

Clasificación Automática de Modulaciones para Sistemas de Guerra Electrónica

**Estado del Arte de las
Tecnologías**

Cátedra Isdefe-UPM

Septiembre 2018 – Julio 2019

Madrid, julio de 2019

Índice

1. Introducción	1
2. Técnicas de clasificación automática de modulaciones	3
2.1. Algoritmos basados en características (<i>feature-based</i> , FB)	6
2.1.1. Extracción de <i>features</i> para AMC	6
2.1.2. Árboles de decisión	9
2.2. Algoritmos basados en redes neuronales	10
3. Conclusiones	13
4. Referencias	13

1. Introducción

En lo que a las estrategias de defensa se refiere, la innovación en el ámbito tecnológico es una parte muy importante de su actividad debido al gran interés de mejorar la eficiencia de los sistemas de defensa, así como la planificación y desempeño de las misiones operativas. Con este objetivo, se llevó a cabo el desarrollo de los denominados sistemas ISTAR (*Intelligence, Surveillance, Target Acquisition and Reconnaissance*), concepto utilizado por la OTAN y que se refiere a los sistemas que presentan la capacidad integrada de adquisición, explotación y distribución de información de inteligencia para la planificación y desarrollo de operaciones militares. En base a este concepto, la generación y gestión de información de inteligencia se puede dividir en las etapas [1] representadas en la Figura 1.




Figura 1: Etapas del proceso de generación y gestión de información de inteligencia en sistemas ISTAR.

Para llevar a cabo las tareas de vigilancia y de adquisición y reconocimiento de objetivos, los sistemas ISTAR presentan sistemas de sensores que integran múltiples tecnologías, entre las que destacan los sensores radar, los sensores ópticos de espectro visible e infrarrojos, los sensores acústicos y los receptores de guerra electrónica. Dentro de los receptores de guerra electrónica para sistemas ISTAR, este estudio se centra en el análisis del estado del arte de los algoritmos que permiten llevar a cabo una clasificación automática de las modulaciones de las señales recibidas, con el objetivo de permitir el re

Los sistemas de guerra electrónica (*Electronic Warfare, EW*), que se encargan principalmente de las tareas de vigilancia y control del espectro electromagnético, se dividen en tres grandes subgrupos [2] :

- Sistemas de apoyo electrónico (*Electronic Support, ES*): analizan el espectro electromagnético para detectar, localizar e identificar las fuentes de emisión.
- Sistemas de ataque electrónico (*Electronic Attack, EA*): llevan a cabo contramedidas electrónicas para evitar la utilización del espectro por parte de terceros.
- Sistemas de protección electrónica (*Electronic Protection, EP*): llevan a cabo acciones para eludir las contramedidas electrónicas.

Una de las funciones más importantes de los sistemas de apoyo electrónico (ES) es la inteligencia de señales (*Signal Intelligence, SIGINT*) para localizar e identificar las emisiones electromagnéticas en toda la banda de frecuencias de comunicaciones y sistemas radar. La finalidad de estas actividades es la obtención de conocimiento e información de inteligencia acerca de las capacidades y objetivos del adversario y el reconocimiento de las amenazas.

Los sistemas SIGINT se dividen generalmente en [2]:

- Sistemas de inteligencia de comunicaciones (*Communications Intelligence, COMINT*) dedicados a tareas de detección, clasificación, identificación y radiogoniometría (*Direction Finding, DF*) de sistemas de comunicaciones, enlaces de datos, comunicaciones satelitales o teléfonos móviles.

- Sistemas de inteligencia electrónica (*Electronic Intelligence*, ELINT) empleados en la detección, localización y medida de parámetros de señales no dedicadas a comunicaciones, generalmente procedentes de sistemas radar. Los parámetros estimados (frecuencia de portadora, ancho de banda, tipo de forma de onda, ancho de pulso o intervalo de repetición de pulsos) de la señal radar detectada permiten clasificar los sistemas radar enemigos y sus sistemas de armas asociados, obteniendo un conocimiento del denominado orden de batalla electromagnético (*Electronic Order of Battle*, EOB).

La determinación de la modulación de las señales detectadas facilita la clasificación e identificación de la fuente de emisión, por lo que se trata de una etapa importante de los sistemas SIGINT. En este sentido, se han desarrollado múltiples algoritmos de clasificación automática de modulaciones (*Automatic Modulation Classification*, AMC) que permiten determinar de forma autónoma la modulación de las señales capturadas en base a sus propiedades y parámetros cuantificables [3].

La arquitectura hardware típica de los sistemas SIGINT [4] mostrada en la Figura 2, se divide normalmente en tres módulos principales: sistema de antenas, receptores de señal, que incluyen etapas de filtrado, amplificación, conversión inferior de frecuencias (*frequency down-conversion*) y muestreo con conversores analógico digital (*Analog-to-Digital Converter*, ADC) y unidades de procesamiento digital de aquellas señales recibidas. Tradicionalmente, estos sistemas presentaban una arquitectura monocanal con antenas direccionales con exploración mecánica o electrónica para determinar la dirección de llegada de las señales interceptadas. Sin embargo, el avance de la electrónica y su reducción de costes han hecho evolucionar estos sistemas hacia arquitecturas multicanal implementando arrays digitales con un receptor para cada elemento radiante, de forma que se puedan aplicar procesados de *beamforming* adaptativos para la determinación de la dirección de llegada (*Direction of Arrival*, DoA) de las señales detectadas.

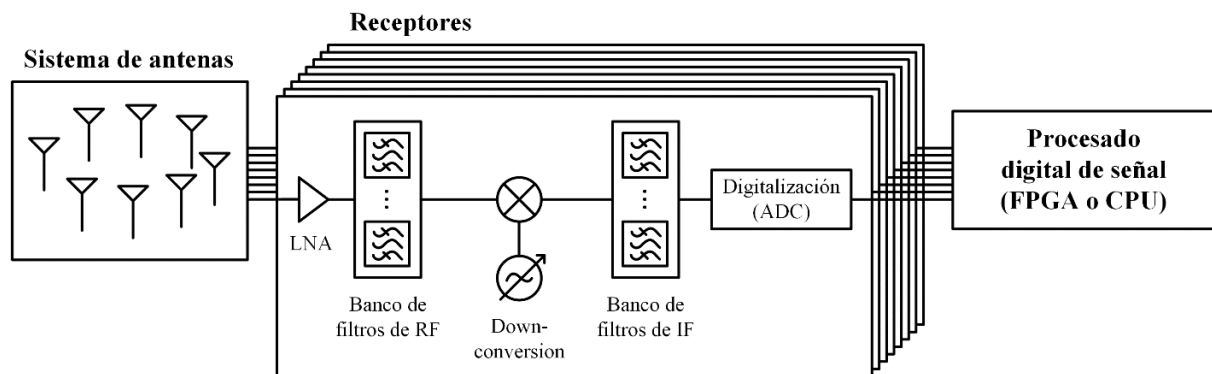


Figura 2: Arquitectura hardware típica de un sistema SIGINT multicanal.

La constante y rápida evolución de las comunicaciones ha desembocado en un mundo digital en el que es necesario el uso de ADCs. La mejora de estos dispositivos y de las plataformas hardware digitales permite [5] : (1) la digitalización de mayores anchos de banda; (2) la localización de los ADCs más cerca de la antena; (3) la implementación de algoritmos de mayor complejidad; (4) el procesamiento de mayores flujos de datos y (5) la disminución del tiempo de procesamiento y latencia para operar en tiempo real. Otro elemento importante de los sistemas de guerra electrónica son las memorias digitales de radiofrecuencia (DRFM) [6], cuyo continuo desarrollo ha permitido aumentar sus capacidades de almacenamiento y su empleo en sistemas de banda ancha.

Además, el desarrollo de equipos de radio definida por software (*Software-defined radio*, SDR) multicanal con mayores anchos de banda permite la implementación de sistemas de guerra electrónica utilizando estos dispositivos. Su gran flexibilidad y moderado coste, hace a estos equipos especialmente útiles para el prototipado de sistemas y la evaluación de algoritmos de clasificación automática de modulaciones, sin necesidad de desarrollar receptores específicos.



Figura 3: DRFM de la compañía Mercury Systems [7] (izq.) y radio definida por software con 4 canales en recepción de National Instruments [8] (dcha.).

Como se ha comentado, la clasificación automática de modulaciones facilita la identificación de las fuentes de emisión detectadas en equipos de guerra electrónica, pero también desempeña un papel importante en otros campos en los que también podría utilizarse el sistema desarrollado como, por ejemplo, en redes de radio cognitiva o en sistemas de identificación de interferencias.

2. Técnicas de clasificación automática de modulaciones

En un contexto en el que el uso de la inteligencia artificial y la digitalización de los sistemas de comunicaciones está en constante crecimiento, las técnicas empleadas en el ámbito de la guerra electrónica son cada vez más complejas, pero más completas a su vez. El problema reside en que en el ámbito militar puede haber diferentes amenazas. Por ello, es necesario conocer la identidad del atacante y el tipo de ataque. En este sentido, la información proporcionada por el análisis de las señales transmitidas por los sistemas enemigos es de gran utilidad para su identificación. Dentro de estas técnicas de análisis, se encuentra la clasificación automática de modulaciones (AMC), en la que se centra este estudio.

En el ámbito civil, la aplicación de AMC más importante es como parte de un sistema de adaptación de enlace (*link adaptation*, LA). En estos sistemas, como se muestra en la Figura 4, el transmisor presenta una unidad de modulación adaptativa. La función del modulador adaptativo es seleccionar la modulación utilizada de un conjunto predefinido. Esta selección está determinada por las especificaciones del sistema y el estado del canal. En el extremo receptor del sistema, asumiendo que el canal es variable con el tiempo, la información de estado del canal (CSI) debe estimarse periódicamente a lo largo de la transmisión. El CSI estimado junto con información sobre la calidad de la señal recibida se enviarán al transmisor donde se utilizará el CSI para la selección del esquema de modulación adecuado. En el receptor, el clasificador de modulaciones, junto con la información de canal y calidad de la señal, permite determinar la modulación que se está

utilizando en cada momento y llevar a cabo la demodulación adecuada de la señal mediante un demodulador reconfigurable. Si la clasificación de modulación es precisa, el método de demodulación correcto permitirá obtener adecuadamente los datos transmitidos. Si la clasificación de modulación es incorrecta, la transmisión completa falla, ya que los datos transmitidos no pueden recuperarse en el demodulador.

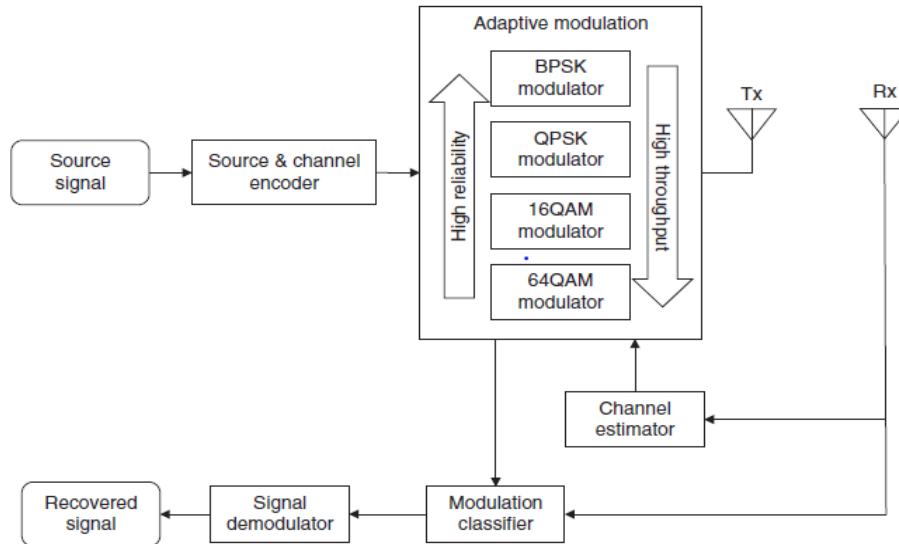


Figura 4: Aplicación de la clasificación de modulaciones en sistemas con adaptación de enlace [3]

En cambio, en el ámbito militar las técnicas AMC son vitales en estrategias en las que se emplean técnicas avanzadas para la interceptación de señales y su procedimiento en tiempo real que son importantes para la toma de decisiones relacionadas con la guerra electrónica.

La clasificación automática de modulaciones es un paso intermedio entre detección de señales y la demodulación de datos en sistemas de comunicaciones, y entre la detección de señales y la respuesta de los sistemas de reacción (*reaction systems*) en sistemas guerra electrónica. El reconocimiento de la modulación es un procedimiento no cooperativo que se basa en el procesamiento de la señal y que suele incluir etapas de estimación de la frecuencia central, determinación de la envolvente compleja, remuestreo de las señales y ecualización del canal [9].

En los sistemas de apoyo electrónico (ES), el objetivo es obtener información de las diferentes emisiones radio detectadas, como la localización del transmisor o su identificación. Es en este punto donde se suele usar AMC, después de que la detección de la señal haya sido realizada correctamente. La información de la modulación resultante no solo se emplea en los sistemas de ES, sino que también tiene diferentes usos en las diferentes ramas de la guerra electrónica.

A continuación, se muestra un sistema militar de guerra electrónica, que incluye sistemas de *jamming* y de decodificación de las señales, y que presenta un clasificador de modulaciones como etapa central necesaria para llevar a cabo el resto funciones (Figura 5).

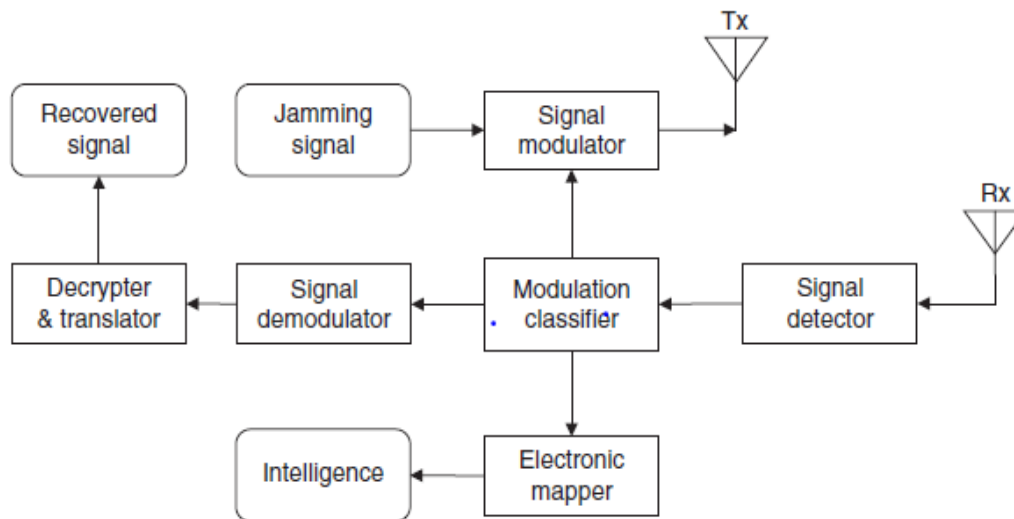


Figura 5: Sistema militar de inteligencia de señales (SIGINT) [3]

De forma general, un clasificador automático de modulaciones (AMC) presenta dos etapas principales: (1) Preprocesamiento de la señal y (2) Selección adecuada del algoritmo de clasificación.

El preprocesamiento puede incluir tareas como la reducción de ruido, la estimación de la frecuencia de la portadora, el período de símbolo y la potencia de la señal o la ecualización del canal, entre otras. Dependiendo del algoritmo de clasificación que se elija, la precisión requerida en las etapas del preprocesamiento puede ser más o menos estricta, ya que algunos algoritmos requieren unas estimaciones muy precisas, mientras que otros son menos sensibles. Esto significa que hay una relación muy importante entre el preprocesamiento de la señal y la elección de uno u otro algoritmo [10].

Los clasificadores de modulaciones se pueden clasificar en tres grandes grupos:

1. Algoritmos basados en la función de verosimilitud (*likelihood-based*, LB): En el enfoque LB, la decisión se toma al maximizar la probabilidad de que se envíe una cierta modulación dada la señal recibida. El algoritmo de máxima verosimilitud (ML) es el algoritmo más popular basado en este enfoque [11].
2. Algoritmos basados en características (*feature-based*, FB): en este caso la clasificación se realiza a través de la extracción de características (*features*) de la señal recibida. Tras dicha extracción, la clasificación o decisión se realiza a través de diferentes algoritmos de clasificación como los árboles de decisión. A diferencia de los algoritmos LB, estas técnicas no son óptimas, pero presentan un desarrollo y una implementación más simples [11].
3. Técnicas basadas en *Machine Learning*: para evitar los problemas relacionados con el diseño de los árboles de decisión y con la optimización de los umbrales de decisión, se han desarrollado técnicas de clasificación de modulaciones basadas en *Machine Learning*, que llevan a cabo de forma automática la generación y selección de parámetros.

A continuación, se describen detalladamente las dos últimas técnicas, algoritmos basados en características y en *Machine Learning*.

2.1. Algoritmos basados en características (*feature-based*, FB)

La clasificación basada en algoritmos de máxima verosimilitud presenta una gran precisión y efectividad, pero debido a su gran complejidad computacional, se empezaron a desarrollar clasificadores basados en la extracción de *features* de la señal recibida. Estos clasificadores presentan un menor rendimiento, ya que no son algoritmos óptimos, pero su reducida carga computacional y simplicidad hace que su uso sea extendido.

A la hora de diseñar un algoritmo FB, se deben seguir tres pasos principales:

- Especificar las modulaciones de interés: el primer paso necesario es especificar las posibles modulaciones de estudio entre las cuales se clasificarán las señales recibidas. Entre las modulaciones analógicas destacan AM y FM, mientras que entre las modulaciones digitales destacan ASK, M-QAM, M-PSK, FSK y OFDM. También puede ser de interés las modulaciones típicas de señales radar como LFM o modulación de fase con códigos de Barker.
- Selección de las características de las señales: el segundo paso de este diseño es la elección y extracción de *features* de la señal recibida. El objetivo de este paso es conseguir la discriminación de una modulación respecto a las otras a través de unos *features* claves, que pueden depender del espectro, ancho de banda, variación de la amplitud o de la frecuencia, SNR u otras características de la señal modulada, por lo que estas dependencias deben ser estudiadas. Además, la determinación de ciertos *features* puede imponer la necesidad de aplicar ciertos preprocesamientos de la señal recibida. En el siguiente apartado, se explican algunos *features* típicos utilizados en los algoritmos AMC y en los que se basará el diseño realizado.
- Elección del algoritmo de clasificación: Este último paso consiste en la elección de un algoritmo que a través de los *features* anteriormente extraídos sea capaz de realizar la clasificación de la señal detectada. Entre los clasificadores basados en *features* destacan los árboles de decisión, que describen más adelante.

2.1.1. Extracción de *features* para AMC

Con el objetivo de clasificar las señales en función de su modulación, se han propuestos distintos tipos de *features*, algunos específicos para clasificar modulaciones analógicas, otros para modulaciones digitales o para ambos tipos de modulaciones (forma de la constelación [12], densidad espectral de potencia [13], envolvente de la señal [14], . A continuación, se detallan los *features* más empleados, que serán útiles para diseñar el árbol de decisión:

1. Estimación de la frecuencia instantánea de la señal recibida, $r(t)$, y empleo del histograma de frecuencia instantánea para clasificar modulaciones analógicas: Utilizando la Transformada de Hilbert de la señal, $r_H(t)$, se determina la señal analítica, $y(t) = r(t) + jr_H(t)$, cuya amplitud, $A(t)$, y fase instantánea, $\phi(t)$, vienen dadas por:

$$A(t) = |y(t)|$$

$$\phi(t) = \arg\{y(t)\}$$

La frecuencia intermedia de la señal puede ser trasladada a 0 Hz para obtener la envolvente compleja de la señal, $y_d(t) = A(t)e^{j[\phi(t)-\omega t]}$, donde ω es la frecuencia

angular (pulsación) intermedia de la señal y $[\phi(t) - \omega t]$ es la fase instantánea de $y_d(t)$. Por tanto, la frecuencia instantánea de la señal viene dada por:

$$f_{inst}(t) = \frac{1}{2\pi} \frac{d\phi_d(t)}{dt}$$

Sin embargo, si la señal recibida es muestreada (señal discreta), la frecuencia instantánea se define como la diferencia de fases de dos tiempos de muestreo consecutivos dividida entre el intervalo entre las dos muestras consecutivas, diferencia entre esos dos tiempos, ΔT (periodo de muestreo) [12].

$$f_{inst}[n] = \frac{\phi_d[n] - \phi_d[n - 1]}{\Delta T}$$

Una vez que se ha calculado la frecuencia instantánea de la señal para un conjunto de tiempos de muestreo, se puede emplear el histograma de la frecuencia instantánea para clasificar el tipo de modulación empleada, ya que las diferentes modulaciones analógicas dan lugar a diferentes patrones, como se observa en la Figura 6, en los que se representan los histogramas para señales analógicas moduladas AM, DSB, LSB, USB y FM. Se comprueba, por ejemplo, que la frecuencia instantánea en señales AM se acumula en torno a la frecuencia de portadora (histograma muy estrecho), mientras que en señales FM la frecuencia instantánea presenta mayor dispersión.

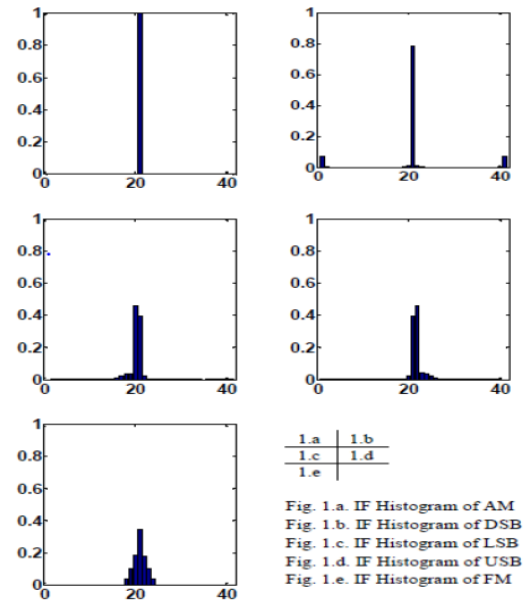


Figura 6: Histogramas de frecuencia instantánea [15].

2. γ_{max} : valor máximo de la densidad espectral de potencia de la amplitud instantánea centrada y normalizada, A_{cn} :

$$\gamma_{max} = \max |DFT(A_{cn}[n])|^2$$

donde $A_{cn}[n] = \frac{A[n]}{\mu_A} - 1$, siendo $A[n]$ la amplitud instantánea de la señal y μ_A la media de la amplitud instantánea del fragmento de la señal considerado.

3. σ_{ap} : desviación estándar del valor absoluto de la componente no lineal de la fase instantánea, filtrando aquellas muestras que presentan una amplitud inferior a un umbral A_t . Se define como:

$$\sigma_{ap} = \sqrt{\frac{1}{N_c} \left(\sum_{A_n[n] > A_t} \phi_{NL}^2[n] \right) - \left(\frac{1}{N_c} \sum_{A_n[n] > A_t} |\phi_{NL}[n]| \right)^2}$$

siendo $\phi_{NL}[n]$ la componente no lineal de la fase instantánea y N_c el número de muestras que cumplen la condición $A_n[n] > A_t$, es decir, cuya amplitud supera el umbral establecido. Ese umbral es usado debido a que las muestras que no lo

superen tienen una gran influencia del ruido y no tienen la misma fiabilidad que el resto.

4. σ_{dp} : desviación estándar del valor de la componente no lineal de la fase instantánea, filtrando aquellas muestras que presentan una amplitud inferior a un umbral A_t . Se define como:

$$\sigma_{dp} = \sqrt{\frac{1}{N_c} \left(\sum_{A_n[n] > A_t} \phi_{NL}^2[n] \right) - \left(\frac{1}{N_c} \sum_{A_n[n] > A_t} \phi_{NL}[n] \right)^2}$$

5. σ_{aa} : desviación estándar del valor absoluto de la amplitud instantánea centrada y normalizada de las muestras de la señal. Se define como:

$$\sigma_{aa} = \sqrt{\frac{1}{N} \left(\sum_{n=1}^N A_{cn}^2[n] \right) - \left(\frac{1}{N} \sum_{n=1}^N |A_{cn}[n]| \right)^2}$$

6. σ_{af} : desviación estándar del valor absoluto de la frecuencia instantánea centrada y normalizada. Se define como:

$$\sigma_{af} = \sqrt{\frac{1}{N_c} \left(\sum_{A_n[n] > A_t} f_N^2[n] \right) - \left(\frac{1}{N_c} \sum_{A_n[n] > A_t} |f_N[n]| \right)^2}$$

siendo $f_N[n]$ la frecuencia instantánea central y normalizada por la frecuencia de muestreo f_s :

$$f_N[n] = \frac{f_m[n]}{f_s}$$

$$f_m[n] = f[n] - \frac{1}{N} \sum_{n=1}^N f[n]$$

7. σ_a : desviación estándar de la amplitud instantánea centrada normalizada de las muestras de la señal. Se define como:

$$\sigma_a = \sqrt{\frac{1}{N_c} \left(\sum_{A_n[n] > A_t} A_{cN}^2[n] \right) - \left(\frac{1}{N_c} \sum_{A_n[n] > A_t} A_{cn}[n] \right)^2}$$

8. μ_{42}^a : es la curtosis (una característica relacionada con la forma de la distribución) de la amplitud instantánea centrada y normalizada. Se define como:

$$\mu_{42}^a = \frac{E\{A_{cn}^4[n]\}}{\{E\{A_{cn}^2[n]\}\}^2}$$

9. μ_{42}^f : es la curtosis de la frecuencia instantánea centrada y normalizada. Se define como:

$$\mu_{42}^f = \frac{E\{f_N^4[n]\}}{\{E\{f_N^2[n]\}\}^2}$$

Estos *features* son la base de los distintos árboles de decisión diseñados que se explican a continuación.

2.1.2. Árboles de decisión

Un árbol de decisión, como el que se muestra en la Figura 7, es un algoritmo de clasificación o predictivo que se usa tanto en aplicaciones tecnológicas como en economía y en procesos de toma de decisiones. Está basado en un modelo de árbol, en el cual, pasando por diferentes nodos, los cuales representa una prueba o test sobre un atributo o *feature*, se va dividiendo en ramas hasta que se llega a un nodo terminal que establece la clasificación final de los datos entrantes.

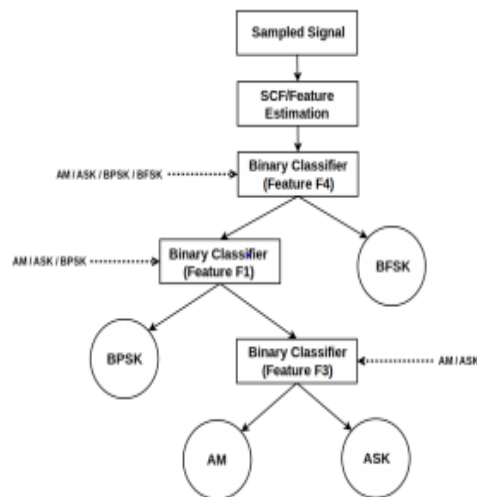


Figura 7: Ejemplo de estructura de árbol de decisión dedicado a la clasificación de modulaciones [16].

En el caso de la clasificación de modulaciones, el diseño del árbol consiste en seleccionar los *features* adecuados que permitan discriminar entre los distintos tipos de modulaciones y los umbrales de decisión para construir los múltiples nodos y ramas del árbol. Un diseño propuesto en [3] para la clasificación automática de modulaciones basado en las características de la señal se representa en la Figura 8.

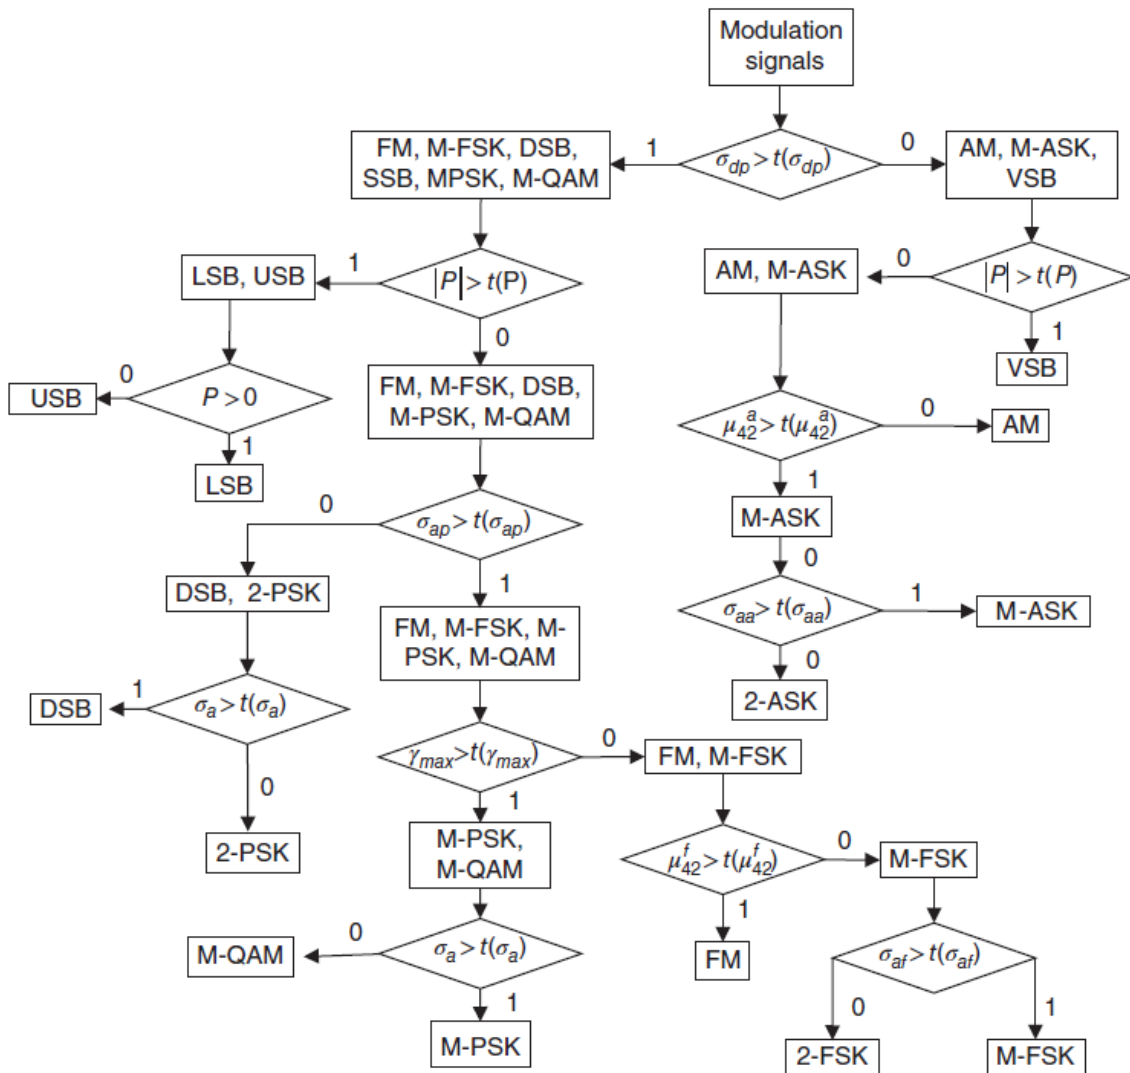


Figura 8: Árbol de decisión basado en las características de la señal para clasificación de modulaciones [3].

Las principales ventajas de este tipo de algoritmos son su simplicidad en el diseño e interpretación, su baja carga computacional y que es adecuado tanto para datos cuantitativos como cualitativos. Sin embargo, el diseño del árbol requiere un conocimiento a priori de los datos y, por tanto, la participación de expertos para seleccionar los parámetros adecuados. Por este motivo, cada vez se emplean más las técnicas de *machine learning* que permiten un aprendizaje automático, llevándose a cabo la extracción y selección de *features* de forma autónoma a partir de unos datos de entrenamiento y sin requerir el conocimiento a priori de un experto.

2.2. Algoritmos basados en redes neuronales

El uso de redes neuronales con el paso de los años va creciendo debido a la tendencia del mundo actual de automatizar todo lo que nos rodea. Las redes neuronales tratan de imitar el comportamiento de la mente humana para permitir el aprendizaje de las máquinas. Estos algoritmos han tenido un gran éxito y se han empleado en múltiples aplicaciones debido a su naturaleza no paramétrica, la capacidad de generar fronteras de decisión arbitrarias, fácil adaptación a diferentes tipos de datos y estructuras de entrada, generación de valores difusos y generalización de uso con múltiples imágenes o datos de entrenamiento, por lo que se

considera una técnica de clasificación [17] con potencial para mejorar los algoritmos de clasificación de modulaciones.

Las redes neuronales están compuestas por: una capa de entrada, con el mismo número de elementos que las dimensiones de los datos de entrada; una serie de capas ocultas y una capa de salida con tantos elementos como clases se tengan. Todas estas capas están conectadas a través de pesos y bias, que se determinan en la etapa de entrenamiento. En la Figura 9, se muestra un ejemplo de red neuronal (perceptrón multicapa) con entradas con cuatro dimensiones es decir $\mathbf{X} = (x_1, x_2, x_3, x_4)$ conectado a la siguiente capa de neuronas a través de pesos W .

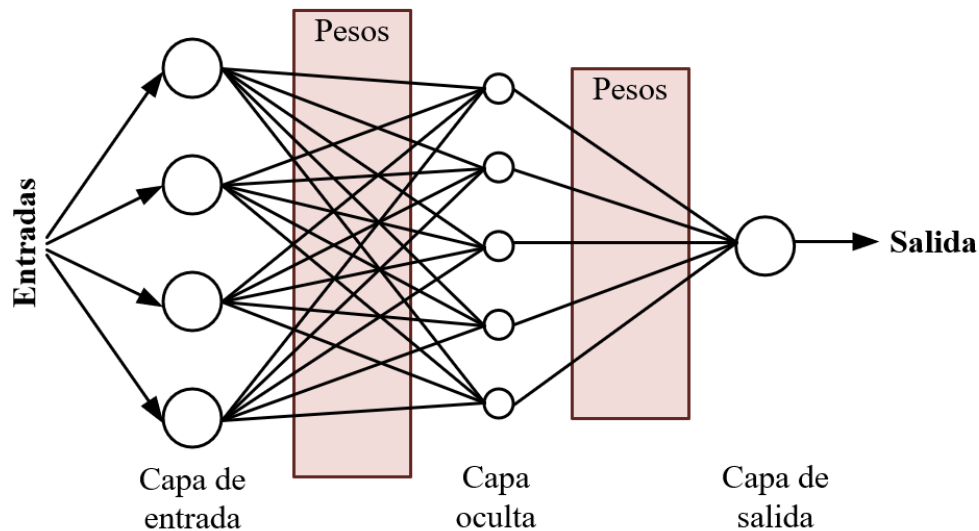


Figura 9: Arquitectura de red neuronal (perceptrón multicapa).

Las redes neuronales basadas en la arquitectura perceptrón multicapa poseen una serie de limitaciones, como el largo proceso de aprendizaje para problemas complejos dependientes de un gran número de variables. Por este motivo, se han propuesto otras arquitecturas basadas en capas convolucionales, que se adaptan a determinadas características de los datos de entrada, para reducir el número de parámetros de la red.

El objetivo del entrenamiento de las redes neuronales es que aprendan esos parámetros (*learnables*), como los pesos y bias, y sean capaces de resolver el problema que se les plantea. Para determinar estos parámetros durante el proceso de entrenamiento se usa muy frecuentemente el algoritmo *backpropagation* basado en la estrategia de optimización de descenso por gradiente que hace uso de la regla de la cadena, que se divide en dos pasos: el primero consiste en introducir los datos de entrenamiento en la capa de entrada para obtener los resultados en la capa de salida. A partir de esto se calcula el error que se propaga hacia atrás y se van actualizando los parámetros hasta obtener un error mínimo. Cuando ya se tiene ese error mínimo se guardan los pesos y bias utilizados para obtener ese error y se repite el proceso con más datos de entrenamiento para que la red vaya convergiendo a un estado que dé lugar a un error mínimo.

La forma más común de *Machine Learning* es aprendizaje supervisado, que se basa en datos de entrenamiento de los que se conoce el resultado deseado. Para ello, se requiere tener una gran cantidad de señales moduladas etiquetadas con su modulación correspondiente, que se emplean para entrenar la red con el objetivo de minimizar una función de pérdida ajustando sus parámetros internos, a menudo llamados pesos. En un sistema típico de aprendizaje profundo, puede haber cientos de millones de estos pesos ajustables.

Las técnicas de Deep Learning están basadas en redes convolucionales las cuales están diseñadas para procesar datos en forma de matrices múltiples, por ejemplo, una imagen en color compuesta de tres matrices 2D que contienen intensidades de píxeles en los tres canales de color. Muchas modalidades de datos se presentan en forma de matrices múltiples: 1D para señales y secuencias, incluido el lenguaje; 2D para imágenes o espectrogramas de audio; y 3D para imágenes de vídeo o volumétricas.

Hay cuatro ideas clave detrás de las redes convolucionales que aprovechan las propiedades de las señales naturales: conexiones locales, pesos compartidos, pooling y el uso de muchas capas.

La arquitectura de una red neuronal convolucional, como la representada en la Figura 10 (arquitectura AlexNet), está estructurada en una serie de etapas. Las primeras etapas se componen de dos tipos de capas: capas convolucionales y capas de pooling. Las unidades en una capa convolucional están organizadas en mapas de características, dentro de los cuales cada unidad está conectada a parches locales en los mapas de características de la capa anterior a través de un conjunto de pesos que implementan un banco de filtros. El resultado de esta suma ponderada local se pasa a través de una no linealidad como una función ReLU [18].

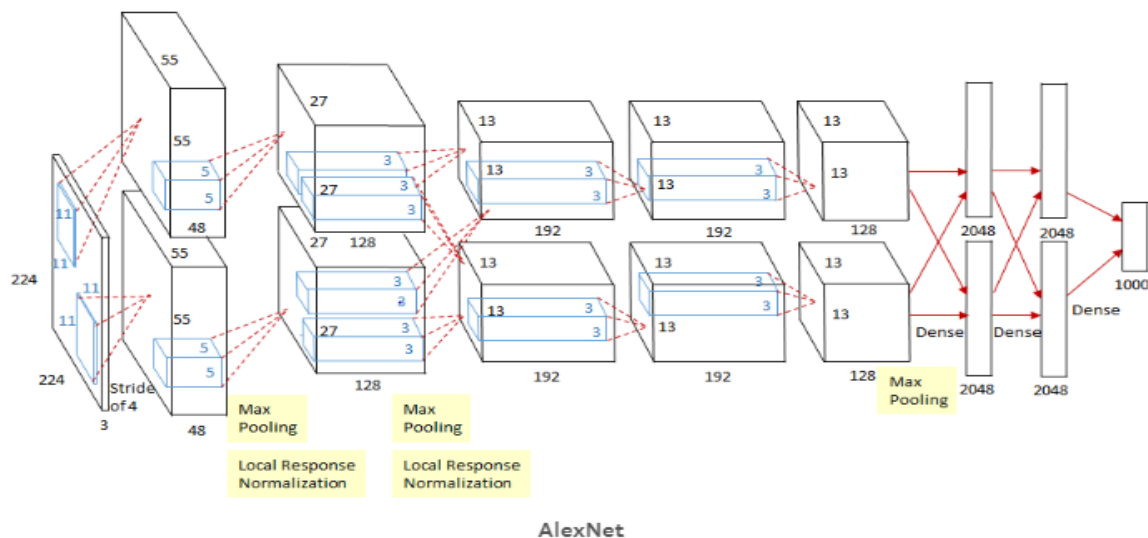


Figura 10: Estructura de la red AlexNet [19].

Matemáticamente, la operación de filtrado realizada por un mapa de características es una convolución discreta. Aunque la función de la capa convolucional es detectar conjunciones locales de características o patrones de la capa anterior, la función de la capa de agrupación es fusionar características semánticamente similares en una sola.

Una unidad de pool típica calcula el máximo de un parche local de unidades en un mapa de características (o en unos pocos mapas de características). Las unidades de pooling vecinas reciben información de parches que se desplazan en más de una fila o columna, reduciendo así la dimensión de la representación y creando una invariancia a pequeños desplazamientos y distorsiones.

3. Conclusiones

En este estudio, se han descrito las técnicas tradicionales para la clasificación automática de modulaciones: los algoritmos basados en la función de verosimilitud (algoritmos óptimos pero de gran complejidad teórica y computacional) y los algoritmos basados en la extracción de parámetros, como los árboles de decisión (algoritmos no óptimos pero de menor complejidad). Sin embargo, estos últimos algoritmos requieren el conocimiento de un experto que permita llevar a cabo la selección de las características adecuadas de las señales que permitan discriminar las distintas modulaciones de interés, así como el diseño y selección del árbol de decisión y de los umbrales seleccionados para las reglas de decisión de cada nodo del árbol.

Por este motivo, para evitar esta desventaja, se está evolucionando hacia un mayor uso de técnicas basadas en *machine learning* y entrenamiento automático para llevar a cabo la clasificación automática de modulaciones. El empleo de redes neuronales, especialmente convolucionales, muestra un gran potencial para extraer de forma autónoma patrones característicos de las señales y realizar la clasificación de su modulación de forma precisa. Sin embargo, se requiere un mayor análisis del comportamiento interno de las redes aplicadas a la clasificación automática de modulaciones para garantizar la robustez de estos sistemas frente a efectos que degradan la calidad de la señal recibida (interferencias, multitrayecto, sincronismo, offset de portadora, Doppler, canales de propagación dinámicos, distorsiones, etc.).

4. Referencias

- [1] Ministerio de Defensa: ISTAR [Online]. Disponible en: <http://www.tecnologiae.innovacion.defensa.gob.es/en-us/Estrategia/HojasDeRuta/Pages/ISTAR.aspx> (Accedido 31/07/2019)
- [2] De Martino, A.: *Introduction to modern EW systems*. Artech house, 2018.
- [3] Zhu, Z., Nandi, A. K.: *Automatic modulation classification. Principles, algorithms and applications*, John Wiley & Sons, 2015
- [4] Alparslan, A., Yegin, K.: “A fast ELINT receiver design”, *13th European Radar Conference (EuRAD)*, 2016.
- [5] Iglesias Muñoz, V.: “Diseño de algoritmos de guerra electrónica y radar para su implementación en sistemas de tiempo real”, Tesis doctoral, Universidad Politécnica de Madrid (UPM), 2015.
- [6] Horizonte Defensa y Seguridad (Cátedra Isdefe-UPM): “Equipos de Guerra Electrónica en Plataformas ISTAR” [Online]. Disponible en: http://www.horizontesdefensayseguridad.net/wp-content/uploads/sites/3/2019/02/Estado_del_Arte_EW_ISTAR_v1.pdf (Accedido 31/07/2019).
- [7] Mercury Systems: “Airborne 1225” [Online]. Disponible en: <https://www.mrcy.com/drfs-solutions/airborne-1225/> (Accedido 31/07/2019).
- [8] National Instruments: “USRP-2945” [Online]. Disponible en: <http://www.ni.com/es-es/support/model.usrp-2945.html> (Accedido 31/07/2019).

- [9] Su, W., Kosinski, J.: “Comparison and Simulation of Digital Modulation Recognition Algorithms”, *International Symposium on Advanced Radio Technologies (ISART)*, 2003.
- [10] Dobre, O., Abdi, A., Bar-Ness, Y., Su, W.: “Survey of Automatic Modulation Classification Techniques: Classical Approaches and New Trends”, *IET Communications*, vol. 1, no. 2, pp. 137–156, 2007.
- [11] Abu-Romoh, M., Aboutaleb, A., Rezki, Z.: “Automatic Modulation Classification Using Moments and Likelihood Maximization”, *IEEE Communications Letters*, vol. 22, no. 5, pp. 938-941, 2018.
- [12] Mobasseri, B.G.: “Digital modulation classification using constellation shape,” *Signal processing*, vol. 80, no. 2, pp. 251-277, 2000.
- [13] Martin, R.: “Noise power spectral density estimation based on optimal smoothing and minimum statistics,” *IEEE Transactions on Speech and Audio Processing*, vol. 9, no. 5, pp. 504-512, 2001.
- [14] Lecours, M., Chouinard, J.Y., Delisle, G.Y., Roy, J.: “Statistical modeling of the received signal envelope in a mobile radio channel,” *IEEE Transactions on Vehicular Technology*, vol. 37, no. 4, pp. 204-212, 1988.
- [15] Xiao, H., Shi, Y.Q., Su, W., Kosinski, J.A.: “Automatic Classification of Analog Modulation Schemes”, *IEEE Radio and Wireless Symposium*, 2012.
- [16] Basumatary, N., Sarma, N., Nath, B.: “Signal Type Detection in CRN :A Hierarchical Modulation Classification Framework using SVM and Decision Tree Approaches”, *International Conference on Accessibility to Digital World (ICADW)*, 2016:.
- [17] Lu, D., Weng, Q.: “A survey of image classification methods and techniques for improving classification performance”, *International Journal of Remote Sensing*, vol. 28, no. 5, pp. 823-870, 2007.
- [18] LeCun, Y., Bengios, Y., Hinton, G.: "Deep learning", *Nature*, vol. 521, no. 7553, pp. 436-444, 2015.
- [19] Krizhevsky, A., Sutskever, I., Hinton, G.E.: “ImageNet Classification with Deep Convolutional”, *Advances in Neural Information Processing Systems*, 2012.