coherente de todos los emisores activos del medio.

Mantenimiento de tracks.

Una vez asociado con el patrón \mathbf{b} , el track H atraviesa dos pruebas. En la primera, la semejanza $s_h(\mathbf{b})$ se compara contra un umbral δ_c que regula la creación de nuevos tracks, $\delta_c \in [0, 1]$. Si $s_h(\mathbf{b}) \geq \delta_c$ se pasa la prueba. En la segunda prueba se computa el promedio acumulativo de los valores de semejanza S_H :

$$S_H = \frac{\sum S_H(\mathbf{b})}{Q_H} \quad (9.2.6)$$

Donde Q_H es el número de patrones a los cuales se les asignó el track H . S_H es comparado contra otro umbral δ_d que regula la la calidad global de los tracks existentes, $\delta_d \in [\delta_c, 1]$. Si $S_H \geq \delta_d$ se pasa la prueba. Si ambas pruebas pasan, el track H es asignado a \mathbf{b} .

Si cualquiera de las dos pruebas falla, un nuevo track es iniciado para el patrón \mathbf{b} . Cuando un nuevo track H es iniciado, $s_h(\mathbf{b}) = 1$, $\hat{\mathbf{x}}_h$ es igualado a \mathbf{b} y Λ_h es igualado a $\sigma^2 I_M$, donde I_M es la matriz identidad, y $\sigma = (\sigma_1, \sigma_2, \dots, \sigma_M)$ representa la resolución de la medición de los

parámetros espaciales. Además, si la segunda prueba falla (es decir $S_H < \delta_d$), el track H previamente establecido es eliminado.

Después de la asignación de \mathbf{b} a un track existente, o recientemente iniciado, cualquier otro track que no haya sido asignado a un patrón de entrada, por un período de tiempo mayor a un parámetro $\tau > 0$, es eliminado. Es decir que un track es eliminado si:

$$\text{TOA}(\mathbf{b}) - \text{TOA}_h > \tau \quad (9.2.7)$$

Donde TOA_h es el tiempo en el cual el track h fue asignado por última vez a una entrada. Borrar tracks libera recursos y reduce las probabilidades de futuras asignaciones erróneas. El número de track H es la salida del proceso de mantenimiento de tracks.

Un track de alta calidad es aquel al cual se le asignaron un gran número de pulsos transmitidos por el mismo emisor. Para asegurar tracks de alta calidad, nuevos tracks se inician rápidamente estableciendo δ_c cerca de 1, a la vez que los tracks de baja calidad son eliminados más lentamente (a medida que S_H declina progresivamente). Esto reduce la ambigüedad durante la asignación de tracks, pero puede derivar en la iniciación de un gran número de tracks, y en predicciones que se basan en la acumulación de secuencias cortas de pulsos.

Filtrado y predicción Kalman.

El filtrado y predicción se implementa con un banco de filtros Kalman estándar, uno por track. Cada track h es asociado con un filtro Kalman, y representado por una distribución Gaussiana unimodal. Después de la asignación del track H a \mathbf{b} , el filtro de H es empleado para predecir la próxima posición y la matriz de covarianza.

Acumulación secuencial de la evidencia

La acumulación secuencial de la evidencia explota la información espacial, combinando las respuestas del proceso de clustering con la clasificación de la red neuronal. En síntesis, las respuestas del clasificador son acumuladas de acuerdo al track, obteniéndose así predicciones desde múltiples vistas de un emisor.

Fusión de la información específica y espacial

Como ya fue mencionado, el proceso de clustering produce un número de track $h = H$ para cada patrón \mathbf{b} de la cadena de información espacial. El número de track indica el emisor específico asignado a \mathbf{b} .

La acumulación secuencial de evidencia es implementada por medio de campos idénticos de acumulación de evidencia $F_1^e, F_2^e, \dots, F_R^e$, donde cada campo F_h^e está conectado a un track h , y replica el campo de salida de la red neuronal, es decir que contiene L nodos, uno por cada tipo de radar. Los nodos de salida del clasificador están conectados a sus respectivos nodos en todos los campos $F_h^e, h = 1, 2, \dots, R$. Cada campo F_h^e incorpora una memoria de corto plazo capaz de acumular sus patrones de entrada. La memoria de F_h^e es caracterizada por un patrón de acumulación $\mathbf{T}_h^e = (T_{h1}^e, T_{h2}^e, \dots, T_{hL}^e)$.

Tras la inicialización de un track h , \mathbf{T}_h^e se iguala a $\mathbf{0}$. Cuando el track $h = H$ se asigna a un patrón \mathbf{b} , F_H^e se activa. El patrón de actividad \mathbf{y}^{ab} de salida del clasificador se acumula en F_H^e de acuerdo a:

$$(\mathbf{T}_H^e)' = \mathbf{T}_H^e + \mathbf{y}^{ab} \quad (9.2.8)$$

La acumulación de patrones de actividad en F_h^e continúa hasta que el track h es eliminado.

Para una PDW dada de entrada, el patrón de actividad \mathbf{y}^e de salida del módulo de acumulación de evidencia es igual a \mathbf{T}_H^e . El tipo de radar se predice como:

$$K^e = \operatorname{argmax}_k \{T_{\mathbf{1}}(Hk^{\mathbf{1}}\mathbf{s})^{\mathbf{1}}\mathbf{s} : k^{\mathbf{1}}\mathbf{s} = 1, 2, \dots, L\} \quad (9.2.9)$$

Además de la predicción discreta, los campos de acumulación de evidencia pueden ser usados para alimentar una tabla de emisores, en el separador de señal de la figura 9.2.1. Los campos también pueden describir múltiples tipos de radar que comparten las mismas características espaciales (misma posición geográfica), lo cual ayuda a vincular los emisores con las plataformas que los transportan.

Predicción desde múltiples vistas.

La acumulación secuencial de evidencia mejora la tasa de clasificación global del sistema de reconocimiento, debido a que la predicción acumulada K^e es tolerante a los errores cometidos por la red neuronal (predicción K). El concepto de predecir clases desde múltiples “vistas” de un emisor, que son acumuladas en el tiempo, ha sido exitosamente desarrollado en varias

arquitecturas neuronales (Baloch, A. A., & Waxman, A. M., 1991). La efectividad de la acumulación de evidencia depende de la calidad de los tracks computados.

10. FASE 5: EVALUACIÓN

10.1. EVALUACIÓN DE RESULTADOS

Simulaciones comparativas.

Fuzzy ARTMAP y otras dos arquitecturas ARTMAP, ARTMAP-IC y ARTMAP con MT-, fueron comparadas mediante simulaciones por computadora. También se incluyeron los clasificadores kNN y RBF para referencia paramétrica y no paramétrica respectivamente. Previo a cada simulación, los datos de los pulsos radar fueron particionados en dos subconjuntos de entrenamiento y prueba. El 50% de la información de cada tipo de radar fue seleccionado al azar para formar el subconjunto de entrenamiento. Luego, los vectores de entrenamiento \mathbf{a} , junto con la etiqueta del tipo de radar \mathbf{t} , fueron presentados repetidamente hasta la convergencia de la red. El mismo orden aleatorio fue usado en todas las presentaciones. La convergencia se alcanzaba cuando la suma cuadrática del cambio fraccional del vector de pesos \mathbf{W} era menor que 0.001, para dos ciclos sucesivos. Un ciclo se define como la presentación del subconjunto de entrenamiento al clasificador, por orden de TOA. El clasificador RBF usado en esta comparación selecciona subconjuntos de patrones de entrenamiento, uno por uno para codificar capas ocultas (Chen, S., Cowan, C. F. N., & Grant, P. M., 1991). En este caso la convergencia se alcanzaba cuando la suma cuadrática de los errores entre la salida real y la deseada caía por debajo de 0.01. Después de la convergencia, el subconjunto de prueba era presentado al clasificador ya entrenado, para probar la predicción.

La performance de cada clasificador fue evaluada en términos de cantidad de recursos consumidos y precisión predictiva. La cantidad de recursos asignados durante el entrenamiento se mide de 3 maneras. La *compresión* se refiere a la relación promedio de patrones de entrenamiento a nodos comprometidos en la capa F_2 . La *memoria* es el número de registros normalizados necesarios para almacenar el conjunto de vectores de pesos, siendo un registro normalizado un conjunto de bits cuyo número alcanza para almacenar los valores

reales del clasificador, como a_i , w_{ji} , ρ , etc. *Tiempo de convergencia* es el número de ciclos requeridos para que el clasificador converja. La precisión predictiva sobre el subconjunto de prueba se midió usando la *tasa de clasificación*, o sea la relación de patrones correctamente clasificados sobre el total de patrones de prueba.

La tabla 10.1.1 contiene el promedio de 20 simulaciones sobre la red fuzzy ARTMAP. Los parámetros de la red fueron elegidos por prueba y error para lograr la mejor tasa de clasificación, con la menor memoria y tiempo de convergencia del entrenamiento. Los resultados indican que la red fuzzy ARTMAP logró consistentemente una buena tasa de clasificación promedio, comparable con las obtenidas por los clasificadores kNN y RBF. Las arquitecturas ARTMAP alcanzan la misma tasa de clasificación con mayor compresión (menos memoria física para almacenar los vectores) y menos ciclos de entrenamiento para la convergencia.

Clasificador	Criterio de evaluación			
	Precisión	Recursos		
	Tasa de clasificación	Compresión	Memoria	T. de convergencia
k-Nearest-Neighbor ($k=1$, $d_{\text{Euclídea}}$)	99,53%	1	80340	N/A
RBF* (Spread del kernel = 0.05)	99,57%	4.2	6370	2125
ARTMAP-IC ($\varepsilon=10^{-4}$, $\alpha=.001$, $\beta=1$, $\bar{p}=0$)	83,54%	217	741	3.8
Fuzzy ARTMAP* ($\varepsilon=10^{-4}$, $\alpha=.001$, $\beta=1$, $\bar{p}=0$)	99,45%	220	733	Detenida en 3.6
Fuzzy ARTMAP con MT- ($\varepsilon=10^{-4}$, $\alpha=.001$, $\beta=1$, $\bar{p}=0$)	99,45%	216	748	3.8

Tabla 10.1.1. Resultados de la comparación. El símbolo * indica que el clasificador no alcanzaba la convergencia.

10.2. PROCESO DE REVISIÓN

A continuación se tratan los inconvenientes encontrados en las simulaciones, que son objeto de revisión, con el fin de mejorar la performance general.

Convergencia y seguimiento negativo de la semejanza

Un problema de convergencia ocurre con el algoritmo fuzzy ARTMAP descrito, cuando el conjunto de entrenamiento contiene patrones idénticos que pertenecen a clases diferentes. En nuestro caso esto se da cuando existen pulsos de radar en la misma unidad de resolución, que pertenecen a distintos tipos de radares. El problema se agrava más debido a que la red ARTMAP tiende a segmentar las partes superpuestas de las clases, en varios prototipos pequeños, a veces de tamaño unitario. La consecuencia es una proliferación de prototipos idénticos para ciertos patrones de entrenamiento.

Para comprender mejor el fenómeno, consideremos el siguiente ejemplo. Supongamos que en el primer ciclo de entrenamiento la red aprendió dos prototipos, completamente superpuestos y de tamaño mínimo, $\mathbf{w}_{A,1}$ (vinculado a la clase A) y $\mathbf{w}_{B,1}$ (vinculado a la clase B), para dos patrones de pulsos idénticos, \mathbf{a}_1 y \mathbf{a}_2 . En el ciclo siguiente, al presentar \mathbf{a}_2 a la red, $\mathbf{w}_{A,1}$ es seleccionado inicialmente, dado que $T_{A,1} = T_{B,1}$ y $\mathbf{w}_{A,1}$ fue creado antes que $\mathbf{w}_{B,1}$ (el índice A.1 es menor que B.1). Como $\mathbf{w}_{A,1}$ no está vinculado a la clase B, la discrepancia aumenta el

parámetro de vigilancia ρ a $(|\mathbf{A}_2 \wedge \mathbf{w}_{A,1}| / M) + \epsilon$, donde $|\mathbf{A}_2 \wedge \mathbf{w}_{A,1}| = |\mathbf{A}_2 \wedge \mathbf{w}_{B,1}|$.

Como resultado $\mathbf{w}_{B,1}$ ya no puede pasar la prueba de vigilancia para resultar seleccionado para \mathbf{a}_2 , y la red crea otro prototipo de tamaño mínimo $\mathbf{w}_{B,2} = \mathbf{w}_{B,1}$. El mismo fenómeno se repite de ciclo en ciclo, produciendo cada vez más prototipos idénticos $\mathbf{w}_{B,n} = \mathbf{w}_{B,1}$ para $n = 3, 4, \dots, \infty$.

Este efecto fue observado en los ensayos de entrenamiento de la red, obligando a terminar manualmente el algoritmo por: (1) detectando de ciclo en ciclo la creación repetida de prototipos idénticos para el mismo patrón de entrada, (2) podando los prototipos no únicos, y (3) definiendo el tiempo de convergencia como el número de ciclos que no llega a producir prototipos duplicados.

Una variante de la arquitectura, denominada ARTMAP-IC, convergía por sí misma con los datos de los radares. La característica de ARTMAP-IC que evita el problema de convergencia es la denominada *seguimiento negativo de la semejanza*, denotado como MT-, que consiste en usar valores negativos de ϵ (Carpenter, G. A., & Markuzon, N., 1998). En el ejemplo anterior,

la discrepancia aumenta ρ pero $w_{B,1}$ todavía pasa la prueba de vigilancia. Esto permite el aprendizaje de prototipos superpuestos, no únicos, para patrones de entrenamiento que pertenecen a diferentes clases. Fuzzy ARTMAP con MT- tiene el mismo orden de error que la versión sin MT- y logra evitar el problema de la convergencia.

Clasificación de datos incompletos

Un clasificador aplicado a ESM puede quedar expuesto a información incompleta, ya sea en el entrenamiento o en operación, por alguna de las siguientes causas:

Número limitado de casos de entrenamiento. Recolectar y analizar información ESM de campo para entrenar una red neuronal, a veces resulta una tarea muy costosa. Si el número de casos de entrenamiento es insuficiente, el clasificador no logrará una buena generalización durante la operación. Por consiguiente resulta de interés conocer como se degrada la performance del clasificador cuando se reduce la cantidad de datos de entrenamiento. En general, la red fuzzy ARTMAP logra altos niveles de precisión entrenándose con muy pocos pulsos por cada tipo de radar (Granger, E., Rubin, M. A., Grossberg, S., & Lavoie, P., 2000).

Componentes faltantes en los patrones de entrada. La información en los diferentes componentes de las PDW proviene de fuentes diversas. La ausencia de componentes en el procesamiento ESM surge de las limitaciones de los sensores y/o demoras en la extracción de parámetros (por ej. PRI). Esto implica que el clasificador se encontrará con patrones de entrada parciales. Más adelante se presenta una estrategia que permite a la red fuzzy ARTMAP procesar exitosamente estos patrones parciales.

Etiquetas de clase faltantes durante el entrenamiento. La tarea de analizar información de radar recolectada en campo puede ser muy difícil, debido a la complejidad y falta de control sobre el entorno. Se requiere mucha experiencia para la separación manual y etiquetado de los trenes de pulsos transmitidos por varios emisores. Este problema trae a consideración la pregunta de si el clasificador se beneficiaría con un entrenamiento donde haya etiquetas de clase faltantes. Este tipo de entrenamiento se denomina “aprendizaje semi-supervisado” o “clustering parcialmente supervisado”.

Para mensurar el efecto sobre la performance, de un entrenamiento usando datos sin etiqueta de clase, se entrenó la red en dos fases. Durante la primera fase, consistente en aprendizaje supervisado, la red fue entrenada en forma normal hasta lograr la convergencia, con una cantidad fija de datos que incluían etiqueta de clase de radar. Durante la segunda fase, consistente en aprendizaje no supervisado, se le presentó a la red un porcentaje variable de datos no etiquetados, de cada tipo de radar, hasta que los pesos \mathbf{W} convergían otra vez. Sin predicción de clase (es decir sin el paso 4 del algoritmo), la red asociaba cada pulso de entrenamiento sin etiqueta con un nodo de categoría en F_2 ya existente, y ajustaba los correspondientes vectores en aprendizaje lento ($0 < \beta < 1$). En todas las simulaciones con información radar nunca se obtuvieron mejores resultados, que los que se logran simplemente descartando los datos sin etiqueta. Esta aproximación es más efectiva cuando los datos de los distintos emisores son separables y bien agrupables, que no es el caso de ESM.

Clases faltantes durante el entrenamiento. Durante la operación pueden encontrarse tipos nuevos de radar, no representados en el conjunto de entrenamiento. Cuando el clasificador recibe un patrón transmitido por un nuevo tipo de radar, sería deseable que lo marque como desconocido, en lugar de hacer una predicción vacía de sentido acerca de la clase. Esto puede ser implementado mediante la *discriminación de familiaridad* (Carpenter, G. A., Rubin, M. A., & Streilein, W. W., 1997a). La importancia en ESM de la discriminación de familiaridad es evidente, dado que un mismo emisor puede exhibir distintos modos de operación en cualquier momento. La capacidad para aprender clases desconocidas es sumamente importante. La tarea de proveer información de entrenamiento a una red neuronal, requiere mucho tiempo del experto en ESM, por lo que cabe esperar que tan solo una pequeña fracción, de la gran cantidad de información existente, sea utilizada para entrenamiento. Unas modificaciones presentadas más adelante permiten a la red fuzzy ARTMAP moderar la degradación producida por la falta de etiquetas de clase, así como de beneficiarse con el aprendizaje de información oculta en datos sin etiqueta, de clases todavía desconocidas.

Estrategia del vector indicador para componentes faltantes.

Una estrategia para manejar componentes faltantes en los patrones de entrada consiste en el uso de *vectores indicadores* (Granger, E., Rubin, M. A., Grossberg, S., & Lavoie, P., 2000). Un vector indicador $\delta = (\delta_1, \delta_2, \dots, \delta_M)$ informa a la red sobre la presencia o ausencia de cada

componente del patrón de entrada: $\delta_i = 1$ si el componente i está presente, y $\delta_i = 0$ si está ausente. A diferencia de las estrategias que consisten en reemplazar simplemente por 0 o por 1, la estrategia del vector indicador modifica los vectores de peso, así como el patrón de entrada, en respuesta a componentes faltantes. Esta aproximación evita un sesgo en el orden de selección de prototipos. Los ajustes al algoritmo fuzzy ARTMAP impuestos por la estrategia del vector indicador, se resumen en la tabla 10.2.1.

Paso del algoritmo	Fuzzy ARTMAP	Fuzzy ARTMAP con vector indicador
Selección de prototipo: - Función de selección - Prueba de vigilancia	$T_j(A) = \frac{ w_{jAA} }{\alpha + w_j }$ $ w_{jAA} \geq \rho A $	$T_j(A, \delta) = \frac{ w_{jAA\delta} }{\alpha + w_{jA\delta} }$ $ w_{jAA\delta} \geq \rho A \wedge \delta $
Aprendizaje: - Actualización de prototipos	$w'_j = \beta(A \wedge w_j) + (1 - \beta)w_j$	$w'_j = \beta((A \vee \delta^c) \wedge w_j) + (1 - \beta)w_j$

Tabla 10.2.1. Modificaciones al algoritmo fuzzy ARTMAP para implementar la estrategia del vector indicador.

Para verificar la efectividad de esta estrategia, se entrenó una red fuzzy ARTMAP con MT- y vector indicador, usando un porcentaje del 0.5% del subconjunto de entrenamiento, tomado al azar. El resto de los datos se usaron para prueba. Para cada clase en el subconjunto de entrenamiento, un porcentaje variable entre el 0% y el 70% de los componentes fue removido de los patrones y declarado como “faltante”. La tasa de clasificación y la compresión lograda por la estrategia del vector indicador, junto con las correspondientes al reemplazo por 1 y por 0, se muestran en la figura 10.2.1.

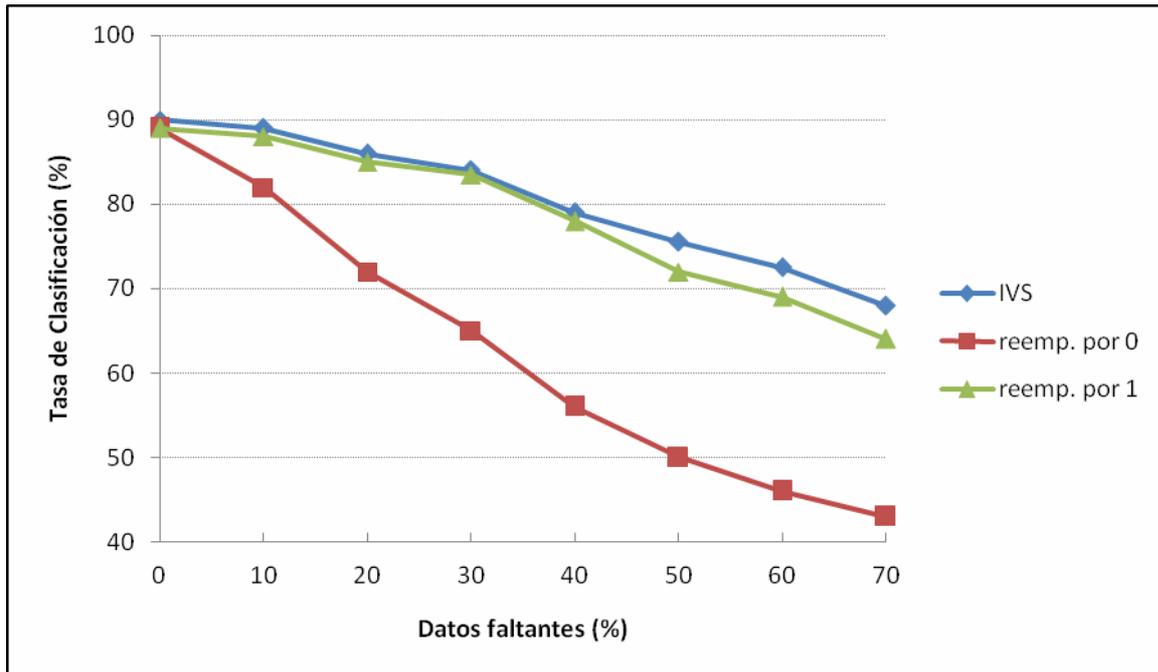


Figura 10.2.1. (a) Precisión con componentes faltantes, sólo durante la fase de prueba.

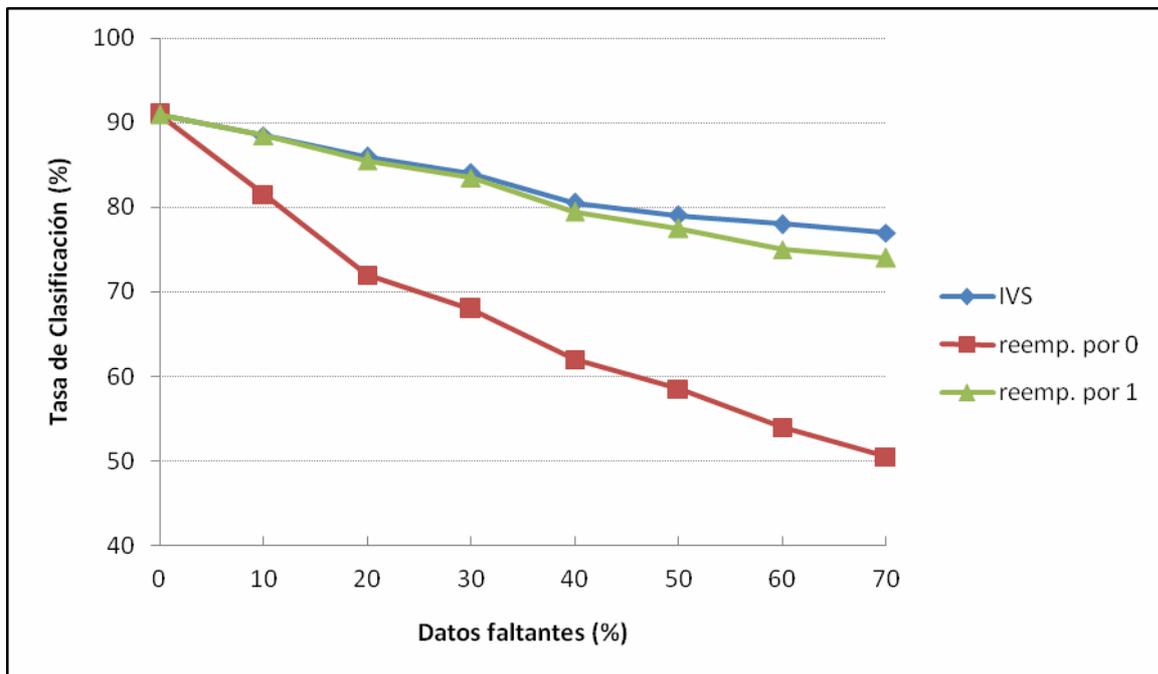


Figura 10.2.1. (b) Precisión con componentes faltantes, sólo durante la fase de entrenamiento.

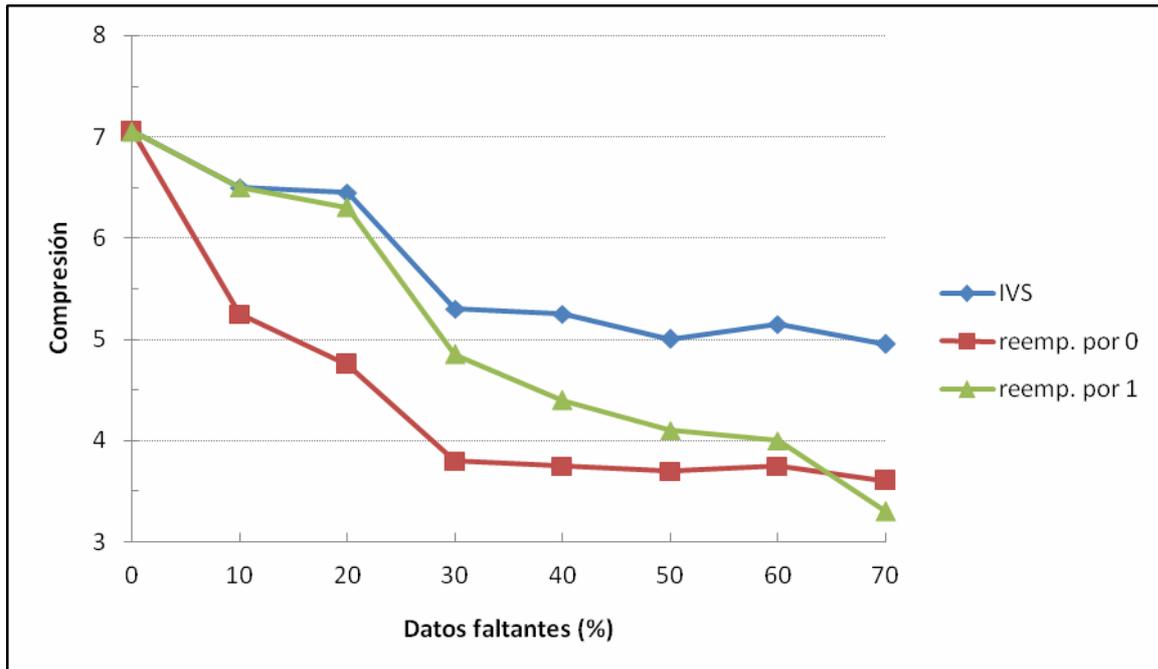


Figura 10.2.1. (c) Compresión para el caso (b).

Discriminación de familiaridad.

La extensión de la red fuzzy ARTMAP que permite la detección de patrones de clases desconocidas se denomina ARTMAP-FD. Se ha demostrado que el algoritmo ARTMAP-FD, efectivamente realiza discriminación de familiaridad sobre los datos de pulsos radar (Granger, E., Grossberg, S., Rubin, M. A., & Streilein, W. W., 1999). Además de usar la tasa de clasificación, la performance de un clasificador también se puede medir por la *tasa de acierto* H (fracción de patrones de prueba de clases conocidas, correctamente clasificados como pertenecientes a una de las clases conocidas) y la *tasa de falsa alarma* F (fracción de patrones de prueba de clases desconocidas incorrectamente clasificados como conocidos).

Algoritmo ARTMAP-FD.

Con codificación complementaria y aprendizaje rápido ($\beta = 1$), el vector prototipo M -dimensional $\mathbf{w}_j = (w_{j1}, w_{j2}, \dots, w_{jM})$, asociado con el nodo de categoría j de la capa F_2 de una red fuzzy ARTMAP, define un hiper rectángulo en el espacio m -dimensional de los componentes de los patrones de entrada, con bordes paralelos a los ejes de coordenadas. Este hiper rectángulo contiene el mayor valor y el menor valor de los componentes de los patrones de entrenamiento, asignados a la categoría j . Un patrón asociado con un nodo de F_2 durante la

prueba se dice “perfectamente conocido” si cae dentro del hiper rectángulo, y “no perfectamente conocido” en el caso que caiga afuera. Esta noción se puede cuantificar por *la medida de familiaridad*:

$$\varphi(\mathbf{a}) = \frac{T_j(\mathbf{a})}{T_j^{\max}} = \frac{|\mathbf{a} \wedge \mathbf{w}_j|}{|\mathbf{w}_j|} \quad (10.2.1)$$

Donde $T_j^{\max} = |\mathbf{w}_j| / (\alpha + |\mathbf{w}_j|)$. El máximo valor de $T_j = T_j^{\max}$ para una entrada \mathbf{a} se obtiene cuando ésta cae dentro del hiper rectángulo asociado con el nodo J , en ese caso $|\mathbf{a} \wedge \mathbf{w}_j| = |\mathbf{w}_j|$. En otras palabras, una entrada \mathbf{a} que es asignada a una categoría J durante la fase de prueba, tiene máximo valor de familiaridad $\varphi(\mathbf{a}) = 1$, si y solo si \mathbf{a} cae dentro del hiper rectángulo R_J ,

El algoritmo ARTMAP-FD es idéntico al algoritmo fuzzy ARTMAP durante el entrenamiento. Durante la prueba se computa $\varphi(\mathbf{a})$ para cada patrón de entrada \mathbf{a} , después que la red seleccionó el nodo J , y tentativamente predijo la clase $K = k(J)$. La entrada \mathbf{a} se declara perteneciente a una clase conocida si el valor de la medida de familiaridad, $\varphi(\mathbf{a})$, es mayor que un umbral de decisión γ . En este caso el algoritmo ARTMAP-FD emite la predicción de clase K para \mathbf{a} . Si por el contrario $\varphi(\mathbf{a}) \leq \gamma$, la entrada \mathbf{a} se marca como perteneciente a una clase desconocida, y ARTMAP-FD no hace ninguna predicción.

Selección del umbral de familiaridad.

La elección de un umbral particular de familiaridad $\gamma = \Gamma$ para usar en operación, depende del costo relativo de los errores debidos a pérdidas (patrones pertenecientes a clases conocidas que la red marca como desconocidas) y a falsas alarmas. Dado que la discriminación de familiaridad implica ubicar una entrada en uno de dos conjuntos, conocida o desconocida, puede usarse el formalismo Receiver Operating Characteristic (ROC) (Helstrom, 1995) para evaluar la efectividad del algoritmo ARTMAP-FD. Optimizar Γ corresponde a elegir un punto en la curva ROC cercano al vértice superior izquierdo del cuadrado unitario. Esto maximiza la correcta selección de patrones conocidos (H), a la vez que minimiza la incorrecta selección de patrones desconocidos (F). De los dos métodos descritos en (Carpenter, G. A., Rubin, M. A., & Streilein, W. W., 1997b) para establecer el umbral de familiaridad Γ , se ha elegido el método de “determinación online del umbral”.

Durante el primer ciclo de entrenamiento ARTMAP-FD, cada vez que un nodo de categoría J gana la competencia para un patrón \mathbf{a} , el aprendizaje rápido expande R_j lo justo para incluir a \mathbf{a} . Antes que el aprendizaje tenga lugar se computa el valor de $\phi(\mathbf{A})$. La medida en que $\phi(\mathbf{A})$ es inferior a 1 refleja la distancia desde el patrón de entrenamiento a R_j . Un patrón familiar es un patrón de entrenamiento exitosamente codificado por un nodo de categoría (sin evento reset). La medida de familiaridad $\phi(\mathbf{A})$ contribuye a la generación de una curva de tasa de acierto de entrenamiento, donde $H(\gamma)$ iguala la fracción de entradas de entrenamiento con $\phi(\mathbf{A}) > \gamma$. En contraposición, un evento reset durante el primer ciclo de entrenamiento refleja que un nodo de categoría J que predice la clase K , ganó la competencia para un patrón que realmente pertenece a una clase diferente k , $k \neq K$. El conjunto de valores de $\phi(\mathbf{A})$ correspondiente a estos eventos son utilizados para generar una curva de tasa de falsa alarma de entrenamiento, donde $F(\gamma)$ iguala a la fracción de entradas que produjeron el evento reset, con $\phi(\mathbf{A}) > \gamma$.

Al finalizar el entrenamiento, el umbral de familiaridad queda dado por $\Gamma = \operatorname{argmax}_{\gamma} \{H(\gamma) - F(\gamma)\}$. La precisión mejora por el uso de un conjunto reducido de valores de $\phi(\mathbf{A})$, en el proceso de construcción de las curvas ROC; concretamente los patrones de entrenamiento que caen dentro del hiper rectángulo ($\phi(\mathbf{A})=1$) no son usados porque estos ejemplares tienden a distorsionar la curva de falsa alarma. La primera respuesta incorrecta a una entrada de entrenamiento es la mejor predicción de la respuesta que tendrá la red a una entrada de prueba desconocida, ya que la búsqueda secuencial no estará disponible durante la fase de prueba. Por último, dando mayor peso a los eventos que ocurren con el proceso de entrenamiento ya más avanzado, se obtiene una mejora en la precisión. Esto se consigue computando las curvas $H(\gamma)$ y $F(\gamma)$, y el umbral Γ , solo después que el sistema ha creado un número de nodos categóricos igual a L (número de clases en el conjunto de entrenamiento). Es de notar que este método de determinación del umbral requiere el almacenamiento de todos los patrones de entrenamiento, para obtener $H(\gamma)$ y $F(\gamma)$ y predecir Γ . En aras de la eficiencia computacional, sería posible aproximar $H(\gamma)$ y $F(\gamma)$ a partir de un conjunto reducido de valores de $\phi(\mathbf{A})$, que serían actualizados incrementalmente, a medida que se va obteniendo nueva información.

Aprendizaje de clases desconocidas.

Mediante Aprendizaje de Clases Desconocidas (Learning of Unfamiliar Classes LUC), un clasificador continúa ajustando sus pesos, durante la fase de prueba, a través de un aprendizaje semi supervisado. El criterio para discriminación de familiaridad también es ajustado online. Cuando un patrón de prueba es marcado como desconocido, el clasificador define una nueva clase. Los patrones subsiguientes pueden ser declarados como conocidos y clasificados como pertenecientes a una de las clases encontradas durante el entrenamiento, o a la recientemente creada; o pueden ser declarados como desconocidos, en cuyo caso se define otra clase nueva. La tasa de acierto (H^*) de un clasificador con LUC puede ser definida como la fracción de patrones de prueba, que son correctamente reconocidos como pertenecientes a una de las clases usadas en el entrenamiento. La tasa de falsa alarma (F^*) de un clasificador con LUC es la fracción de patrones de prueba de clases desconocidas (no encontradas durante la fase de entrenamiento), no marcados como desconocidos o no asignados a una clase nueva, creada durante la fase de prueba.

El algoritmo fuzzy ARTMAP fue modificado de la siguiente manera para incorporar la capacidad LUC. Primero, a los efectos de focalizar los efectos de LUC (en contraposición al aprendizaje con etiquetas de clases faltantes), los pesos asociados con los nodos de F_2 , que fueron asignados durante la fase de entrenamiento, se mantienen constantes durante la fase de prueba. Solamente a los pesos de los nuevos nodos creados durante la prueba, se les permite cambiar con aprendizaje lento ($0 < \beta < 1$).

Además, para prevenir la generación de un número excesivo de nodos nuevos, a los patrones que fueron declarados desconocidos, se les da “una segunda oportunidad” de ser asociados con un nodo existente, antes de definir una nueva clase. Específicamente, un patrón \mathbf{a} declarado desconocido por la red, es sometido a una prueba de vigilancia en cada uno de los nodos nuevos. Si pasa la prueba para uno o más de estos nodos nuevos, se lo asocia con el nodo j_{new} que tenga la activación $T_{j_{new}}$ más alta. Si el patrón todavía no puede asociarse con ninguno de estos nodos nuevos, entonces se realiza una prueba de *coactivación*. Si el nivel de activación T_j del nodo J no supera al nivel de activación $T_{j_{new}}$ de todos los nodos nuevos con un margen suficiente, es decir si $T_j - T_{j_{new}} < \epsilon_{co}$, entonces el patrón es asociado con el nodo j_{new} para el cual $T_j - T_{j_{new}}$ es mínimo. Si pasa cualquiera de estas dos pruebas, no puede tener lugar ningún ajuste de los pesos $\mathbf{w}_{j_{new}}$. Solamente si ninguna de estas opciones de asociación con nodos existentes tiene éxito, se define una clase nueva.

Cuando se define una clase nueva, un nuevo nodo categórico J_{new} es asignado para codificar la entrada ($\mathbf{w}_{J_{new}} \leftarrow \mathbf{A}$), y vinculado a un nuevo nodo de mapeo K_{new} de F^{ab} mediante $\mathbf{w}_{J_{new}}^{ab}$. Seguidamente, el aprendizaje lento semi supervisado ajusta los pesos de los nuevos nodos de F_2 , tras su asignación a patrones conocidos. Es de notar que las nuevas clases definidas son interpretadas de manera diferente: cada nuevo nodo de F_2 o F^{ab} representa un fragmento de la información de un emisor que pertenece a una clase de radar desconocida.

Por último, el algoritmo fuzzy ARTMAP-LUC extiende el método online para mejorar el umbral de familiaridad Γ . Si un patrón \mathbf{a} es declarado conocido, $\varphi(\mathbf{A})$ es agregado a los valores $\{ \varphi \}$ usados para generar la curva de tasa de acierto $H^*(\gamma)$; de lo contrario $\varphi(\mathbf{A})$ es agregado a los valores $\{ \varphi \}$ usados para generar la curva de tasa de falsa alarma $F^*(\gamma)$. El umbral $\Gamma^* = \operatorname{argmax}_{\gamma} \{ H^*(\gamma) - F^*(\gamma) \}$ es recalculado siguiendo cada asignación de los patrones de entrada. Para una ejecución más rápida, es posible ajustar Γ cada vez que un patrón se asigna a un nodo nuevo, es decir, cuando \mathbf{W} es modificado.

Simulaciones con discriminación de familiaridad y clases desconocidas.

En simulaciones por computadora, 13 de un total de 15 tipos de radar fueron declarados conocidos (presentes en las clases usadas en el entrenamiento). La selección de las clases conocidas fue realizada al azar, con la restricción que no se permitía un número insuficiente de patrones de una clase desconocida (menos de mil). El 50% de la información de cada una de las 13 clases, tomado al azar, fue presentado a la red durante la fase de entrenamiento. El umbral de familiaridad Γ fue determinado durante el entrenamiento, mediante el método online descrito. Los patrones remanentes de las 13 clases de entrenamiento, más todos los patrones de las 2 clases de radar marcadas como desconocidas formaron el conjunto de prueba.

Los resultados promediados de 20 simulaciones, obtenidos por el algoritmo fuzzy ARTMAP-FD puro y fuzzy ARTMAP-FD con LUC se muestran en la tabla 10.2.2. Los resultados muestran que fuzzy ARTMAP-FD tuvo una alta tasa de acierto (99,60%), pero apenas un rendimiento marginal en cuanto a evitar falsas alarmas: 14,33% de los patrones pertenecientes a clases desconocidas fueron erróneamente asignados a clases conocidas. Esto es una consecuencia de la superposición, la dispersión y la mezcla no homogénea de pulsos de diferentes tipos de radar. Definiendo nuevas clases y asignándolas a patrones desconocidos,

LUC reduce la tasa de falsa alarma a aproximadamente la mitad (7,46%), sin pérdida de la precisión.

En promedio fuzzy ARTMAP con FD y LUC requiere 125 registros adicionales para almacenar los vectores prototipos, y unos 21 nodos nuevos de F_2 , más los de F^{ab} , para representar los diferentes modos de las 2 clases de emisores desconocidos. A pesar de la creación de estos nodos adicionales, la precisión de la red sobre clases conocidas no resulta significativamente degradada.

Criterio de evaluación	Fuzzy ARTMAP con FD	Fuzzy ARTMAP con FD y LUC
Tasa de acierto	99,60%	99,63%
Tasa de falsa alarma	14,33%	7,46%
Tasa de clasificación	99,51%	99,49%
Memoria	806	931

Tabla 10.2.2. Simulaciones comparativas de fuzzy ARTMAP-FD con y sin LUC

Simulación con acumulación de evidencia.

Esta sección resume las simulaciones del sistema completo de reconocimiento de pulsos radar. Para la simulación se utilizó software de distribución libre, escrito en lenguaje Matlab, tanto para la implementación de la red neuronal como el clustering, la acumulación de evidencia y la integración de los mismos. La configuración de parámetros de clustering usada fue $\delta_c = 0,98$, $\delta_d = \delta_c + 0,01$, y $\tau = 10$ msec. La red neuronal fue fuzzy ARTMAP con las extensiones: seguimiento negativo de la semejanza (MT-), discriminación de familiaridad (FD), estrategia de vector indicador (IVS) y aprendizaje de categorías desconocidas (LUC). Los parámetros de vigilancia y coactivación usados para asociar patrones desconocidos con nodos ya existentes en LUC fueron $\rho = 0,8$ y $\varepsilon_{co} = 0,05$. La tasa de aprendizaje fue establecida en $\beta = 0,5$ para el ajuste semi supervisado de los pesos prototipos de los nuevos nodos.

Los patrones presentados al clasificador contenían 3 parámetros específicos de tipo, PRI, PW y RF, mientras que los presentados al módulo de clustering contenían 2 parámetros espaciales, DOA y PA. El sistema normalmente recibe del separador por TOA, el valor de PRI y el número de track al cual fue asignada la PDW. La separación por TOA es una tarea compleja debido a la agilidad en PRI (jitter, stagger) de los radares modernos. Para propósitos de simulación, se asumió que la separación por TOA sólo pudo realizarse en forma confiable

para casos de PRI constante. Aproximadamente 30.000 pulsos del conjunto de datos pertenecen a emisores con PRI constante, el resto (aproximadamente 22.000) pertenecen a emisores con PRI complejos.

Durante el entrenamiento, todos los patrones específicos de tipo tenían el componente PRI. Durante la fase de prueba, el componente PRI fue declarado faltante para los patrones pertenecientes a emisores de PRI complejo. Además, un 10% seleccionado al azar de los componentes específicos de tipo, de cada modo de emisor, también fue declarado faltante. Para manejar estos datos faltantes se utilizó la estrategia IVS.

Para emisores con PRI constante, el valor usado tanto en entrenamiento como en prueba fue la media, estimada usando un promedio móvil que tenía en cuenta los pulsos perdidos. Supongamos que el separador por TOA ha ordenado correctamente los n_k pulsos pertenecientes al emisor k , y ha computado los valores $PPI_k(i)$ y $q_k(i)$ para $i = 2, 3, \dots, n_k$, donde $q_k(i)$ es el múltiplo del valor nominal PRI_k más próximo al valor $PPI_k(i)$, es decir $q_k(i) = \operatorname{argmin}_q \{q : |q \cdot PRI_k - PPI_k(i)| : q = 1, 2, \dots\}$. El promedio móvil es:

$$\overline{PRI}_k(i) = \frac{1}{\Delta} \sum_{m=i-\Delta+1}^i \frac{PPI_k(m)}{q_k(m)} \quad (10.2.2)$$

Donde Δ es el número de pulsos en la ventana de promedio móvil. El hecho de observar el intervalo entre pulsos dentro de una ventana definida por los últimos 5 PRI consecutivos es consistente con el valor del parámetro de clustering, $\tau = 10\text{mseg.}$, que corresponde a 5 veces el máximo valor de PRI esperado. Si el tiempo transcurrido entre un pulso y el anterior va más allá de esta ventana, se considera que el pulso pertenece a la siguiente ráfaga de pulsos del emisor.

Para tener en cuenta la evolución cronológica del entorno, el conjunto de entrenamiento fue creado seleccionando el primer 0,5% de la información de cada emisor, por orden de TOA. Luego, los datos para el entrenamiento fueron tomados solamente de los emisores correspondientes a 13 de los 15 tipos de radares tomados al azar, y declarados como conocidos. Después del entrenamiento, toda la información remanente de las 13 clases conocidas (99,5% de cada emisor), más todos los patrones de las 2 clases desconocidas fueron presentados al sistema de reconocimiento, por orden de TOA. Para manejar las clases faltantes durante el entrenamiento fueron utilizadas las extensiones FD y LUC descriptas

anteriormente. Cuando se aplica la estrategia IVS, la medida de familiaridad de la ecuación (10.2.1) se transforma en:

$$\varphi(\mathbf{A}) = \frac{|A_{jAc}|}{|w_{jAc}|} \quad (10.2.3)$$

Cuando se utiliza fuzzy ARTMAP con FD solo, la acumulación de evidencia de las respuestas \mathbf{y}^{ab} , en los campos F_H^e ocurre solamente si la entrada \mathbf{a} es declarada conocida. Con FD y LUC, en cambio, la acumulación de evidencia ocurre siempre dado que se definen nuevas clases cuando se presentan patrones desconocidos. Para soportar la capacidad de acumular patrones de clases desconocidas, cada vez que se define una nueva clase, se inicializa un nuevo nodo en cada campo de acumulación de evidencia F_h^e , $h = 1, 2, \dots, R$, así como en las capas F_2 y F^{ab} .

La performance del sistema en función de la cantidad de información usada para entrenamiento se resume en la figura 10.2.2. La cantidad de información es un porcentaje de los patrones seleccionado al azar, para cada tipo de emisor. Este porcentaje fue variado entre el 10% y el 100% del conjunto de entrenamiento (entre 0,05% y 0,5% del conjunto completo de datos). Los resultados obtenidos por fuzzy ARTMAP con MT- e IVS, y con el clasificador k NN se incluyen para comparación. Cuando faltan componentes, los patrones de prueba son clasificados con k NN sobre la base de los que están presentes.

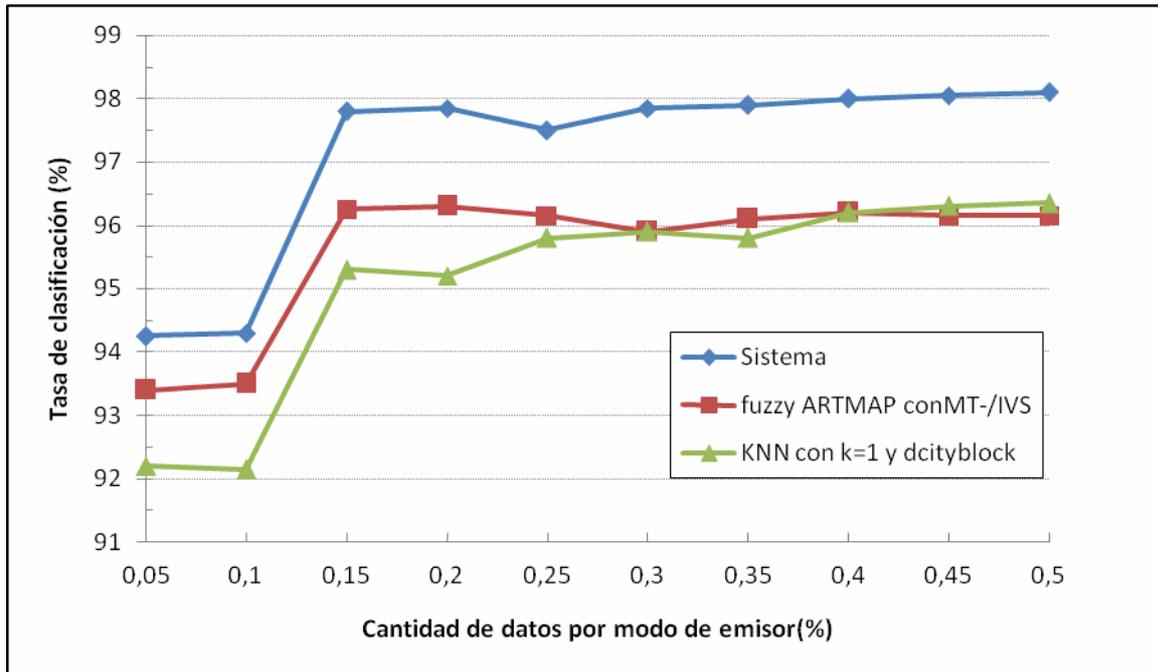


Figura 10.2.2a. Tasa de clasificación de patrones conocidos

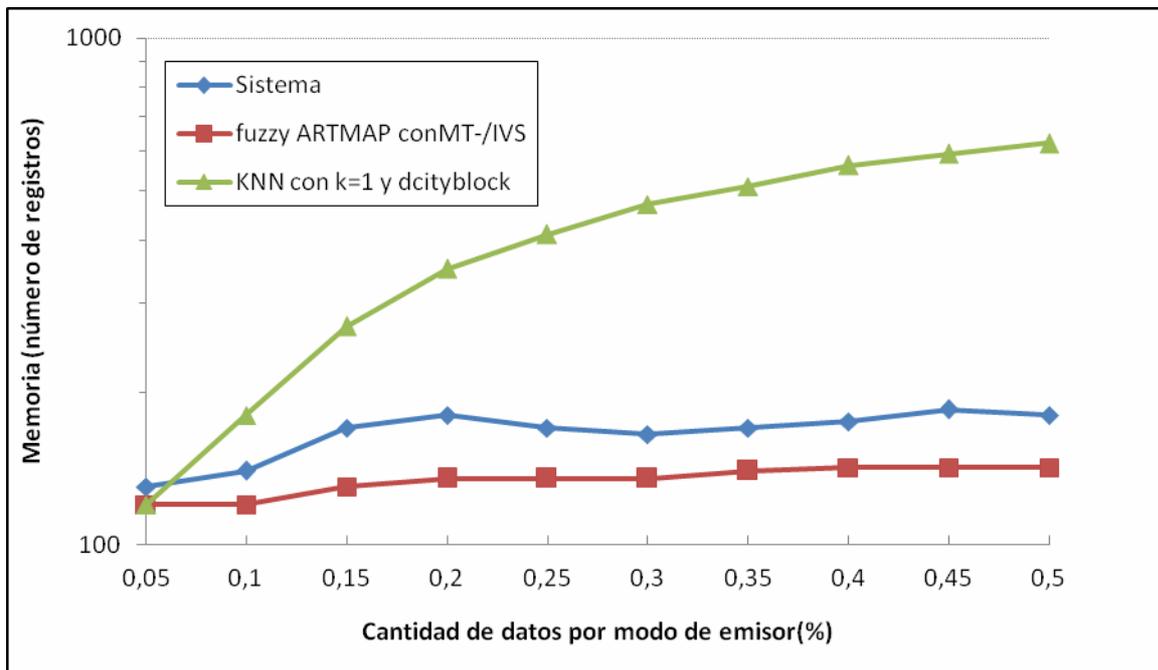


Figura 10.2.2b. Requerimiento de memoria durante el entrenamiento

La figura 10.2.2a indica que la fusión de la información específica y espacial mejora la tasa de clasificación de fuzzy ARTMAP con MT- e IVS, para patrones de clase conocida, en aproximadamente un 2%. El sistema logra una tasa de clasificación de casi 98%, con un

conjunto de entrenamiento de tan solo el 0,15% del conjunto completo, o sea unos 80 pulsos. Este nivel de performance se obtiene junto con la capacidad de detectar y aprender patrones de clases desconocidas. Cuando se lo entrena con solo el 0,5% de la información de clases conocidas, el sistema alcanza una tasa de acierto promedio $H^* = 97\%$ y una tasa de falsa alarma $F^* = 13\%$ del conjunto de datos de prueba.

La figura 10.2.2b ilustra la noción de que ejemplos de entrenamiento adicionales, más allá de un cierto punto, resultan redundantes (la memoria utilizada crece a medida que aumenta el número de patrones de entrenamiento). La figura también muestra el costo de memoria debido a la definición de clases nuevas durante la fase de prueba. Cuando se lo entrena con el 0,5% de la información de clases conocidas, el sistema crea en promedio 5 nuevos nodos en F_2 , F_{ab} y todas las capas F_h^e .

10.3. Conclusiones

Se ha propuesto una arquitectura de ESM alternativa para el reconocimiento e identificación de emisiones de radar. Esta arquitectura combina un clasificador basado en una red neuronal, un algoritmo de clustering online y un módulo de acumulación de evidencia. Una vez entrenada con muestras tomadas de campo, la red neuronal clasifica y predice el tipo de radar de los pulsos interceptados, basándose en los parámetros específicos de tipo. A su vez, el algoritmo de clustering separa los pulsos de cada emisor, basándose en los parámetros espaciales. El módulo de acumulación de evidencia permite fusionar las respuestas del clasificador con las estimaciones del algoritmo de clustering, y de esta manera predecir la clase del emisor más probable. La implementación particular del sistema consiste en una variante de la red fuzzy ARTMAP para clasificación, y el método del vecino más próximo junto con un banco de filtros Kalman para clustering online.

Las simulaciones demostraron que la red fuzzy ARTMAP con seguimiento negativo de la semejanza (MT-), obtuvo consistentemente un alto nivel de precisión y compresión, aún con una cantidad de datos de entrenamiento muy limitada. Comparada con otras variantes ARTMAP, así como con los clasificadores de referencia RBF y kNN, esta implementación presenta una tasa de clasificación comparable, requiriendo la menor cantidad de recursos (menor tiempo de convergencia y menos memoria para almacenar los prototipos). La característica MT- le permite a fuzzy ARTMAP converger naturalmente, evitando el problema de la proliferación de categorías, que puede aparecer cuando patrones muy

parecidos o idénticos del conjunto de entrenamiento, pertenecen a clases distintas. Otra modificación a fuzzy ARTMAP con MT- fue introducida para manejar el caso de componentes faltantes en los patrones de entrada, y clases faltantes durante el entrenamiento. Se trata de la estrategia del vector indicador (IVS), que provee un medio efectivo para procesar patrones parciales de entrada, ya sea que los componentes estén ausentes en el conjunto de entrenamiento o en el de prueba. La discriminación de familiaridad (FD) le permite a la red detectar patrones que pertenecen a clases desconocidas durante el entrenamiento y la prueba, y habilita a que tenga lugar el aprendizaje de clases desconocidas (LUC), durante la prueba. Los resultados obtenidos soportan la aproximación original de integrar la información específica de tipo con la espacial, a través de la acumulación de evidencia, y son promisorios para abordar aplicaciones de sistemas ESM autónomos, que deban enfrentarse a datos de emisores complejos, incompletos y superpuestos.

10.4. Próximos pasos

Posibles acciones

El paso siguiente a la obtención de resultados satisfactorios en las simulaciones por computadoras, sería la implementación en hardware de la red fuzzy ARTMAP. En efecto, en determinadas bandas de radar la densidad electromagnética puede superar los 10^6 pulsos por segundo. Esta carga de información requiere una velocidad de respuesta que solo el procesamiento paralelo masivo puede alcanzar. El objetivo sería entonces desarrollar una arquitectura VLSI (Very Large Scale Integration) que implemente el algoritmo fuzzy ARTMAP.

Bibliografía

- Anderberg, M. R. (1973). *Cluster Analysis for Applications*. New York, NY: Academic Press.
- Baloch, A. A., & Waxman, A. M. (1991). Visual Learning, Adaptive Expectation, and Behavioral Conditioning of the Mobile Robot MAVIN. *Neural Networks*, 4, 271-302.
- Bar-Shalom, Y., & Li, R. A. (1993). *Estimation and Tracking: Principles, Techniques and Software*. Boston, MA: ARtech House.
- Blackman, S. S. (1986). *Multiple-Target Tracking with Radar Applications*. Norwood, MA: Artech House.
- Browne, J. P. R., & Thurbon, M. T. (1998). *Electronic Warfare*. London, UK: Brassey's.
- Carpenter, G. A., & Markuzon, N. (1998). ARTMAP-IC and Medical Diagnosis: Instance Counting and Inconsistent Cases. *Neural Networks*, 11 (2), 323-336.
- Carpenter, G. A., and Grossberg S. (1987). A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine. *Computer Vision, Graphics, and Image Processing*, 37, 54-115.
- Carpenter, G. A., Grossberg, S. (2002). *The Handbook of Brain Theory and Neural Networks*. (M. A. Arbib, Ed.) Cambridge, MA: MIT Press.
- Carpenter, G. A., Grossberg, S. (1987). ART 2: self-organization of stable category recognition codes for analog input patterns. *Applied Optics*, 26 (23), 4919-4930.
- Carpenter, G. A., Grossberg, S., & Reynolds, J. H. (1991). ARTMAP: Supervised Real Time Learning and Classification of Nonstationary Data by a Self-Organizing Neural Network. *Neural Networks*, 4, 565-588.
- Carpenter, G. A., Rubin, M. A., & Streilein, W. W. (1997a). ARTMAP-FD: Familiarity Discrimination Applied to Radar Target Recognition. *Proc. Int'l Conference on Neural Networks, III*, pp. 1459-1464.
- Carpenter, G. A., Rubin, M. A., & Streilein, W. W. (1997b). Threshold Determination for ARTMAP-FD Familiarity Discrimination. *Intelligent Systems Through Artificial Neural Networks*, 7, 23-28.
- Carpenter, G.A., Grossberg, S., Markuzon, N., Reynolds, J. H., & Rosen, D. B. (1992). Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps. *IEEE Transactions on Neural Networks*, 3 (5), 698-713.

- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). *CRISP-DM 1.0 Step-by-step data mining guide*. CRISP-DM Consortium.
- Chen, S., Cowan, C. F. N., & Grant, P. M. (1991). Orthogonal Least Square Learning Algorithm for Radial Basis Function Networks. *IEEE Transactions on Neural Networks*, 2 (2), 302-309.
- Davies, C. L., & Hollands, P. (1982). Automatic Processing for ESM. *Proceedings of IEE*, 129 (3), 164-171.
- Granger, E., Grossberg, S., Rubin, M. A., & Streilein, W. W. (1999). Familiarity Discrimination of Radar Pulses. (M. Press, Ed.) *Advances in Neural Information Processing Systems*, 11, 875-881.
- Granger, E., Rubin, M. A., Grossberg, S., & Lavoie, P. (2000). Classification of Incomplete Data Using the Fuzzy ARTMAP Neural Network. *Proc. Int'l Joint Conference on Neural Networks, IV*, pp. 35-40.
- Granger, E., Rubin, M. A., Grossberg, S., & Lavoie, P. (2000). *A What and Where Fusion Neural Network for Recognition and Tracking of Multiple Radar Emitters*. Technical Report CAS/CNS-TR-2000-029, Boston University, Boston, MA.
- Gray, R. M. (1984). Vector Quantization. *IEEE ASSP Magazine*, 1 (2), 4-29.
- Grossberg, S. (2000). *Adaptive Resonance Theory*. Technical Report CAS/CNS-2000-024, Boston University, Center for Adaptive Systems and Department of Cognitive and Neural Systems, Boston, MA.
- Helstrom, C. W. (1995). *Elements of Signal Detection and Estimation*. Englewood Cliffs, NJ: Prentice Hall.
- Skolnik, M. I. (1962). *Introduction to Radar Systems*. New York, NY: McGraw-Hill.
- Van Brunt, L. B. (1982). *Applied ECM*. Dunn Loring, VA: EW Engineering.
- Wiley, R. (1985). *Electronic Intelligence: The Interception of Radar Signals*. Dedham, MA: Artech House.
- Wiley, R. G. (1993). *Electronic Intelligence: The Analysis of Radar Signals* (2nd ed.). Norwood, MA: Artech House.
- Wilkinson, M. A., and Watson, M. A. (1985). Use of Metric Techniques in ESM Data Processing. *Proceedings IEE*, 132 (4), 229-232.