

Estimadores de Posición 2D Mediante Redes Neuronales en Detectores de Radiación γ para PET

Ramón José Aliaga*, Jorge Daniel Martínez*, Rafael Gadea*, Ángel Sebastián*, Jose María Benlloch†

*Departamento de Ingeniería Electrónica

Universidad Politécnica de Valencia, Camino de Vera s/n, 46022 Valencia (Spain)

†Grupo de Física Médica Nuclear

Instituto de Física Corpuscular, CSIC-Universitat de València, Edif. Institutos Paterna

Abstract— This paper studies the use of Neural Networks (NNs) for position estimation in PET γ -ray detectors. We focus on bidimensional positioning for sensors based on scintillators and Position Sensitive Photomultiplier Tubes (PS-PMTs). Concretely, the detector under study is composed of a $49 \times 49 \times 10 \text{ mm}^3$ LSO continuous crystal optically coupled to the flat panel H8500 multi-anode PMT. We have performed a thorough analysis of the NN architecture and training procedures using the GEANT4 simulation toolkit in order to reach the best results in terms of spatial resolution and bias correction. Thus, we show how NNs can partially model and correct the non-uniform detector response using only the four position-weighted signals from simple charge division networks. Finally, the designed NN has been implemented in an FPGA for real time pre-corrected Line-of-Response (LOR) estimation at high count rates.

I. INTRODUCCIÓN

La tomografía por emisión de positrones (PET, *Positron Emission Tomography*) es una técnica de imagen médica funcional que está adquiriendo una importancia creciente dada su extraordinaria sensibilidad. Los escáneres PET nos facilitan imágenes de la distribución de la concentración de un determinado radiofármaco en el interior del cuerpo humano. Para ello se detecta la radiación generada tras la desintegración β^+ de un radionúcleo inestable empleado como marcador de la sustancia de interés (e.g. $^{18}\text{F} - \text{FDG}$ es comúnmente empleado como marcador de la glucosa para la detección de células cancerígenas).

La partícula β^+ (positrón) emitida por el radioisótopo recorre una distancia muy reducida antes de aniquilarse con un electrón, produciéndose la conversión de toda su masa en energía y dando lugar a la emisión de 2 fotones γ de 511 keV prácticamente colineales en sentidos contrarios. La detección en coincidencia temporal de ambos fotones en dos módulos detectores opuestos nos permite definir una línea de respuesta (LOR, *Line of Response*) a lo largo de la cuál se ha producido la desintegración radioactiva. La información de todas estas LORs es utilizada posteriormente para generar la imagen mediante técnicas de reconstrucción tomográfica.

La obtención del punto de incidencia en cada módulo detector (los extremos de la LOR correspondiente a cada desintegración) es un aspecto crítico en el diseño de detectores PET de alta resolución. Existen diversas aproximaciones aunque el método más sencillo es el basado en la obtención del centroide de la distribución de luz de centelleo empleado

ya en la cámara de centelleo original de Hal Anger [1]. Sin embargo esta técnica requiere de mapas de corrección obtenidos mediante una calibración exhaustiva del detector para corregir los efectos no lineales presentes en este proceso: comportamiento espacial no uniforme, diferencias en las ganancias de cada fotomultiplicador o la incapacidad de preservar la forma de la distribución de luz conforme el punto de interacción se acerca progresivamente a los bordes. Todos estos fenómenos implican habitualmente una reducción en la resolución así como la aparición de artefactos en la imagen y la compresión no uniforme de ésta. La principal consecuencia es la reducción del campo de visión útil (UFOV, *Useful Field of View*) de la cámara PET. Esto último es si cabe más restrictivo en el diseño de detectores de pequeña área donde la maximización del UFOV constituye una prioridad irrenunciable. Otros esquemas de posicionamiento han sido desarrollados con el objetivo de evitar los errores sistemáticos presentes en la estimación basada en el centroide [2], [3]. Sin embargo, todos ellos requieren de una modelización no menos exhaustiva del detector y de tiempos de procesado por evento de varias decenas de μs en PCs de propósito general.

En este trabajo estudiamos el uso de redes neuronales para la estimación de la posición en detectores de rayos γ aplicados a imagen médica nuclear. Las redes neuronales pueden ser entrenadas de manera que modelen la respuesta real del detector mediante un proceso de aprendizaje previo siguiendo un proceso de calibración sencillo. Además, la posibilidad de implementación sobre dispositivos programables nos permite disponer de estimaciones corregidas del punto de incidencia en tiempo real con tiempos de procesado inferiores a los 100 ns . Existen investigaciones previas para detectores basados en PMTs [4] y APDs [5], sin embargo nuestro análisis se centra en el uso de cristales centelleadores continuos y tubos fotomultiplicadores multi-ánodo (MA-PMT) en configuración flat-panel.

La estructura del artículo es la siguiente: en la Sección II se expondrán los métodos y materiales empleados tanto durante la simulación como en la validación de los resultados. La Sección III introduce los fundamentos de las redes neuronales y su aplicación a la estimación de posición en detectores de rayos γ . A continuación, las secciones IV y V analizan respectivamente el proceso de optimización de la red neuronal con el objetivo de encontrar una arquitectura adecuada y los

resultados obtenidos con la red neuronal implementada. Por último se expondrán las principales conclusiones.

II. MÉTODOS

Se ha realizado un análisis minucioso del estimador de posición basado en redes neuronales empleando el paquete de simulación GEANT4 [9]. El entrenamiento, en modo supervisado, y la posterior validación de las redes se realizaron con el Neural Networks Toolbox de MATLAB, siguiendo el algoritmo RPROP [10].

II-A. Características del detector

El módulo detector empleado consta de un cristal de LSO de $49 \times 49 \times 10 \text{ mm}^3$ (del tamaño de la ventana de entrada del fotomultiplicador) acoplado a un MA-PMT H8500 de Hamamatsu. El H8500 es un fotomultiplicador de tipo *flat-panel* compuesto de una matriz de 8×8 ánodos cubriendo una superficie de $49 \times 49 \text{ mm}^2$. Las cinco caras externas del cristal se han considerado pulidas y pintadas con material absorbente para preservar la forma de la distribución de luz, aunque se ha considerado un 5% de reflexión en las mismas. La producción de luz en el centelleador y la resolución intrínseca en energía han sido fijadas a valores conservadores para el LSO.

El H8500 se ha acoplado al cristal de LSO mediante una capa de grasa óptica de 0,2 mm. Se ha modelado también la ventana de entrada de borosilicato del H8500 de 2 mm de grosor. El espectro de emisión del LSO ha sido considerado monocromático centrado en 420 nm que se corresponde con la longitud de onda de máxima emisión del cristal centelleador. El circuito de *read out* del fotomultiplicador está compuesto por una red de resistencias para la división de la carga generada por cada ánodo del fotomultiplicador del tipo *Discretized Positioning Circuits* (DPC) [6]. Éste nos permite reducir el número de canales de 64 (uno por cada ánodo del H8500) a sólo 4.

II-B. Simulación

Basándonos en el modelo de detector anterior se han simulado, empleando GEANT4, tanto la emisión de fotones gamma desde una fuente puntual como los fenómenos de transporte en el interior del centelleador (scatter Compton y absorción fotoeléctrica), la ionización de los electrones y la consiguiente emisión de fotones ópticos así como el proceso de recolección de la luz desde el centelleador hasta el fotocátodo.

III. ESTIMADOR DE POSICIÓN

Sea S una fuente puntual de fotones γ situada en (x_s, y_s, z_s) y colimada en la dirección perpendicular a la superficie del detector, la interacción de un fotón en el detector puede ser vista como la realización de una variable aleatoria $X \rightarrow \mathbf{A}$ con \mathbf{A} el vector de elementos a_i igual al número de fotones de centelleo que llegan a cada pad del MA-PMT.

Las entradas de la red neuronal reciben un vector \mathbf{J} siendo

$$J_k = \sum_i A_i \cdot G_i \cdot R_{i,k} \quad (1)$$

la salida k -ésima de la red de división de carga, \mathbf{G} el vector de ganancias normalizado de cada pad del PMT y $R_{i,k}$ la función de transferencia de corriente desde el pad i -ésimo del fotomultiplicador hasta la k -ésima salida de la red de división de carga.

Según el Teorema de Aproximación Universal [7], puede probarse que cualquier función continua, definida sobre una región acotada, puede ser aproximada uniformemente con precisión arbitraria por un Perceptrón Multicapa (MLP) de dos capas ocultas (ver Apéndice). Nuestro objetivo es por tanto conseguir un estimador de posición del tipo

$$\hat{\mathbf{r}} = \Phi\{\mathbf{J}; W, b\} \quad (2)$$

donde W y b son los pesos y umbrales de cada una de las neuronas que integran la red. Para conseguir que una estructura de red neuronal fija se adapte a la inversa de una determinada función f , partiremos de un conjunto de entrenamiento formado por pares (X_i, J_i) , donde $X_i = (x_i, y_i)$ es la posición de la fuente puntual y J_i una realización de las salidas de la red DPC para la posición de fuente X_i , con $J_i = f(X_i)$. Entonces se modifican los pesos y umbrales de la red siguiendo un algoritmo *backpropagation* de descenso de gradiente para minimizar el error cuadrático medio

$$E = \frac{1}{2} \sum_i \|X_i - F(J_i)\|^2 \quad (3)$$

donde F es la función de transferencia de la red. Los valores iniciales de los pesos y umbrales suelen determinarse según la regla de Nguyen-Widrow [8].

IV. OPTIMIZACIÓN

IV-A. Posicionamiento 1D

Con el objetivo de seleccionar una arquitectura de red neuronal adecuada hemos evaluado en primer lugar las prestaciones de este tipo de estimadores en el caso del posicionamiento unidimensional. Para ello se han unido los ánodos de cada columna del detector, y se ha considerado un circuito de división de corriente resistivo con 8 entradas, una para cada columna de ánodos, y dos salidas. Se ha realizado un barrido del eje x en pasos de 1 mm, simulándose un total de 10000 eventos por posición. La ventana de energía para la selección de eventos válidos, con el objetivo de evitar la presencia de fotones que no hubiesen depositado toda su energía en el detector, se fijó en el 20% centrada en el fotopico de 511 keV.

Concretamente, se han simulado MLPs de una, dos y tres capas ocultas con hasta 16 neuronas en total. Para cada caso, se realizaron 100 entrenamientos distintos cada uno con distintas ganancias en cada uno de los ánodos (escogidas según una distribución de probabilidad uniforme en un ratio 1 : 3) y con un subconjunto distinto de 500 eventos por posición para el entrenamiento supervisado. Los parámetros de evaluación fueron el error sistemático medio y la resolución FWHM (*Full Width-Half Maximum*) media en cada punto, así como la desviación típica de los mismos a lo largo de los 100 entrenamientos.

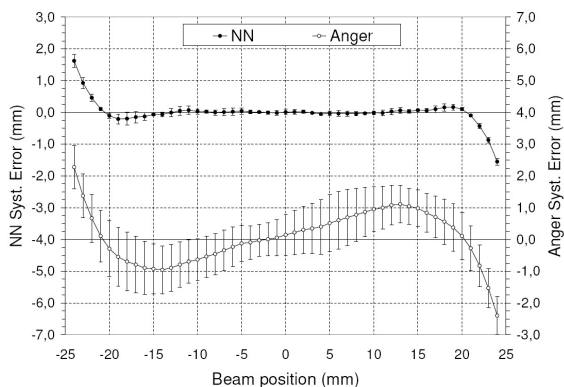


Fig. 1. Error sistemático en función de la posición de la fuente.

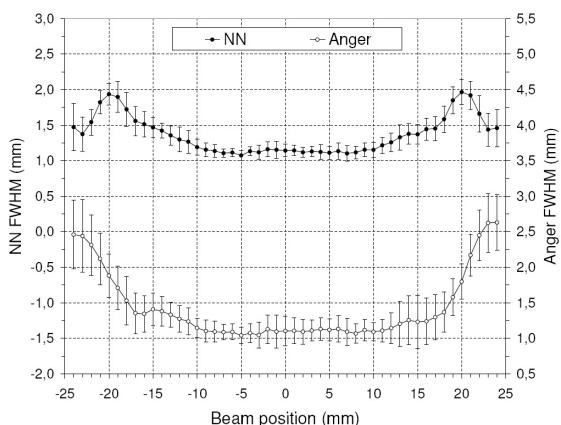


Fig. 2. Resolución espacial en función de la posición de la fuente.

Se ha observado que, para un mismo número de neuronas, la segunda capa oculta aumenta considerablemente la resolución mientras que la tercera añade demasiada complejidad a la red sin mejorar significativamente los resultados. Así mismo, para una configuración con dos capas ocultas, un aumento de la segunda capa mejora la linealidad de la respuesta, reduciendo el error sistemático, mientras que un aumento de la primera capa disminuye el FWHM, aumentando así la resolución. La red neuronal escogida finalmente se compone de dos capas ocultas de 9 y 4 neuronas, respectivamente. Un aumento de las mismas por encima de estos valores apenas representan una mejora. Los resultados obtenidos con una red 2/9/4/1 se muestran en la Figuras 1 y 2.

IV-B. Posicionamiento 2D

Para la evaluación del posicionamiento bidimensional, se ha desplazado la fuente de radiación a lo largo de una malla de 49×49 puntos separados 1 mm, simulando un total de 2000 fotones γ detectados en cada posición. Del mismo modo, se han fijado una ventana de energía del 20% en torno al fotopico. Las redes han sido entrenadas con 100 eventos por posición, y para cada caso se han realizado 50 entrenamientos distintos.

Se nos plantean dos alternativas para el posicionamiento

TABLA I
RESULTADOS SOBRE XILINX X2VP7FG456-7

| | MLP $2 \times 4/9/4/1$ | MLP $1 \times 4/15/8/2$ |
|--------------|------------------------|-------------------------|
| LUTs: | 1026 de 9,856 (10%) | 1040 de 9,856 (10%) |
| Slices: | 838 de 4,928 (17%) | 813 de 4,928 (16%) |
| Flip-Flops: | 1268 de 9,856 (12%) | 1134 de 9,856 (11%) |
| Block RAMs: | 6 de 44 (13%) | 3 de 44 (6%) |
| Mult. 18x18: | 28 de 44 (63%) | 25 de 44 (56%) |
| f_{max} : | 195 MHz | 195 MHz |
| Cadencia: | 61,5 ns (16,3 MHz) | 92,3 ns (10,8 MHz) |
| Latencia: | 195 ns | 292 ns |

bidimensional: una única red neuronal, con cuatro entradas y dos salidas, o bien dos redes neuronales independientes para el posicionamiento en cada coordenada, cada una con el tamaño determinado anteriormente (4/9/4/1) pero con cuatro entradas dado que ahora tenemos un circuito DPC completo que transforma los 64 pixels del H8500 en 4 canales cuyas corrientes de salida están relacionadas linealmente con el centroide de la distribución de luz.

En el caso de una única red neuronal, se han simulado redes MLP de hasta 25 neuronas en las capas ocultas siendo el tamaño óptimo alcanzado 4/15/8/2, a partir del cual no se aprecian mejoras significativas ni en resolución ni en corrección del error sistemático.

Cada entrenamiento de las redes objeto de estudio, con 100 eventos por cada posición de incidencia, requirió aproximadamente 30 minutos en un servidor Sun Fire V20z con 2 procesadores AMD Opteron y 4 GB de memoria RAM.

IV-C. Implementación

Finalmente, han sido implementadas las dos redes neuronales en FPGA sobre un dispositivo Virtex-II Pro de Xilinx. Para minimizar la ocupación de recursos, dado que el estimador de posición debe integrarse en el sistema de adquisición de datos del escáner ya existente, se ha tomado la decisión de entrenar la red *off-line* y posteriormente reconfigurar la FPGA con los pesos y umbrales adecuados. La estructura de red diseñada requiere un multiplicador por cada neurona, que en cada ciclo multiplica una de las entradas por su peso correspondiente. Debido a la precisión requerida a la salida, la única opción para la implementación de la función sigmoide ha sido una memoria ROM que es compartido por todas las neuronas lo que reduce drásticamente los recursos empleados.

La ejecución de cada capa requiere $N + 3$ ciclos de reloj, donde N es el tamaño de la capa más grande. La red está segmentada para aceptar un nuevo vector de entrada cada $N + 3$ ciclos minimizando el posible *deadtime*. La Tabla I recoge el uso de recursos de las distintas arquitecturas de red que hemos considerado, así como su velocidad de operación. La implementación se ha llevado a cabo con entradas y salidas de datos de 12 bits (correspondientes al número de bits de los convertidores analógico-digital del sistema de adquisición de datos) y una precisión interna de 12 bits fraccionarios.

Como puede observarse, las redes 4/9/4/1 son capaces de procesar hasta 16,3 *Meventos/s* lo que permite soportar las tasas de evento más elevadas de los sistemas PET existentes

con la finalidad ya sea de aumentar la sensibilidad minimizando el *deadtime* ya de disminuir la dosis inyectada o reducir el tiempo de exploración.

V. RESULTADOS

La validación de la red neuronal implementada se ha llevado a cabo mediante la obtención de un histograma de posicionamiento 2D (la función de dispersión del punto) en una malla de 9×9 puntos separados 5 mm entre sí. Los resultados del posicionamiento con dos MLP $4/9/4/1$ y mediante el método del centroide sin mapas de corrección se muestran en la Figura 3.




Fig. (a)

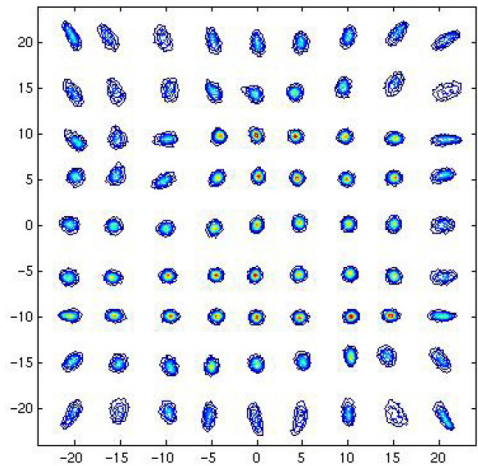


Fig. (b)

Fig. 3. Histograma de posiciones 2D (a) Centroide (b) MLP.

Puede observarse como el posicionamiento mediante la red neuronal corrige los artefactos de compresión en los bordes aumentando el UFOV a la vez que disminuye el error sistemático en la zona de interés.

VI. CONCLUSIONES

Las redes neuronales representan una buena aproximación para la estimación de posición corregida y de alta resolución en detectores de rayos γ para aplicaciones de imagen

médica nuclear. Concretamente, hemos mostrado cómo los detectores basados en cristales continuos y MA-PMTs pueden beneficiarse ampliamente de estimadores de posición basados en redes neuronales para modelar la respuesta del detector y corregir sus no linealidades permitiendo una reconstrucción de la posición en tiempo real. Además, los resultados presentados en este artículo animan la posibilidad de ampliar este enfoque a la obtención de la profundidad de interacción en el cristal lo que permitiría una reconstrucción precisa y completamente 3D del punto de interacción en el interior del centelleador.

APÉNDICE

Las redes neuronales están constituidas por elementos sencillos de cálculo denominados *neuronas*. Su estructura interna se compone de una o varias capas de estos elementos operando en paralelo, de modo que los valores de salida de las neuronas de una capa se usan como entradas de las neuronas de la capa siguiente. Usaremos la notación $M/N_1/\dots/N_k$ para hacer referencia a una red con M entradas y N_i neuronas en la i -ésima capa.

A. Perceptrón Multicapa

Una de las arquitectura de red neuronal más extendida es el Perceptrón Multicapa (MLP). En un MLP, cada neurona evalúa una determinada función lineal de sus entradas y después transforma ese valor por medio de una función no lineal φ generalmente de tipo sigmoide para reducir el rango de variación de su salida. Así, la función de transferencia de una neurona de N entradas (x_1, \dots, x_N) es

$$F(x_1, \dots, x_N) = \varphi \left(\sum_{i=1}^N w_i x_i + b \right) \quad (4)$$

donde w_i son los *pesos* y b es el *umbral* de la neurona.

REFERENCIAS

- [1] H. Anger, "Scintillation camera", *Rev. Sci. Inst.*, 29(1), pp. 27-33, 1958.
- [2] J. Joung, *et al.*, "Investigation of bias-free positioning estimators for the scintillation cameras", *IEEE Trans. Nucl. Sci.*, vol.48, no.3, pp. 715-719, 2001
- [3] Y.H. Chung, *et al.*, "Evaluation of Maximum-Likelihood position estimation with poisson and gaussian noise models in a small gamma camera", *IEEE Trans. Nucl. Sci.*, vol.51, no.1, pp. 101-104, 2004.
- [4] A.M. Bronstein, *et al.*, "Optimal nonlinear line-of-flight estimation in positron emission tomography", *IEEE Trans. Nucl. Sci.*, vol.50, no.3, pp.421-426, 2003.
- [5] P. Bruyndonckx, *et al.*, "Neural network-based position estimators for PET detectors", *IEEE Trans. Nucl. Sci.*, vol.51, no.5, pp.2520-2525, 2004.
- [6] S. Siegel, *et al.*, "Simple charge division readouts for imaging scintillator arrays using a multi-channel PMT", *IEEE Trans. Nucl. Sci.*, vol.43, no.3, pp.1634-1641, 1996.
- [7] S. Haykin, *Neural Networks: A Comprehensive Foundation*, Upper Saddle River, NJ: Prentice-Hall, 1999.
- [8] D. Nguyen and B. Widrow, "Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights", *Proceedings of the International Joint Conference on Neural Networks*, vol. 3, pp.21-26, 1990.
- [9] S. Agostinelli *et al.*, "GEANT4: A Simulation Toolkit", Stanford Linear Accelerator Center, Stanford Univ., Stanford, CA, SLAC Rep. SLAC-PUB-9350, 2002.
- [10] M. Riedmiller and H. Braun, "A direct adaptive method for faster backpropagation learning: The RPROP algorithm", *Proceedings of the IEEE International Conference on Neural Networks*, 1993.