

Conformador De Imagen Ultrasónica Basado En Redes Neuronales

**Óscar Martínez-Graullera, Carolina Bertoncini, Luis Elviraa,
Montserrat Parrilla, Alberto Ibáñez**


Instituto de Tecnologías Físicas y de la Información
Consejo Superior de Investigaciones Científicas

June 18, 2024


TECNIACUSTICA 2023 . CUENCA

Agradecimientos: PID2022-138013OB-I00/ MCIN/AEI/10.13039/501100011033/FEDER, UE y PID2019-111392RB-I00/ MCIN/AEI/10.13039/501100011033/; ISABEL-202150E058


Estructura de un conformador de haz




Estructura de un conformador de haz



Estructura de la Red Neuronal



Redes Neuronales Profundas



Redes Neuronales Profundas


Posibles objetivos:

1. Clasificación de reflectores: mapa de probabilidades
2. Reducir el impacto de la difracción en la imagen manteniendo la resolución lateral.


Puntos clave del diseño de un conformador DNN

1. La información de entrada
2. La estructura de la red
3. La base de aprendizaje

La información de entrada. Apertura sintética



La información de entrada. Prefocalización.



Full Matrix Capture

$$FMC(\vec{x}) : \left\{ s_{ij}(\tau), \tau = \frac{x - x_i}{c} + \frac{x - x_j}{c} \quad \forall i = 1 \dots N, j = 1 \dots N \right\}$$

La información de entrada. Hipotesis de reflectividad

$$s_{ij}(\tau) = m(\vec{x}) + n_{ij}(\tau)$$

Delay and sum:


$$DAS = \left| \sum_i^N \sum_j^N s_{ij}(\tau) \right| = \left| N^2 m(\vec{x}) + \sum_i^N \sum_j^N n_{ij}(\tau) \right|$$

Estima de la reflectividad:

$$\hat{m}(\vec{x}) = \frac{DAS}{N^2} = \left| m(\vec{x}) + \frac{\sum_i^N \sum_j^N n_{ij}(\tau)}{N^2} \right|$$


Podemos minimizar el término de ruido?

La información de entrada. Matriz de emisión/recepción



64 linear array 3MHz BW: 50%



Estimador del comportamiento de baja frecuencia



16 linear array 3MHz BW: 50%. I (red) + Q (blue)


1. ecos desde el reflector.
2. ecos desde el radio del reflector y cerca angularmente.
3. ecos desde posiciones cercanas al reflector fuera de su radio
4. ecos desde una región ajena al reflector

Estimador del comportamiento de baja frecuencia




64 linear array 3MHz BW: 50%

La información de entrada. matriz de emisión/recepción



64 linear array 3MHz BW: 50%


Estructura de la red



TensorFlow (Keras). Modelo de regresión. La red necesita estimar 5.889 coeficientes.

Base de aprendizaje

Escena global



Base de aprendizaje


Modelo:

- ▶ Array 64 elementos.
- ▶ SNR 20dB
- ▶ 12 reflectores entre 0dB y -30dBs


Aprendizaje:

- ▶ 1001 escenas generales aleatorias
- ▶ Imágenes de 64x64
- ▶ Distinta resolución espacial
- ▶ Distinta distribución y número de reflectores
- ▶ La imagen se resuelve pixel a pixel
- ▶ Diez ciclos de aprendizaje por imagen


Base de aprendizaje




Base de aprendizaje



Base de aprendizaje



Resultados experimentales



Phased array 64 elements. 2.6MHz, CIRS 040GSE

Conclusiones: DNN beamformer

Resultados:

- ▶ Identifica y elimina la región de lóbulos secundarios.
- ▶ Aumenta la resolución lateral
- ▶ Mejora el contraste en la imagen

En desarrollo:

- ▶ Es posible mejorar la resolución axial? (deconvolución)
- ▶ Corregir el "borrado" de los blancos dudosos.
- ▶ Implementación.