

DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y TELECOMUNICACIONES

CARRERA DE INGENIERÍA EN ELECTRÓNICA Y TELECOMUNICACIONES

PROYECTO DE TITULACIÓN:

“DETECCIÓN DE OBJETOS EN SEÑALES DE RADAR USANDO REDES NEURONALES CONVOLUCIONALES”

AUTOR: Novoa Gordillo Miguel Andrés

DIRECTOR DEL PROYECTO: Ing. Carrera Erazo, Enrique Vinicio. PhD.



AGENDA

1.- INTRODUCCIÓN

2.- OBJETIVOS

3.- MARCO TEÓRICO

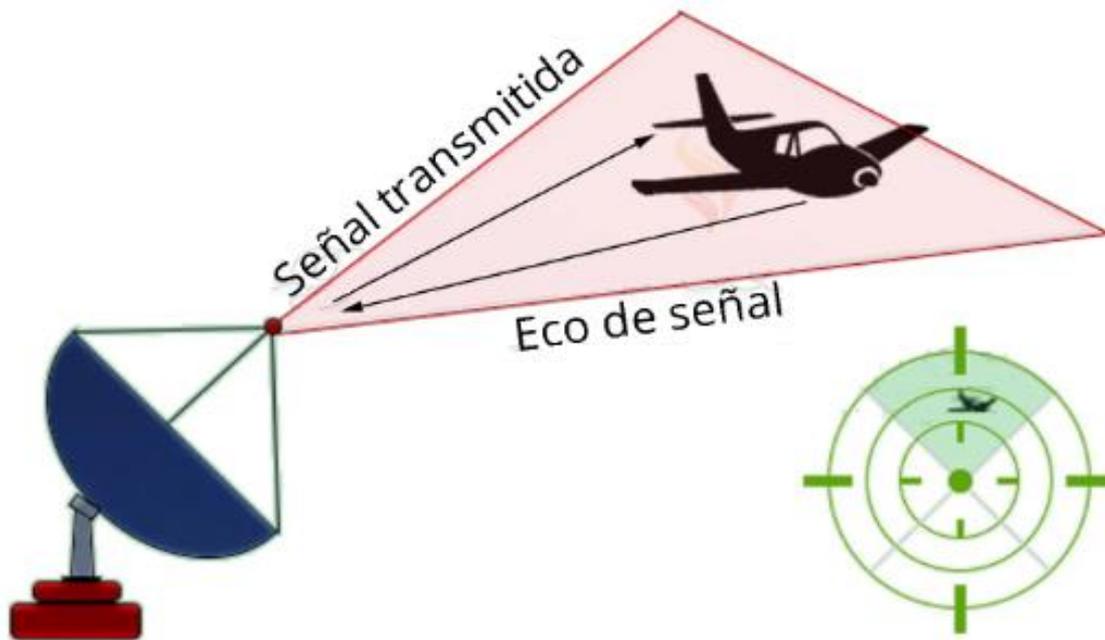
4.- METODOLOGÍA

5.- RESULTADOS

6.- CONCLUSIONES , RECOMENDACIONES Y TRABAJOS FUTUROS



Los sistemas de radar funcionan a través de radiaciones electromagnéticas y entre sus aplicativos permiten detectar y localizar objetos en condiciones donde el ser humano no es capaz de realizar esta tarea.



RETOS

La señal de interés se ve afectada por reflexiones generadas por el ambiente, fenómeno denominado "clutter"

En el 2008 bombardeo aéreo Angostura

En el 2013 proyecto de fortalecimiento de la seguridad y el sistema de vigilancia del espacio aéreo del Ecuador

Actualmente se cuenta con cuatro radares primarios y siete radares secundarios



Objetivo General

Detectar objetos en señales de radar usando redes neuronales convolucionales para mejorar el desempeño, la capacidad y la calidad de radares actualmente existentes.

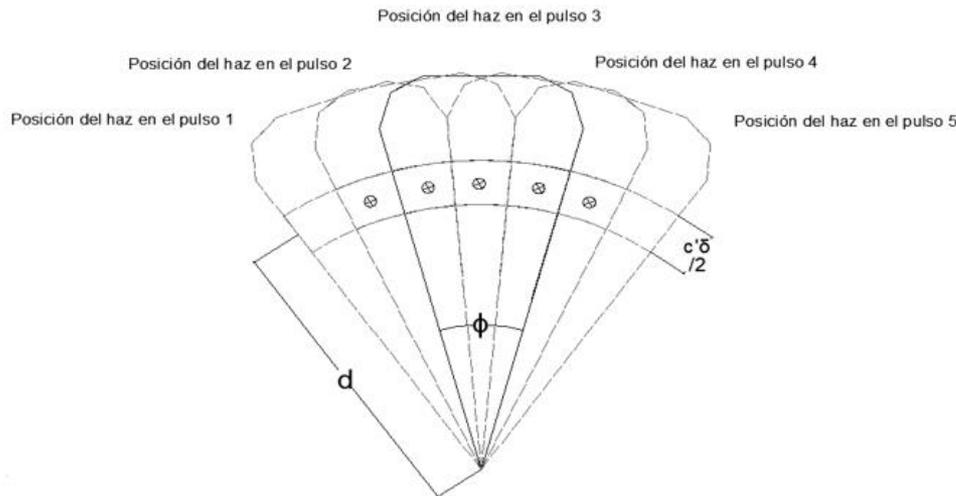
Objetivos Específicos

- Investigar los diferentes algoritmos existentes de redes neuronales convolucionales y sus aplicaciones.
- Obtener los conjuntos de datos generados por simulación de señales de radar para el entrenamiento del sistema y comprobar el funcionamiento del algoritmo con un nuevo conjunto de datos generado por el mismo software.
- Implementar los modelos basados en redes neuronales convolucionales para la detección de objetos en señales de radar.
- Evaluar los resultados obtenidos de la detección de objetos por el sistema de redes neuronales convolucionales unidimensionales contra las redes neuronales convolucionales bidimensionales y otros algoritmos de máquina tradicionales.



Irradian señales electromagnéticas en forma de haz y receptan ondas que contienen la reflexión de los objetos

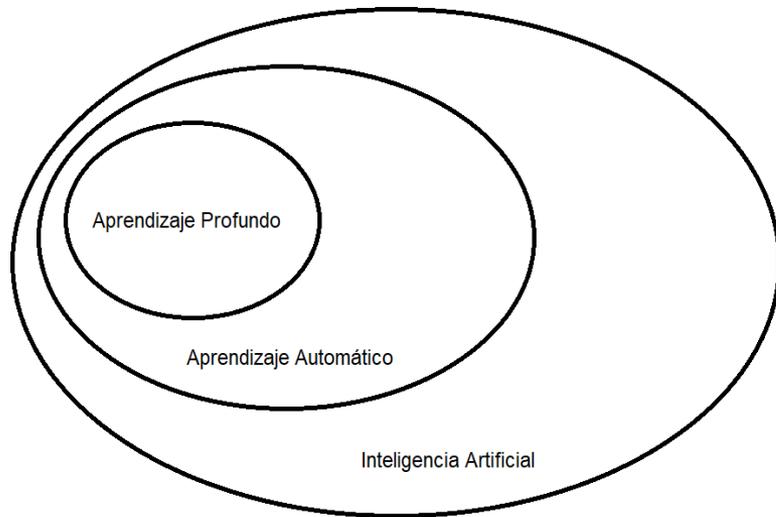
$$\frac{S}{N} = \frac{\text{Potencia de señal}}{\text{Potencia de ruido}}$$



$$\left(\frac{S}{N}\right)_{dB} = 10 * \log \left(\frac{\text{Potencia de señal}}{\text{Potencia de ruido}}\right)$$

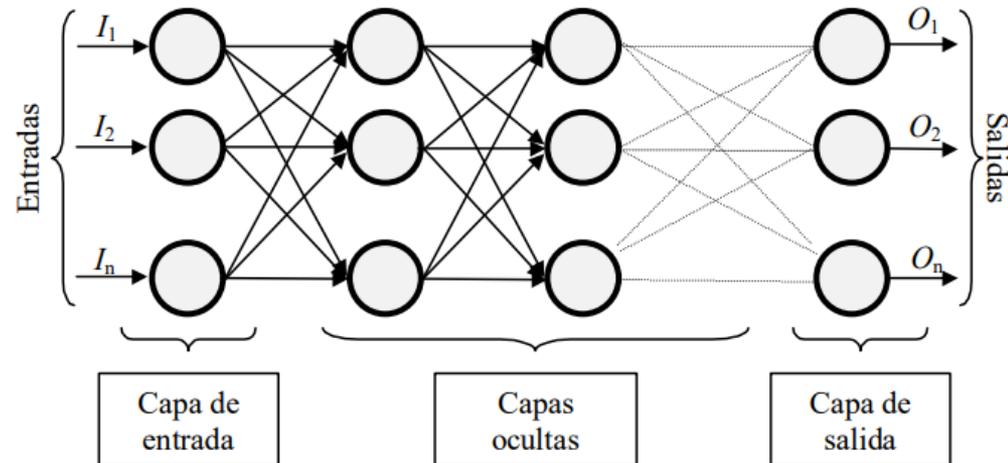


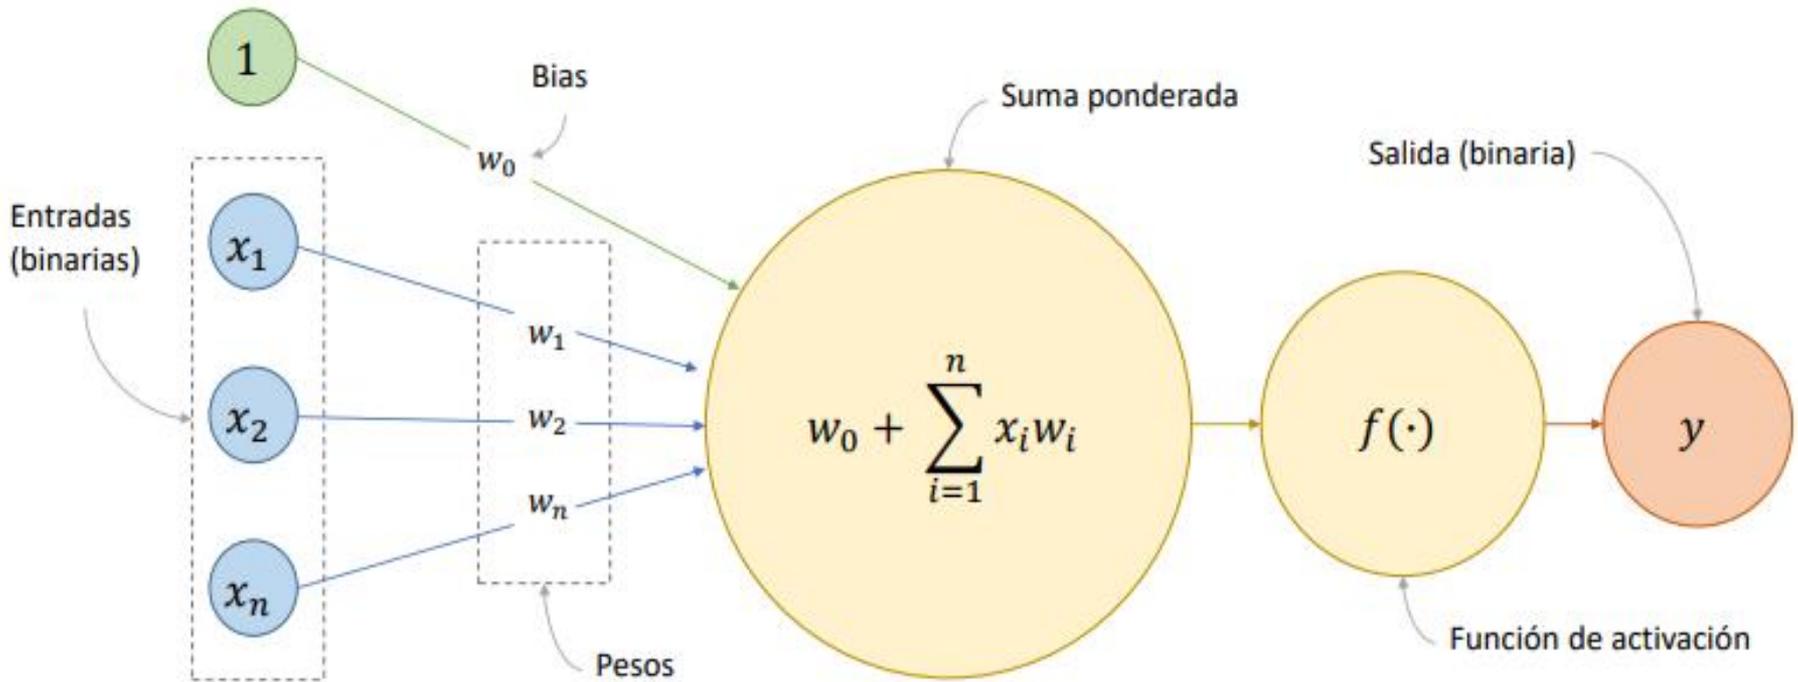
Aprendizaje Profundo (Deep Learning)



Redes Neuronales Artificiales

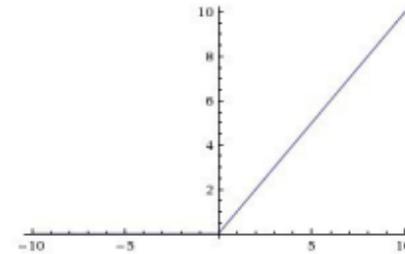
Modelo matemático implementado computacionalmente que tiene por objetivo emular las funciones de las neuronas biológicas



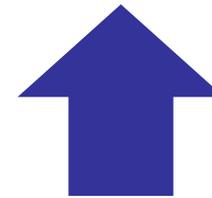


Una funciones de activación permite conocer el siguiente estado de activación en base a la entrada total y al anterior estado

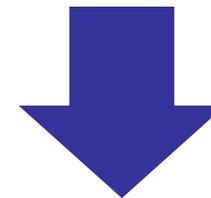
$$\text{ReLU}(x) = \max \{0, x\}$$



Tipo	Función	Rango
Identidad	$y = x$	$[-\infty, +\infty]$
Escalón	$y = \text{sign}(x)$	$\{-1, +1\}$
	$y = H(x)$	$\{0, +1\}$
Sigmoide	$y = \frac{1}{1 + e^x}$	$[0, +1]$
	$y = \text{tanh}(x)$	$[-1, +1]$
Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$
Sinusoidal	$y = A * \sin(\omega x + \varphi)$	$[-1, +1]$
ReLU	$y = \max\{0, x\}$	$[0, +\infty]$



ReLU



Softmax

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=0}^K e^{z_k}} \quad \forall j \dots K$$





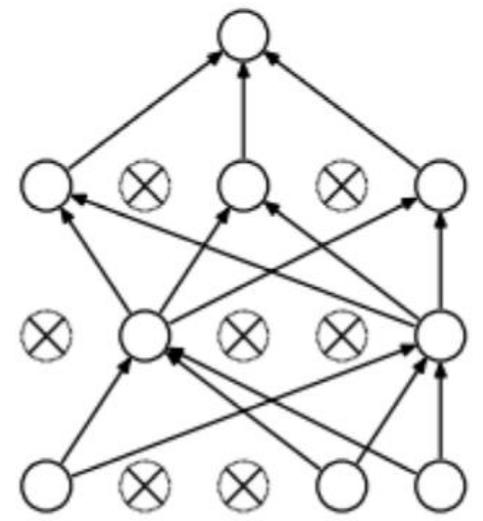
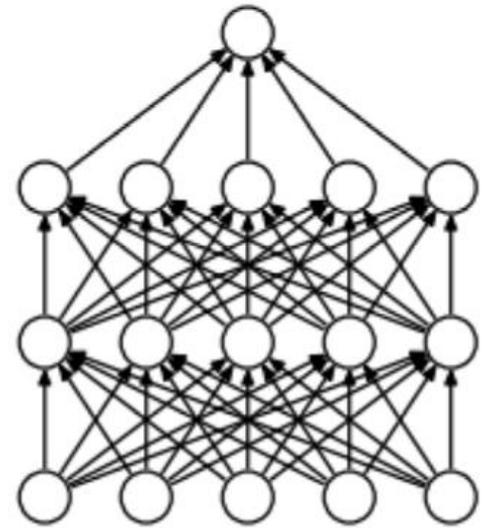
Toma los datos del exterior para el entrenamiento o validación de la red neuronal



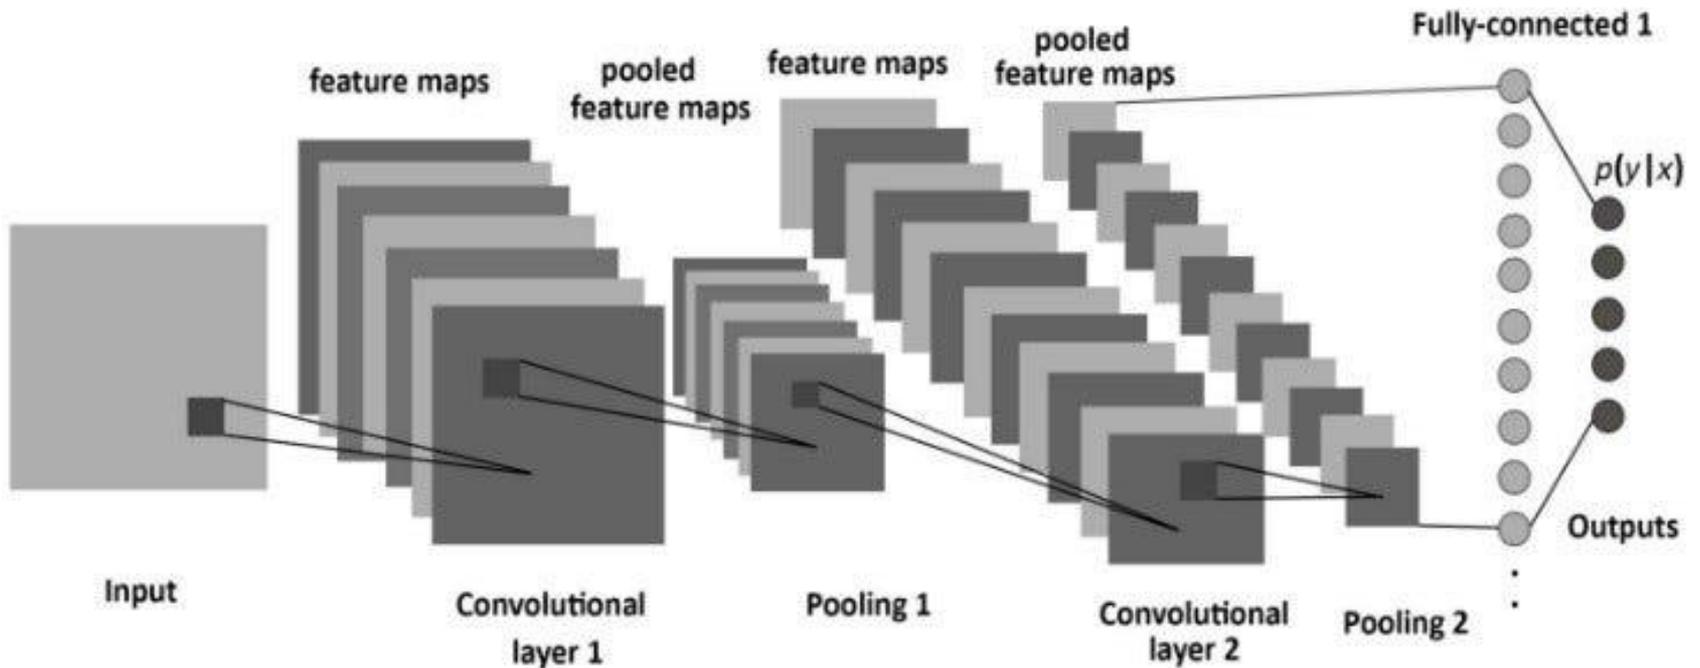
Interconexión entre todas las neuronales de las capas anteriores y siguientes



Previene el "sobreajuste" ignorando aleatoriamente ciertas neuronas.

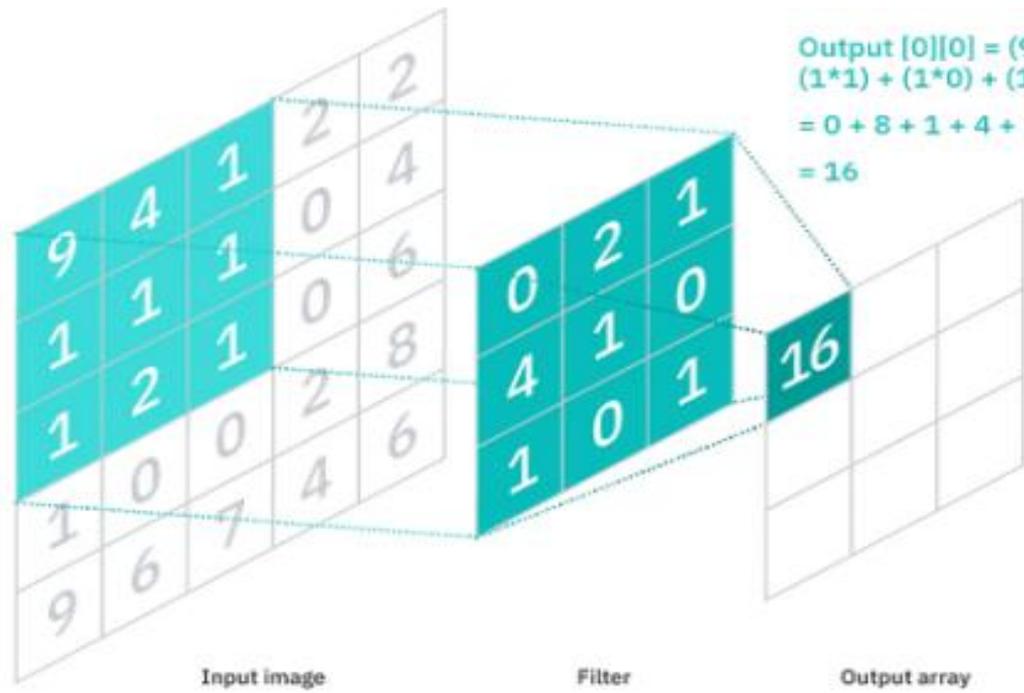
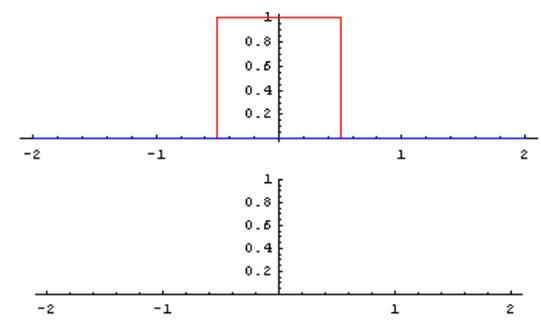


Una red neuronal convolucional es un tipo de red neuronal que se caracteriza por el uso de diversas capas convolucionales en el procesamiento de la red.



$$(f * g)_{(t)} = \int_0^t f(u)g(t - u)du; \quad \forall t > 0$$

$$x_n * y_n = \sum_{k=0}^n x_k y_{n-k}$$



Output [0][0] = (9*0) + (4*2) + (1*4) + (1*1) + (1*0) + (1*1) + (2*0) + (1*1)

= 0 + 8 + 1 + 4 + 1 + 0 + 1 + 0 + 1

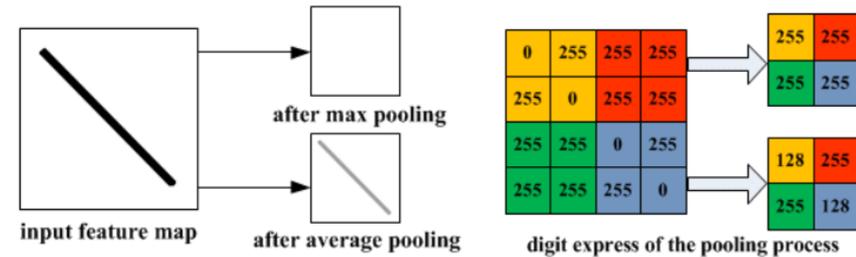
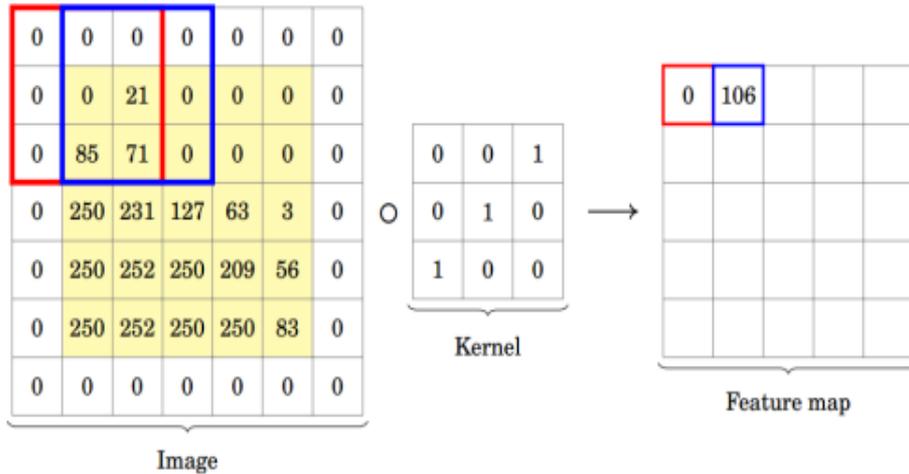
= 16

Rellenar los bordes de la imagen con ceros

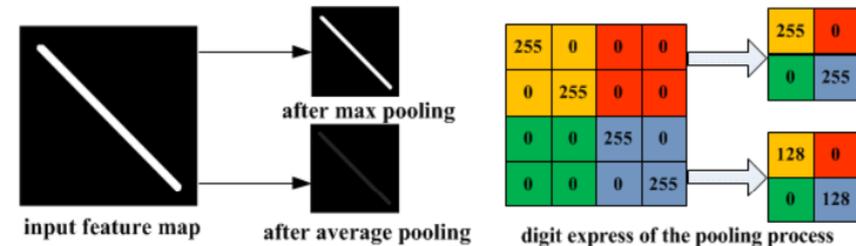
Padding

Pooling

Conservar las características más importantes detectadas por el filtro.

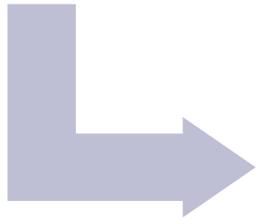


(a) Illustration of max pooling drawback

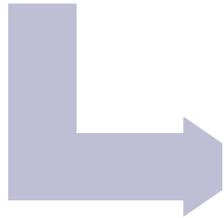




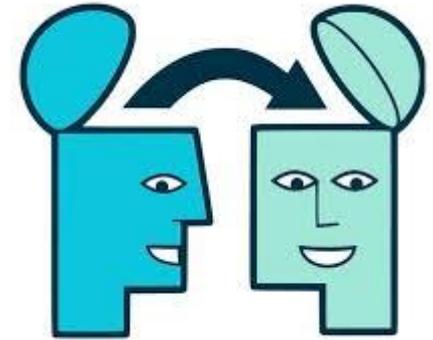
- Realizan la operación de la convolución en una dimensión

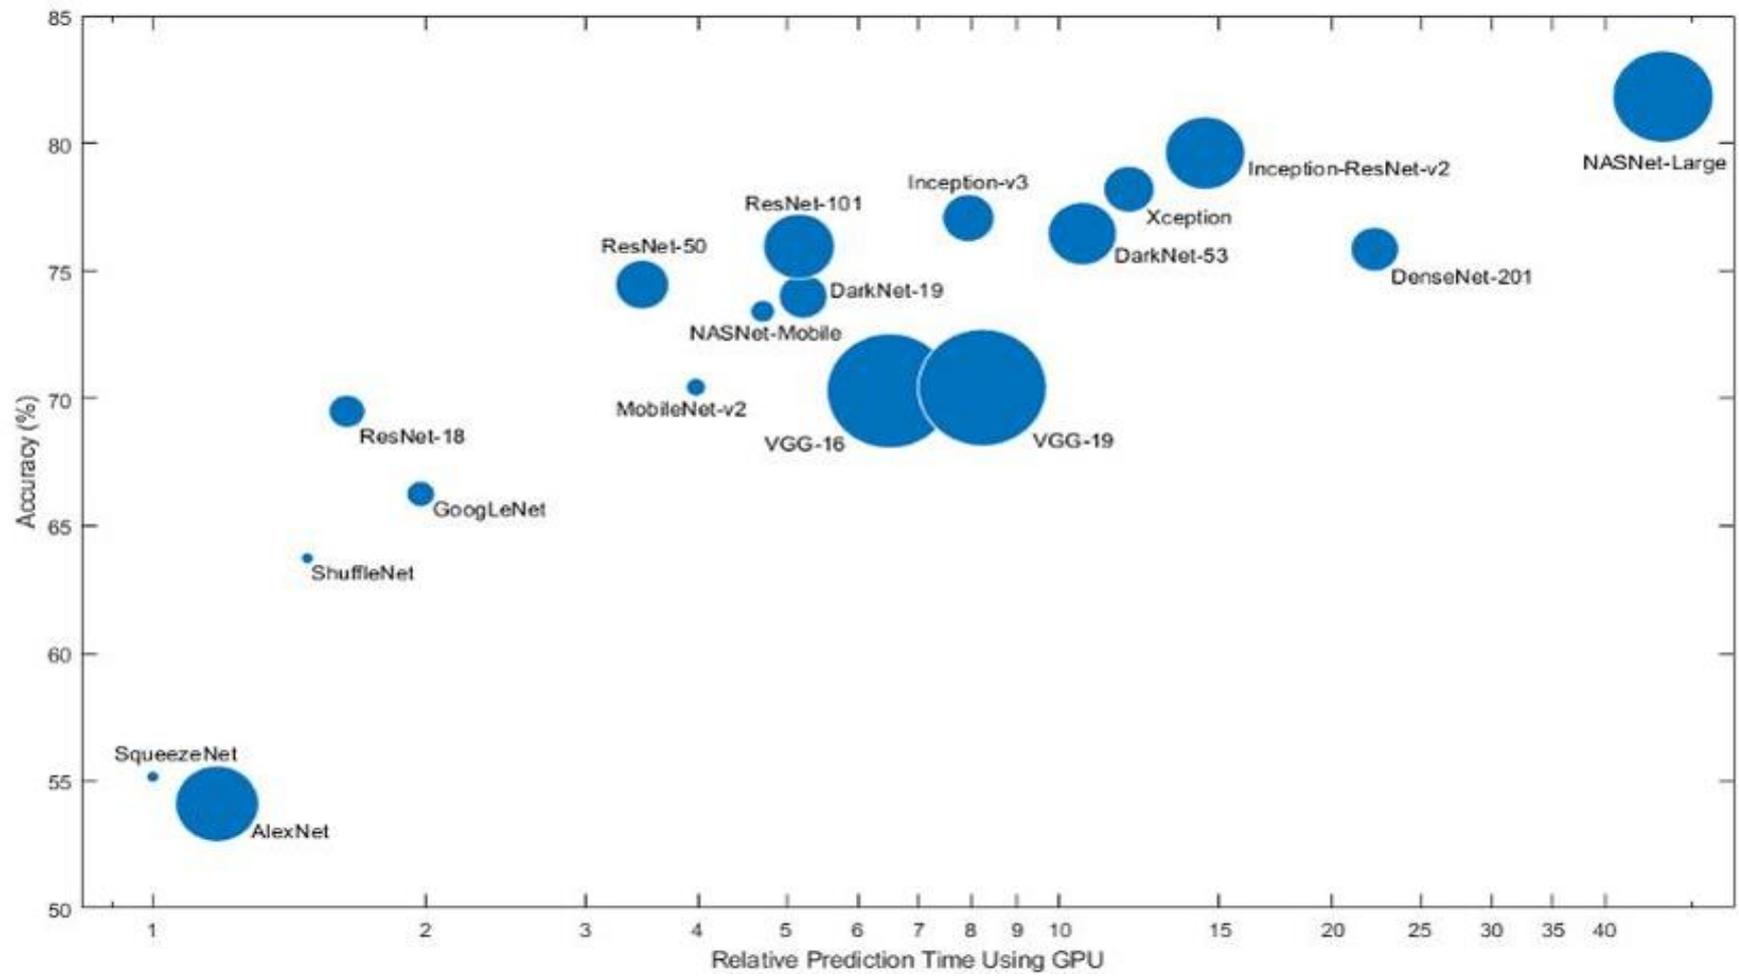


- Se caracterizan por tener como datos de entrada imágenes

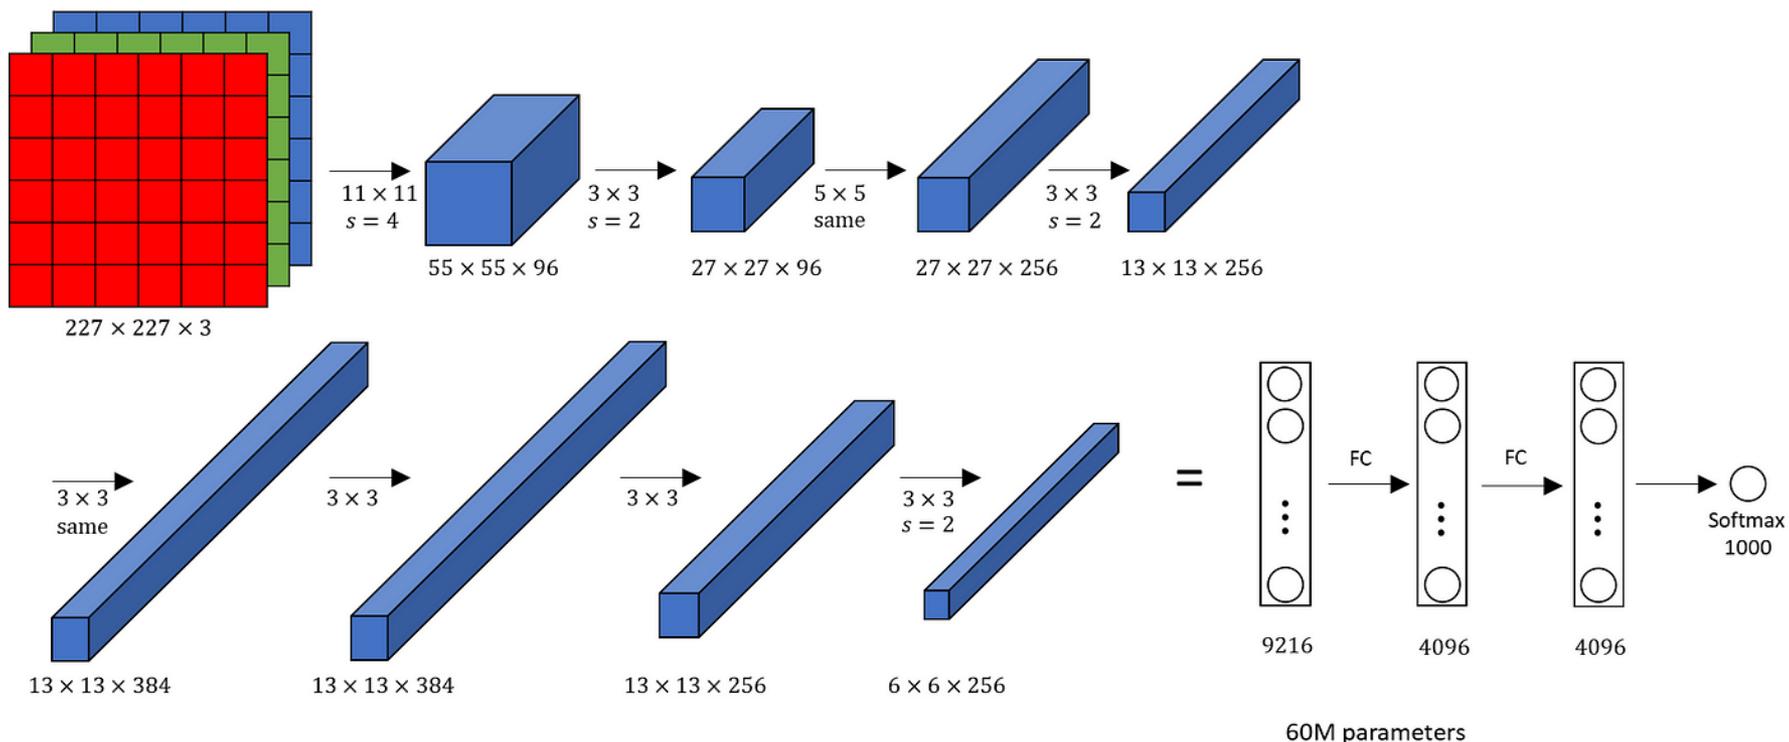


- Redes pre diseñadas tienen la característica de que pueden ser modificadas mediante técnicas como la transferencia de aprendizaje





Red neuronal convolucional pre entrenada utilizada principalmente para la clasificación y reconocimiento de imágenes

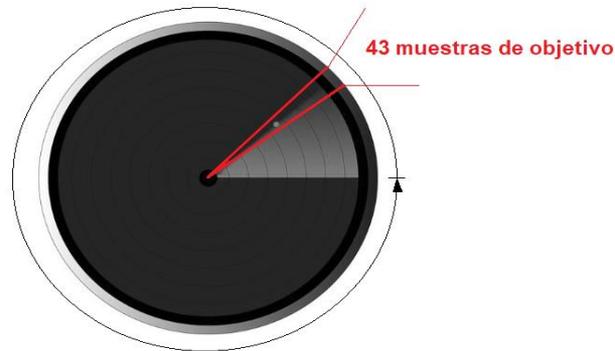


Matriz de confusión		Estimado por el modelo			
		Negativo (N)	Positivo (P)		
Real	Negativo	a: (TN)	b: (FP)	Precisión ("precision") Porcentaje predicciones positivas correctas:	$d/(b+d)$
	Positivo	c: (FN)	d: (TP)		
		Sensibilidad, exhaustividad ("Recall") Porcentaje casos positivos detectados	Especificidad ("Specificity") Porcentaje casos negativos detectados	Exactitud ("accuracy") Porcentaje de predicciones correctas (No sirve en datasets poco equilibrados)	
		$d/(d+c)$	$a/(a+b)$	$(a+d)/(a+b+c+d)$	



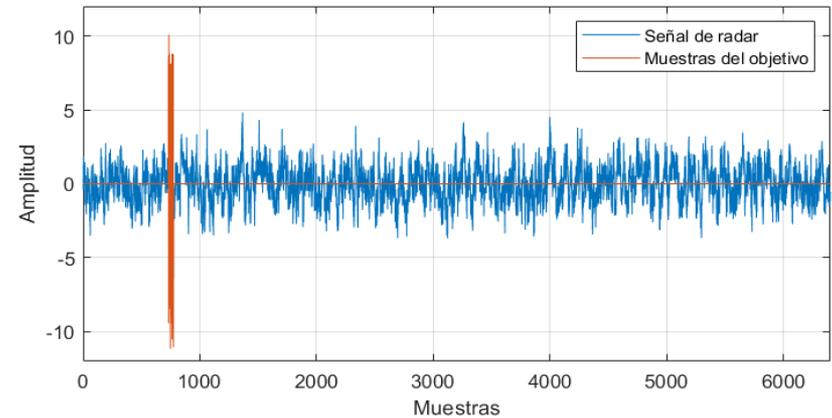
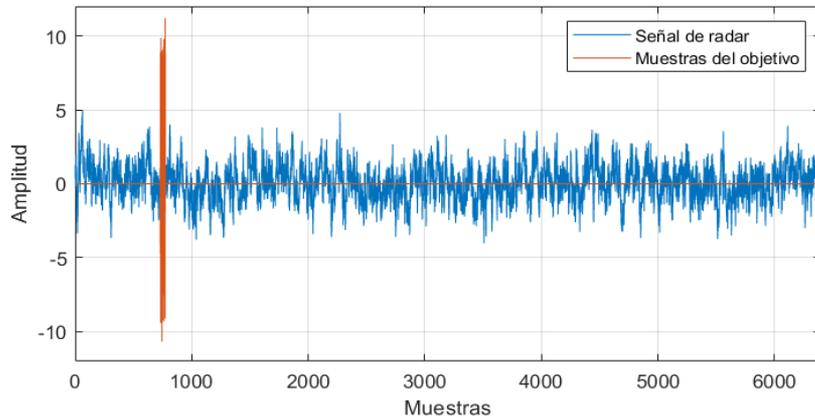
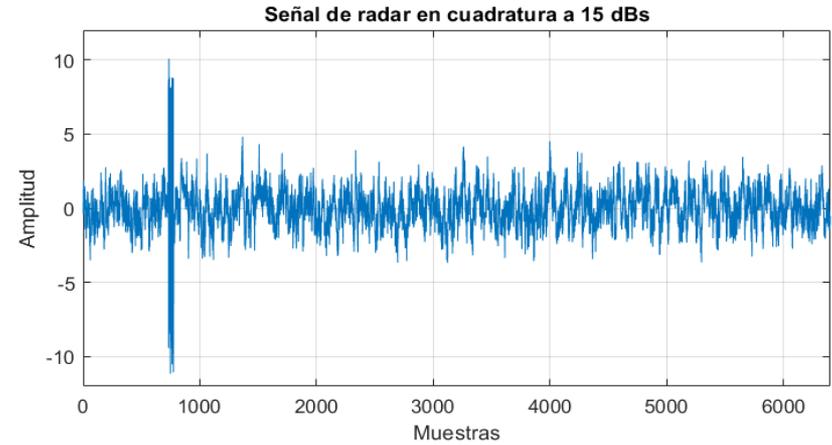
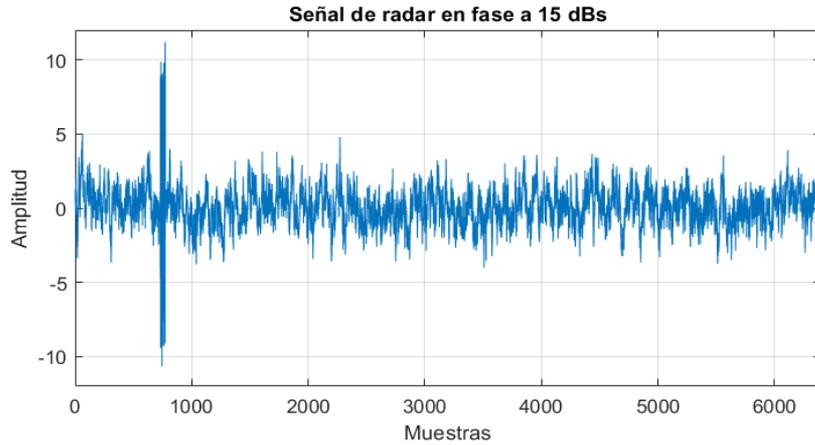
**SOFTWARE SIMULADOR
DE SEÑALES DE RADAR**

El barrido del radar da como resultado 6400 muestras con componente en fase y cuadratura de las cuales 43 muestras representan la presencia de un objetivo



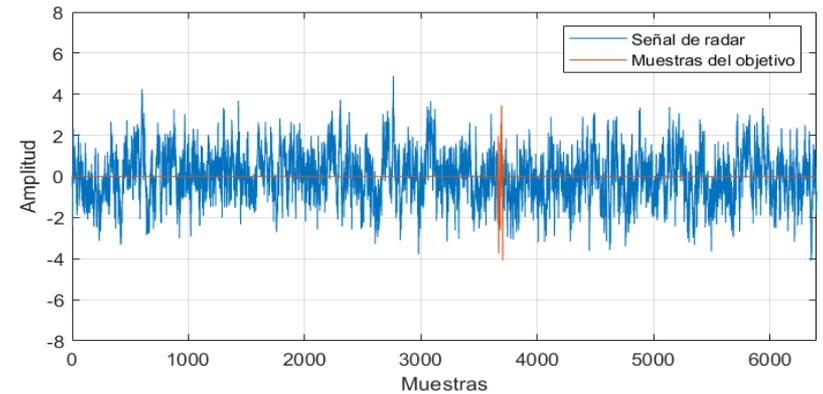
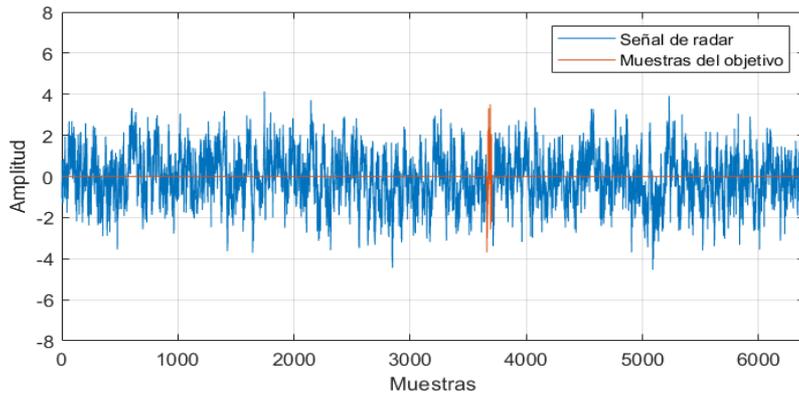
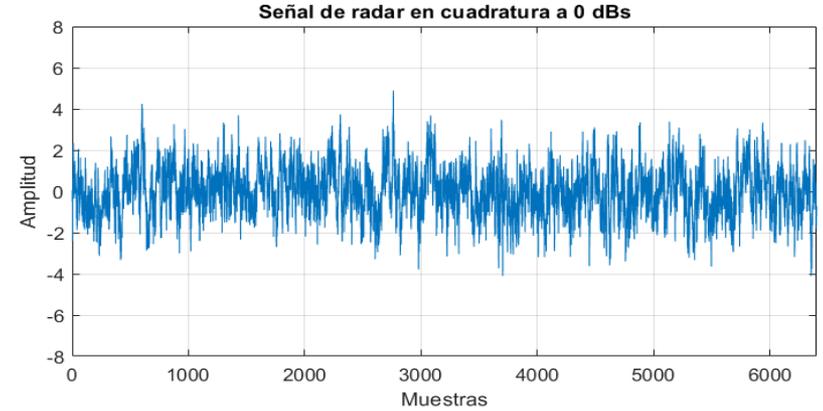
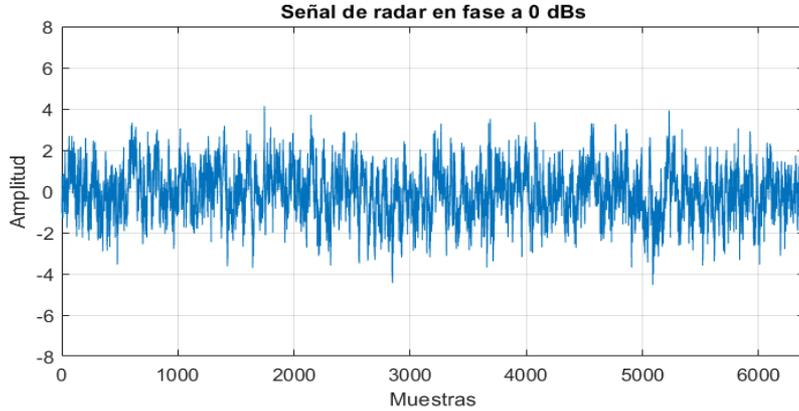
Componentes en fase y cuadratura de una señal de radar a una SNR de 15 dBs

METODOLOGÍA

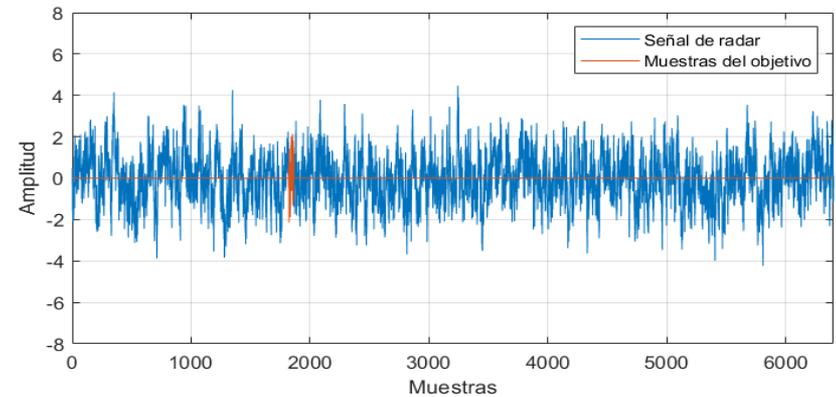
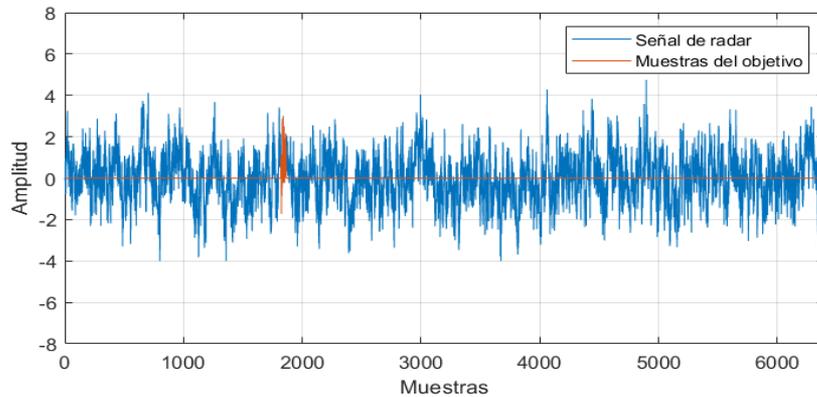
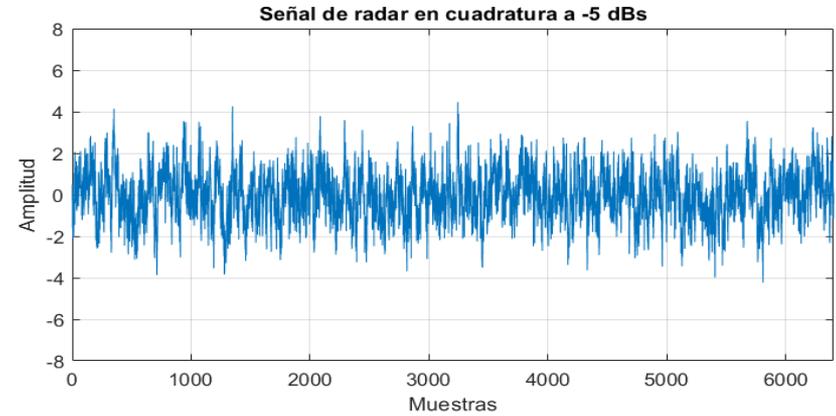
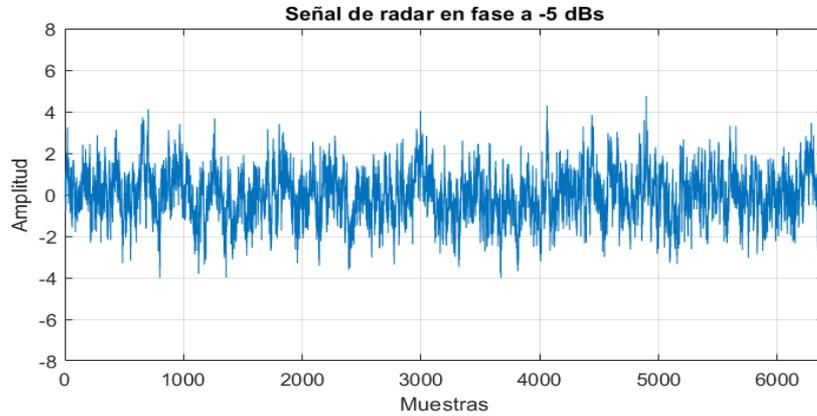


Componentes en fase y cuadratura de una señal de radar a una SNR de 0 dBs

METODOLOGÍA



Componentes en fase y cuadratura de una señal de radar a una SNR de -5 dBs



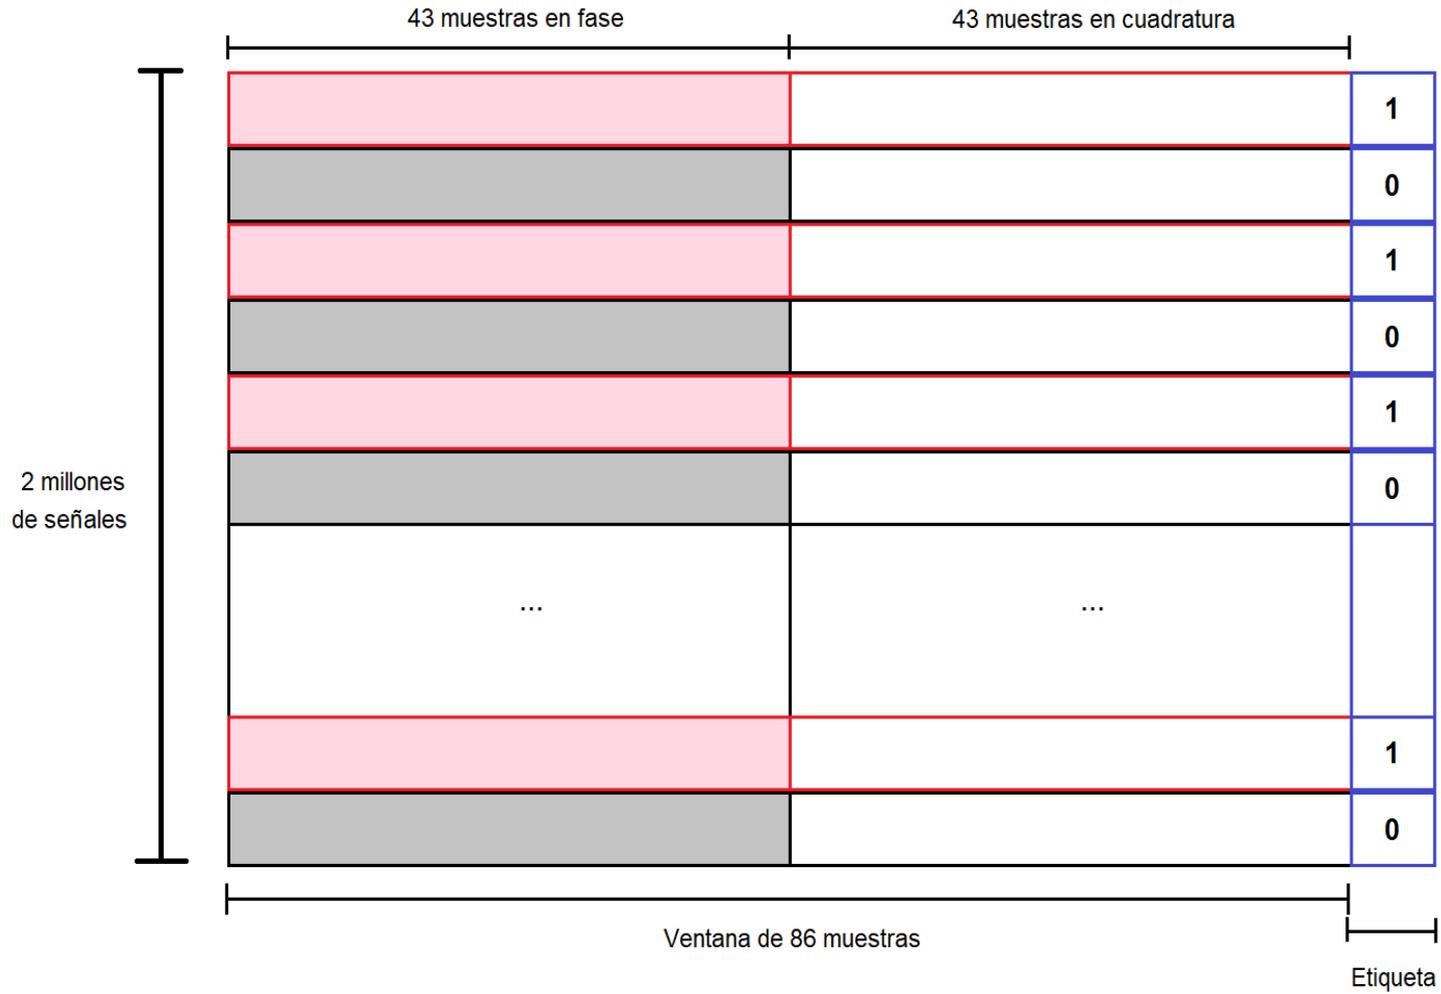


	1
	0
	1
	0
	1
	0
...	
	1
	0

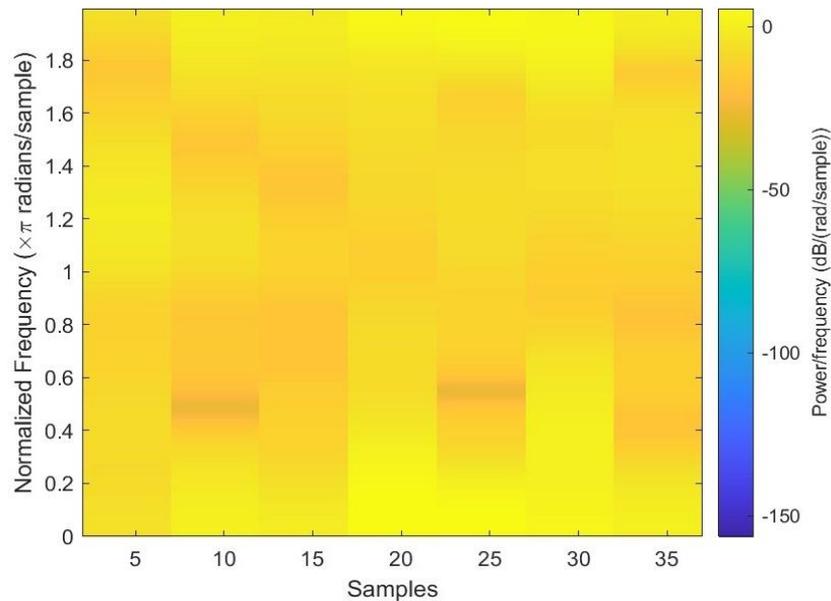
Ventana de 43 muestras

Etiqueta

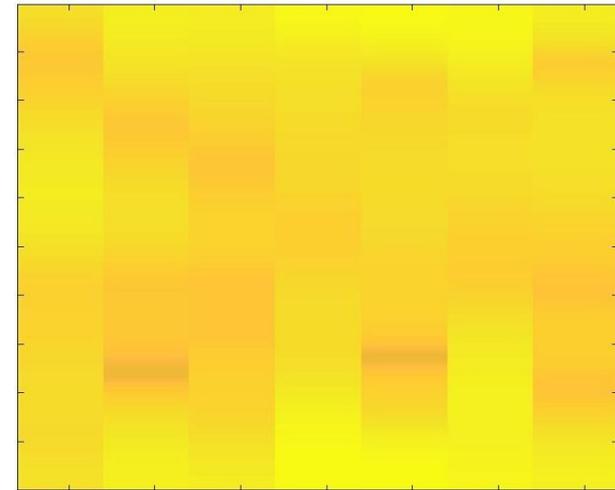




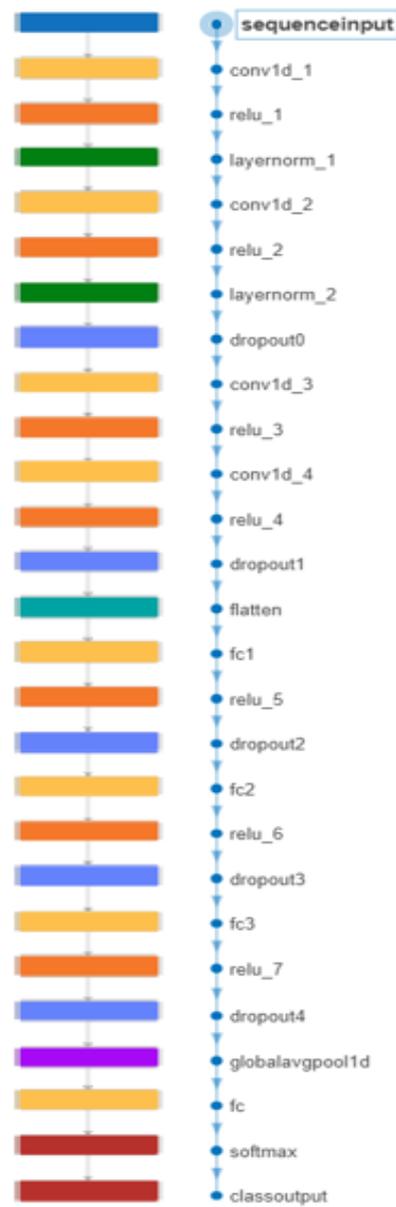
Espectrograma de una señal
de radar simulada



Re ajuste del área de
espectrograma.

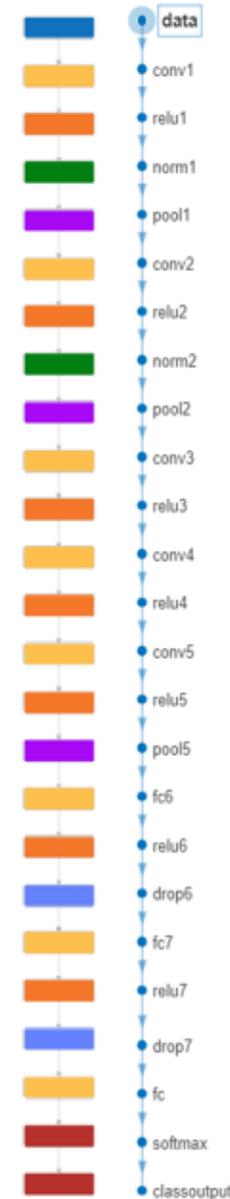


ANALYSIS RESULT		
#	Name	Type
1	sequenceinput Sequence input with 1 dimensions	Sequence Input
2	conv1d_1 32 10 convolutions with stride 1 and pad...	1-D Convolution
3	relu_1 ReLU	ReLU
4	layernorm_1 Layer normalization	Layer Normalization
5	conv1d_2 32 10 convolutions with stride 1 and pad...	1-D Convolution
6	relu_2 ReLU	ReLU
7	layernorm_2 Layer normalization	Layer Normalization
8	dropout0 50% dropout	Dropout
9	conv1d_3 32 5 convolutions with stride 1 and padd...	1-D Convolution
10	relu_3 ReLU	ReLU
11	conv1d_4 32 5 convolutions with stride 1 and padd...	1-D Convolution
12	relu_4 ReLU	ReLU
13	dropout1 50% dropout	Dropout
14	flatten Flatten	Flatten
15	fc1 100 fully connected layer	Fully Connected
16	relu_5 ReLU	ReLU
17	dropout2 50% dropout	Dropout
18	fc2 50 fully connected layer	Fully Connected
19	relu_6 ReLU	ReLU
20	dropout3 50% dropout	Dropout
21	fc3 25 fully connected layer	Fully Connected
22	relu_7 ReLU	ReLU
23	dropout4 50% dropout	Dropout
24	globalavgpool1d 1-D global average pooling	1-D Global Average...
25	fc 2 fully connected layer	Fully Connected
26	softmax softmax	Softmax
27	classoutput crossentropyx	Classification Output

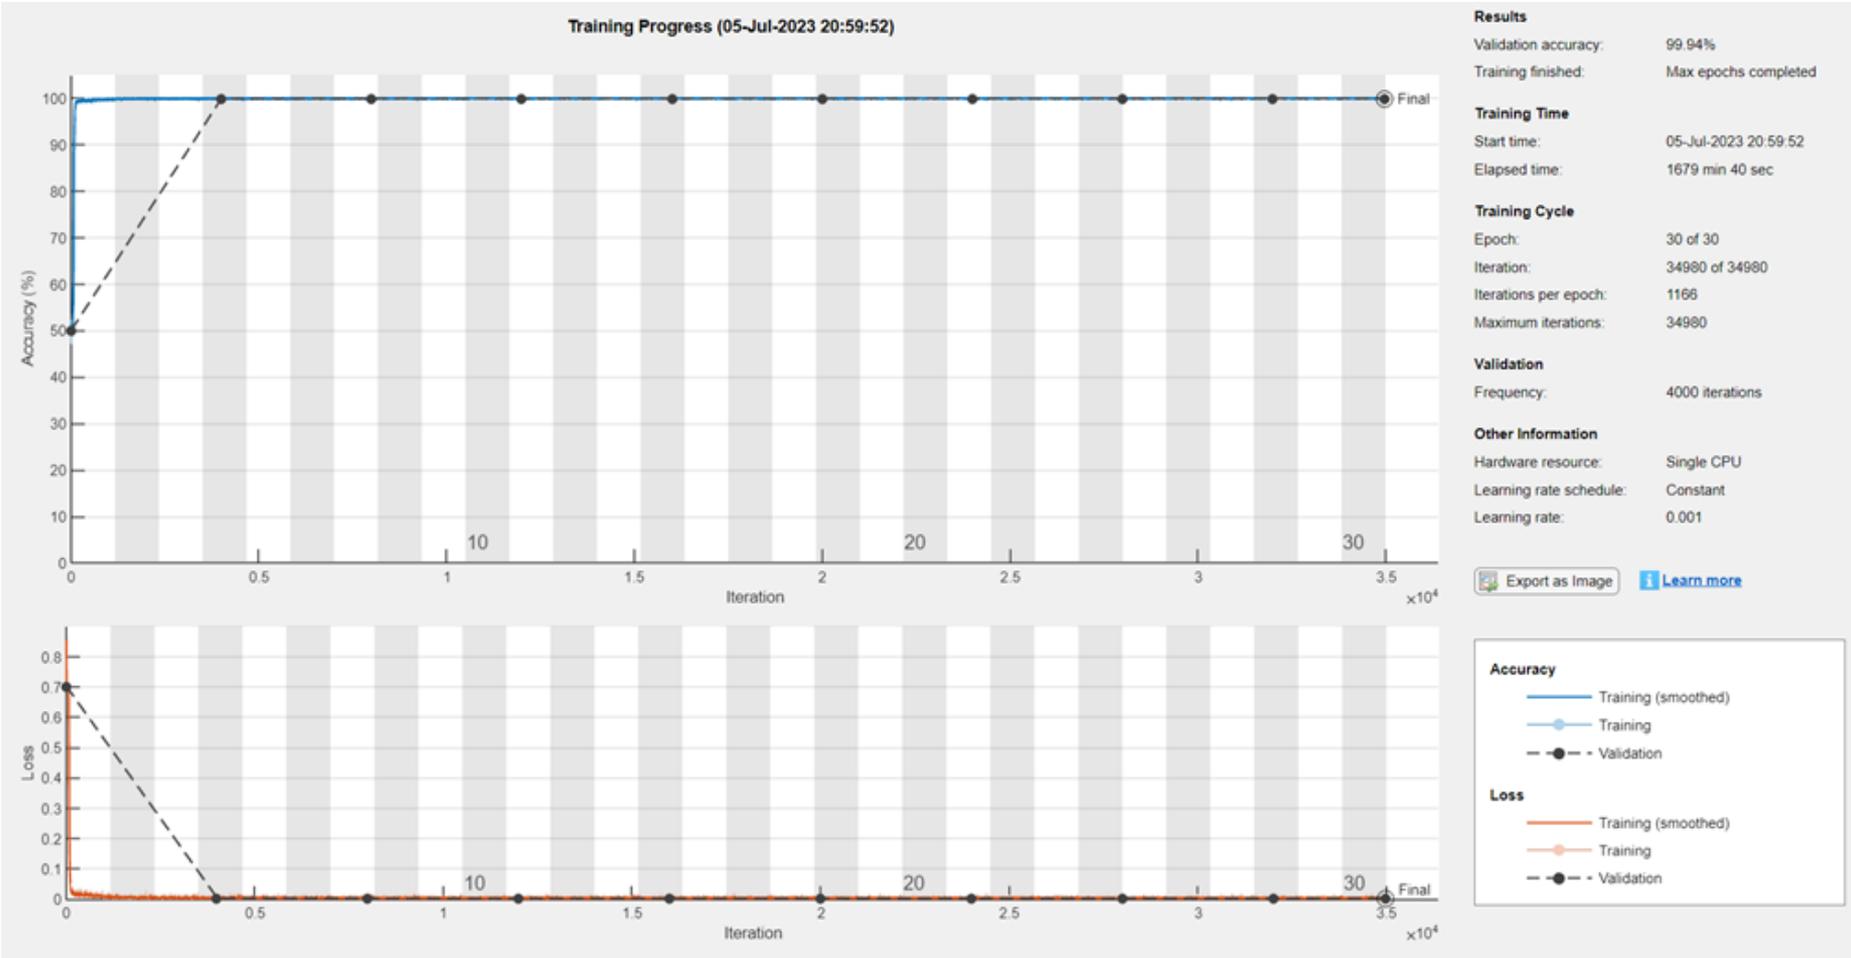


ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

ANALYSIS RESULT			
	Name	Type	Activations
1	data 227x227x3 images with 'zerocenter' nor...	Image Input	227(S) × 227(S) × 3(C) × 1(B)
2	conv1 96 11x11x3 convolutions with stride [4 4...	2-D Convolution	55(S) × 55(S) × 96(C) × 1(B)
3	relu1 ReLU	ReLU	55(S) × 55(S) × 96(C) × 1(B)
4	norm1 cross channel normalization with 5 chan...	Cross Channel Nor...	55(S) × 55(S) × 96(C) × 1(B)
5	pool1 3x3 max pooling with stride [2 2] and pa...	2-D Max Pooling	27(S) × 27(S) × 96(C) × 1(B)
6	conv2 2 groups of 128 5x5x48 convolutions wi...	2-D Grouped Conv...	27(S) × 27(S) × 256(C) × 1(B)
7	relu2 ReLU	ReLU	27(S) × 27(S) × 256(C) × 1(B)
8	norm2 cross channel normalization with 5 chan...	Cross Channel Nor...	27(S) × 27(S) × 256(C) × 1(B)
9	pool2 3x3 max pooling with stride [2 2] and pa...	2-D Max Pooling	13(S) × 13(S) × 256(C) × 1(B)
10	conv3 384 3x3x256 convolutions with stride [1 ...	2-D Convolution	13(S) × 13(S) × 384(C) × 1(B)
11	relu3 ReLU	ReLU	13(S) × 13(S) × 384(C) × 1(B)
12	conv4 2 groups of 192 3x3x192 convolutions ...	2-D Grouped Conv...	13(S) × 13(S) × 384(C) × 1(B)
13	relu4 ReLU	ReLU	13(S) × 13(S) × 384(C) × 1(B)
14	conv5 2 groups of 128 3x3x192 convolutions ...	2-D Grouped Conv...	13(S) × 13(S) × 256(C) × 1(B)
15	relu5 ReLU	ReLU	13(S) × 13(S) × 256(C) × 1(B)
16	pool5 3x3 max pooling with stride [2 2] and pa...	2-D Max Pooling	6(S) × 6(S) × 256(C) × 1(B)
17	fc6 4096 fully connected layer	Fully Connected	1(S) × 1(S) × 4096(C) × 1(B)
18	relu6 ReLU	ReLU	1(S) × 1(S) × 4096(C) × 1(B)
19	drop6 50% dropout	Dropout	1(S) × 1(S) × 4096(C) × 1(B)
20	fc7 4096 fully connected layer	Fully Connected	1(S) × 1(S) × 4096(C) × 1(B)
21	relu7 ReLU	ReLU	1(S) × 1(S) × 4096(C) × 1(B)
22	drop7 50% dropout	Dropout	1(S) × 1(S) × 4096(C) × 1(B)
23	fc 2 fully connected layer	Fully Connected	1(S) × 1(S) × 2(C) × 1(B)
24	softmax softmax	Softmax	1(S) × 1(S) × 2(C) × 1(B)
25	classoutput crossentropyx	Classification Output	1(S) × 1(S) × 2(C) × 1(B)



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA



Ejemplo del resultado de matriz de confusión la red convolucional unidimensional

RESULTADOS

Confusion Matrix

	NO OBJETIVO	SI OBJETIVO	
NO OBJETIVO	299773 50.0%	138 0.0%	100.0% 0.0%
SI OBJETIVO	227 0.0%	299862 50.0%	99.9% 0.1%
	NO OBJETIVO	SI OBJETIVO	
	99.9% 0.1%	100.0% 0.0%	99.9% 0.1%
			Target Class



ÉPOCA	SNR (dBs)	EXACTITUD %	TIEMPO
30	-5 dB	99,939166 %	1679 min 40 seg
	-4 dB	99,989833 %	1758 min 18 seg
	-3 dB	99,997333 %	2134 min 43 seg
	-2 dB	100,00000 %	1958 min 33 seg
	-1 dB	100,00000 %	1975 min 41 seg
	0 dB	100,00000 %	3539 min 36 seg
	5 dB	100,00000 %	1945 min 29 seg
	10 dB	100,00000 %	1815 min 21 seg
	15 dB	100,00000 %	1885 min 55 seg



SNR	TN	FP	FN	TP
-5	299773	227	138	299862
-4	299961	39	22	299978
-3	299992	8	8	299992
-2	300000	0	0	300000
-1	300000	0	0	300000
0	300000	0	0	300000
5	300000	0	0	300000
10	300000	0	0	300000
15	300000	0	0	300000



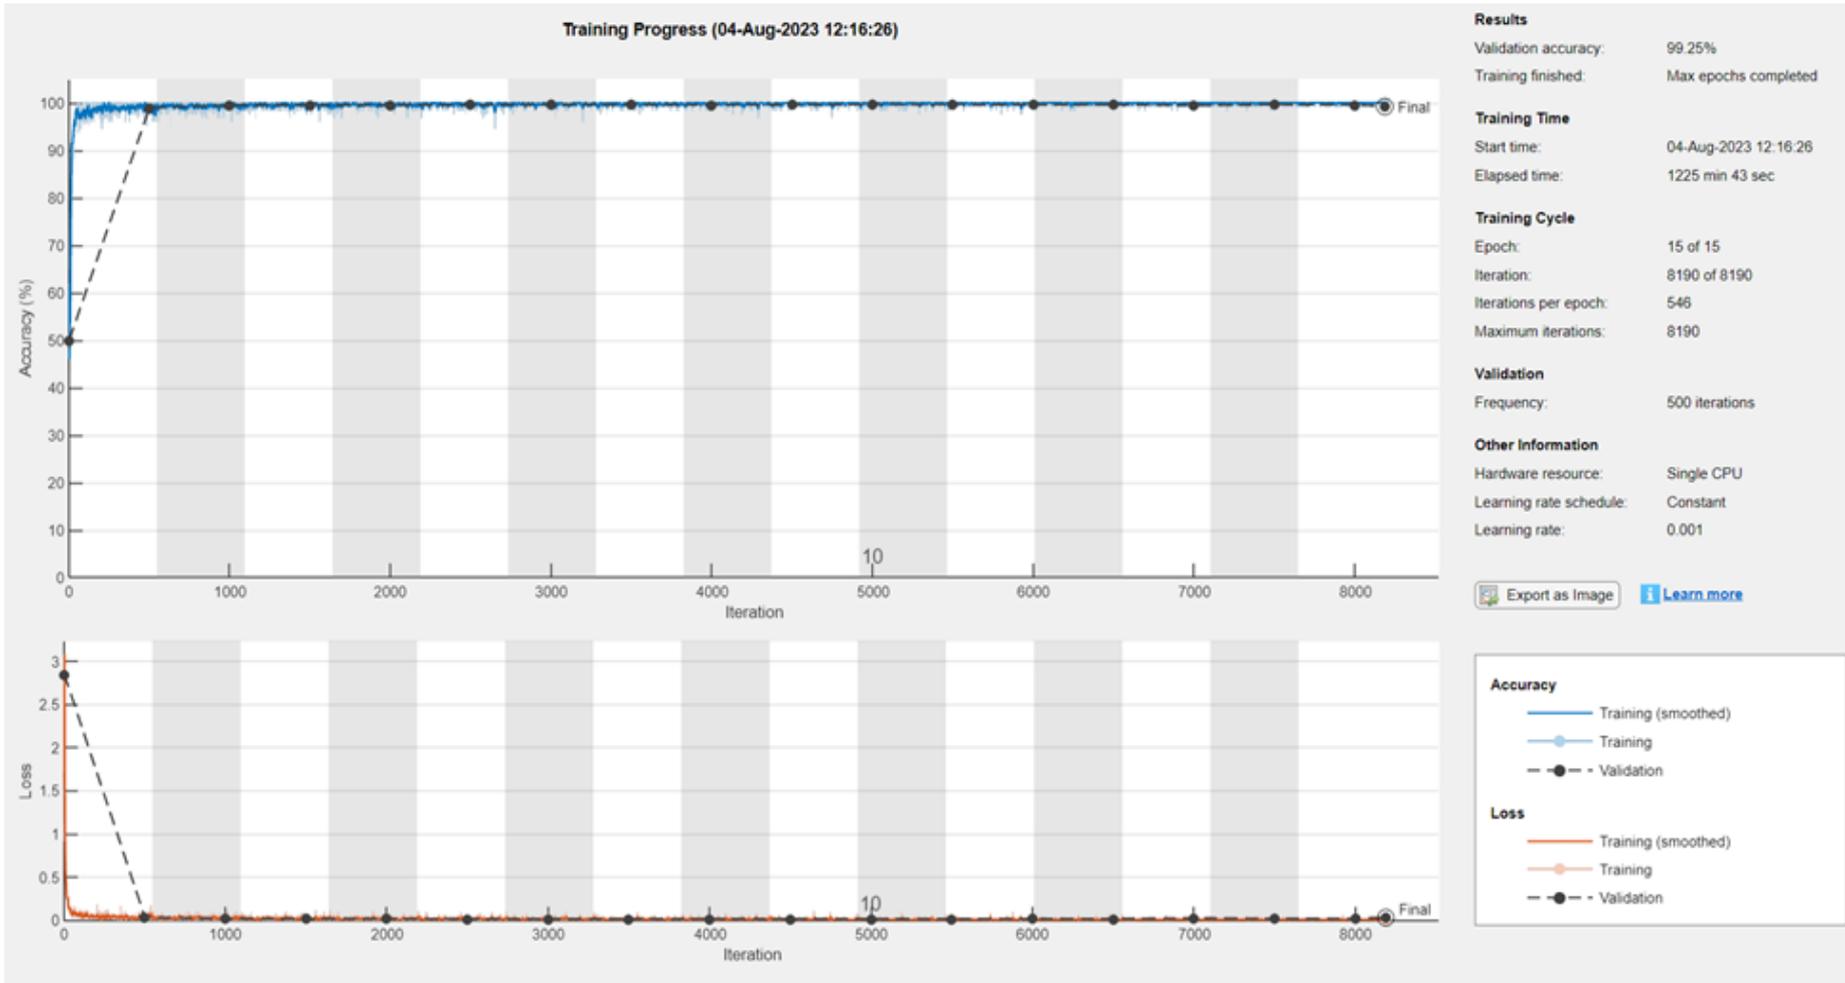
SNR	PRECISIÓN	SENSIBILIDAD	ESPECIFICIDAD	EXACTITUD
-5	99,924355%	99,954000%	99,92433%	99,9391666%
-4	99,987000%	99,992666%	99,987000%	99,9898333%
-3	99,997333%	99,997333%	99,997333%	99,9973333%
-2	100,0000%	100,0000%	100,0000%	100,0000%
-1	100,0000%	100,0000%	100,0000%	100,0000%
0	100,0000%	100,0000%	100,0000%	100,0000%
5	100,0000%	100,0000%	100,0000%	100,0000%
10	100,0000%	100,0000%	100,0000%	100,0000%
15	100,0000%	100,0000%	100,0000%	100,0000%

Probabilidad de falsa alarma% = 100% – Especificidad

Probabilidad de falsa alarma% = 100% – 99,924333333%

Probabilidad de falsa alarma% = 0,07566667%





Ejemplo del resultado de matriz de confusión la red convolucional bidimensional.

RESULTADOS

Confusion Matrix

Output Class	NO OBJETIVO	14791 49.3%	15 0.1%	99.9% 0.1%
	SI OBJETIVO	209 0.7%	14985 50.0%	98.6% 1.4%
		98.6% 1.4%	99.9% 0.1%	99.3% 0.7%
		NO OBJETIVO	SI OBJETIVO	Target Class



ÉPOCAS	SNR (dBs)	EXACTITUD %	TIEMPO
15	-5	99,2533333%	1225min 43 seg
	-4	99.8600000%	1228min 31 seg
	-3	99,9333333%	1223min 49 seg
	-2	99,9933333%	1224min 46 seg
	-1	100.0000000%	1216min 36 seg
	0	100.0000000%	1222min 2 seg
	5	100.0000000%	1270min 49 seg
	10	100.0000000%	1272min 37 seg
	15	100.0000000%	1240min 46 seg



SNR (dBs)	TN	FP	FN	TP
-5	14791	209	15	14965
-4	14990	10	32	14968
-3	14983	17	3	14997
-2	14999	1	1	14999
-1	15000	0	0	15000
0	15000	0	0	15000
5	15000	0	0	15000
10	15000	0	0	15000
15	15000	0	0	15000



SNR	PRECISIÓN	SENSIBILIDAD	ESPECIFICIDAD	EXACTITUD
-5	98,62264%	99,89986%	98,60666%	99,252835%
-4	99,93323%	99,78666%	99,93333%	99,860000%
-3	99,88677%	99,98000%	99,88666%	99,93333%
-2	99,99333%	99,99333%	99,99333%	99,99333%
-1	100,0000%	100,0000%	100,0000%	100,0000%
0	100,0000%	100,0000%	100,0000%	100,0000%
5	100,0000%	100,0000%	100,0000%	100,0000%
10	100,0000%	100,0000%	100,0000%	100,0000%
15	100,0000%	100,0000%	100,0000%	100,0000%

Probabilidad de falsa alarma% = 100% – Especificidad

Probabilidad de falsa alarma% = 100% – 98,606666667%

Probabilidad de falsa alarma% = 1.3933333%



CONCLUSIONES

- Realizando una comparativa entre las redes neuronales convolucionales unidimensionales y bidimensionales se puede concluir que en los parámetros de exactitud, sensibilidad, especificidad y precisión reflejan mejores resultados en las redes convolucionales unidimensionales, en la tabla 2 se evidencia que desde el SNR de -2 dBs hasta 15 dBs las redes unidimensionales obtuvieron un 100% de exactitud y en el SNR más bajo de -5 dBs un 99,94% de exactitud junto con una baja probabilidad de falsa alarma de un 0,0756%, esto en contra posición a las redes bidimensionales las cuales en el SRN más bajo reflejaron un 99,25% y una probabilidad de falsa alarma de un 1.39%. Entre las causas por las cuales las redes convolucionales unidimensionales obtuvieron mayores porcentajes en los parámetros de rendimiento se encuentra la cantidad de datos con los cuales se trabajaron en ambos modelos: para las redes unidimensionales se usaron 2 millones de señales de radar y para las redes bidimensionales 100 mil señales, esto debido a la capacidad computacional y almacenamiento que conlleva generar y entrenar el modelo bidimensional mediante el uso de imágenes.

CONCLUSIONES

- Una de las ventajas del uso de redes neuronales convolucionales unidimensionales en comparación a las bidimensionales es que el modelo se lo puede entrenar y validar con el uso de vectores, en contraste con el modelo bidimensional que obligatoriamente requiere el uso de imágenes; esto se puede solventar mediante el empleo de ordenadores con mayores capacidades computacionales de procesamiento y almacenamiento. Con las características necesarias en un ordenador, en las redes neuronales bidimensionales se pueden aprovechar las redes pre entrenadas junto con herramientas de transfer learning que facilitan el diseño e implementación de los modelos por su arquitectura pre diseñada.
- Comparando los tiempos de entrenamiento y validación de ambos modelos se puede evidenciar que la red convolucional unidimensional empleo un mayor tiempo debido a que se utilizaron una mayor cantidad de datos para este tipo de red; ambas redes se desarrollaron con el uso de una unidad de procesamiento central, pero se recomienda hacer uso de una unidad de procesamiento gráfico ya que el tiempo de entrenamiento y validación de los modelos se reduciría notablemente.

TRABAJOS FUTUROS

- Entre los trabajos futuros se espera continuar con una constante preparación en el campo del aprendizaje profundo, indagando de igual manera en el aprendizaje automático con la finalidad de poder hacer uso de estas técnicas y orientarlas a solucionar varias problemáticas en el campo de las telecomunicaciones y en la detección de objetos en señales de radar, desarrollando diferentes tipos de redes y modelos para analizar la respuesta de todos y poder compararlos.

**GRACIAS POR
SU ATENCIÓN**



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA