

# Capítulo 21

## Métodos de Soft Computing para la Estimación no Invasiva de la Temperatura en Medios Multicapa Empleando Ultrasonido Retrodisperso

CESAR A. TEIXEIRA<sup>1</sup>, WAGNER C. DE ALBUQUERQUE<sup>2</sup>, MARÍA G. RUANO<sup>1</sup> Y ANTÓNIO E. RUANO<sup>1</sup>

<sup>1</sup>Centro de Sistemas Inteligentes, Facultad de Ciencias y Tecnología, Universidad de Algarve, Portugal.

<sup>2</sup>Programa de Ingeniería Biomédica-COPPE, Universidad Federal de Río de Janeiro, Brasil.

La seguridad y eficacia de las terapias térmicas están ligadas con la determinación exacta de la temperatura, es por ello que la retroalimentación de la temperatura en los métodos computacionales es de vital importancia. En algunas modalidades terapéuticas solamente se aplica terapia en una región delimitada, y se debe ser muy cuidadoso para evitar efectos no deseados sobre el tejido circundante. En medios multicapa, la temperatura debe determinarse considerando todos los componentes del medio, capas e interfaces. La medida directa de la temperatura no es el mejor procedimiento porque la perforación, tanto de los tejidos enfermos como de los sanos, es necesaria para la ubicación correcta de los sensores. La elaboración exacta de mapas de temperatura no invasivos en tiempo y espacio mejoraría significativamente el uso de estas terapias, y conllevaría al desarrollo de instrumentación de control. En este capítulo, se propone el método de retroalimentación de la temperatura mediante una técnica no invasiva de ultrasonido retrodisperso usando las técnicas de soft-computing (redes neuronales de funciones de base radial (RBFNN, por sus siglas en inglés: radial basis functions neural networks) y algoritmos genéticos multi-objetivo). Se desarrolló, *ex profeso*, un phantom de tres capas a base de agar-agar y mediante la aplicación de ultrasonido terapéutico (UST) se incrementó la temperatura.

Tanto en las diferentes capas como en sus interfases, se logró para todos los puntos sensados y todas las intensidades de ultrasonido aplicadas, una exactitud menor a 0.5 °C. La metodología propuesta considera la estimación de las temperaturas en puntos múltiples y a varias intensidades de ultrasonido, con el propósito de desarrollar controladores de temperatura prácticos. Hasta donde tenemos conocimiento, ésta es la primera propuesta de valoración mediante una técnica no invasiva en medios multicapa que emplean ultrasonido tanto para su aplicación terapéutica como para su estimación.

## Introducción

El valor de la temperatura, tanto en tiempo como espacio, es un factor de primordial importancia para que las terapias térmicas aplicadas a tejidos biológicos sean seguras y eficaces. Actualmente, la temperatura se puede medir de forma no invasiva en los puntos de interés; sin embargo, sólo se puede monitorear un número limitado de puntos para evitar el daño excesivo originado por la inserción de los sensores en los tejidos. Además, si se aplica radiación, los sensores actúan como dispersores, no deseados, de la misma. Esta restricción puede comprometer la cantidad de información necesaria para un uso correcto de la terapia. Una alternativa atractiva para abordar este problema es el uso de métodos no invasivos de valoración de la temperatura. En (Arthur *et al.*, 2005) se puntualiza que es deseable tener una resolución de 0.5 °C en 1 cm<sup>3</sup> para hipertermia/diatermia.

Se han divulgado diversas técnicas basadas en tomografía eléctrica de la impedancia (Paulsen *et al.*, 1996), radiometría por microondas (Meaney y Paulsen 1996), imagen de resonancia magnética (MRI, por sus siglas en inglés: magnetic resonante imaging) (Hynynen *et al.*, 1996), y ultrasonido retrodisperso (BSU, por sus siglas en inglés: backscattered Ultrasound) para la valoración de la temperatura mediante técnicas no invasivas. La MRI es probablemente la única tecnología actual capaz de proveer una valoración con la exactitud y la resolución espacial de 0.5 °C en 1 cm<sup>3</sup> que es la deseada para hipertermia/diatermia (Arthur *et al.*, 2005). Sin embargo, la instrumentación de la MRI es relativamente costosa y puede ser difícil o imposible su aplicación en algunas terapias.

La opción de la técnica BSU para la estimación de la temperatura tiene algunos aspectos interesantes. El ultrasonido es una forma de energía no ionizante, de instrumentación barata y requisitos simples de procesamiento de señales (Arthur *et al.*, 2005). Los métodos ultrasónicos de la termometría se pueden agrupar en cuatro categorías, según la característica dependiente de temperatura extraída de las señales de BSU: los basados en el desplazamiento del eco temporal (TES, por sus siglas en inglés: temporal echo-shifts) debido al cambio en la velocidad media del sonido y la expansión del medio (Simon *et al.*, 1998); los basados en desplazamientos de frecuencia en las componentes espectrales de las señales de BSU, también debido(s) al cambio en la velocidad media del sonido y la expansión del medio (Amini *et al.*, 2005); los que analizan los desplazamientos en el coeficiente de atenuación acústico dependiente de la frecuencia (Ueno *et al.*, 1990); y, finalmente, los que miden los desplazamientos en la energía retrodispersada en inhomogeneidades del tejido (Arthur *et al.*, 2003).

Los métodos por desplazamiento en el coeficiente de atenuación son más apropiados para las temperaturas superiores 50 °C; mientras que los de desplazamiento temporal de los ecos, los de desplazamiento frecuencial y los de cambio en la energía retrodispersada son convenientes para temperaturas en el intervalo de la hipertermia (41-45 °C) (Arthur *et al.*, 2005). Los métodos mencionados anteriormente se han concentrado esencialmente en medios homogéneos *in-vitro*, y asumieron una relación lineal entre la característica extraída y la temperatura.

Este capítulo presenta un método no lineal y no invasivo para medir la temperatura de un medio de capas múltiples, aplicado a un phantom a base de agar-agar de tres capas calentado por ultrasonido terapéutico. Las redes neuronales de base radial (RBFNN, por sus siglas en inglés) se aplicaron, en la forma de estructuras autorregresivas con entradas exógenas (NARX), para la estimación

no invasiva de temperatura. Las estructuras de RBFNN fueron optimizadas usando el algoritmo genético para varios objetivos (MOGA, por sus siglas en inglés: multi-objective genetic algorithm) (Fonseca y Fleming 1993).

Las estructuras de NARX se optimizan para un correcto comportamiento en los puntos dentro de cada capa y en las interfaces, para ser bien condicionados, y para minimizar la complejidad de cómputo (esencial para las aplicaciones en tiempo real). Las variables de entrada consideradas son los últimos valores de la temperatura y los desplazamientos temporales de eco computados (TES) de las señales de BSU.

Este trabajo es una continuación de los resultados acertados obtenidos con la misma estrategia de valoración en medios homogéneos (Teixeira et al., 2006; Teixeira et al., 2008).

## 21.2 Disposición experimental y adquisición de datos

La Figura 21.1 presenta la disposición experimental usada para la adquisición de datos.

Según lo mencionado previamente, el phantom construido a base de agar presenta tres capas; dos de ellas compuestas por (cantidades en % del peso total) 86.5% de agua desgasificada y desionizada, 11 % de glicerina, y 2.5% de agar. La capa intermedia (que contiene grafito) fue obtenida agregando grafito en polvo en una proporción del 2% del peso del agua a la composición antes mencionada, como se ve en las Figuras 21.1 y 21.2. Cinco termopares fueron colocados a lo largo del eje del transductor terapéutico, tres dentro de cada capa y dos en las interfaces. En la región axial es donde ocurre el calentamiento máximo; por lo tanto se medirá la temperatura más alta. El phantom fue sumergido en un tanque de agua desgasificada y desionizada, e





Figura 21.1 Disposición experimental.

irradiado por un transductor terapéutico de ultrasonido (TUS) a cuatro diferentes intensidades (0.5, 1.0, 1.5 y 2.0  $W/cm^2$ ). El agua del tanque fue mantenida a aproximadamente 22 °C usando un calentador de acuario de 75 W.

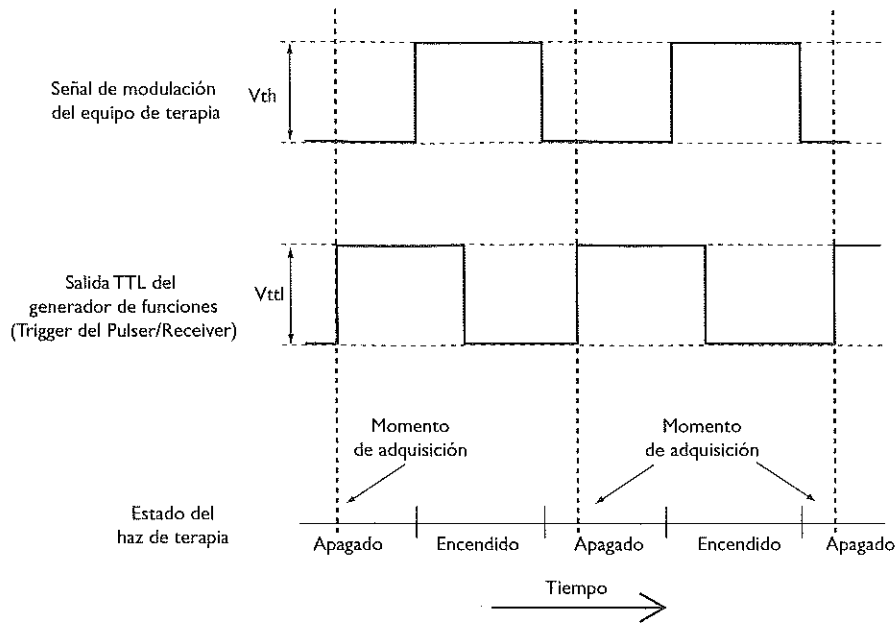
El dispositivo de TUS (Sonopulse generación 2000, Ibramed, SP, Brasil) calentó el phantom emitiendo ráfagas de ondas ultrasónicas de frecuencia central 1.0 MHz (0.5 de ciclo de carga) a una frecuencia de repetición de pulsos de 100 Hz. El transductor TUS es del tipo de pistón plano, con un área de radiación efectiva de 3.5  $cm^2$ . La naturaleza del pulso del haz terapéutico permite la adquisición de las señales retrodispersas del ultrasonido (BSU) durante los ciclos apagados (intervalo entre dos pulsos), por medio de un transductor de imagen. Por lo tanto no interfiere con el transductor de imagen, y permite colocar los transductores a lo largo del mismo eje, como se aprecia en la Figura 21.2.



**Figura 21.2** Disposición experimental de los transductores y de los termopares (todas las unidades están en **mm**), vista lateral.

La señal empleada para modular la onda continua de TUS en el dispositivo terapéutico se conecta a la entrada de modulación externa de un generador de función (33220A, Agilent, Santa Clara, CA, USA). Entonces el generador de función produce una señal TTL con la misma frecuencia, desfasada temporalmente, como se muestra en la Figura 21.3.

La señal originada entonces se usa para accionar el pulser/receptor (5800PR, Panametrics-NDT, Waltham, MA, USA) y para controlar el transductor de ultrasonido de imagen (IUS) y después para adquirir una señal BSU, durante el ciclo apagado del haz terapéutico. El transductor de IUS (V310SU, Panametrics-NDT, Waltham, MA, USA) presenta frecuencia central de 5 MHz y un diámetro de 6.0 mm. Las señales análogas de BSU recibidas por el pulser/receptor



**Figura 21.3** Señales de sincronismo ejemplificando la adquisición de la señal BSU.

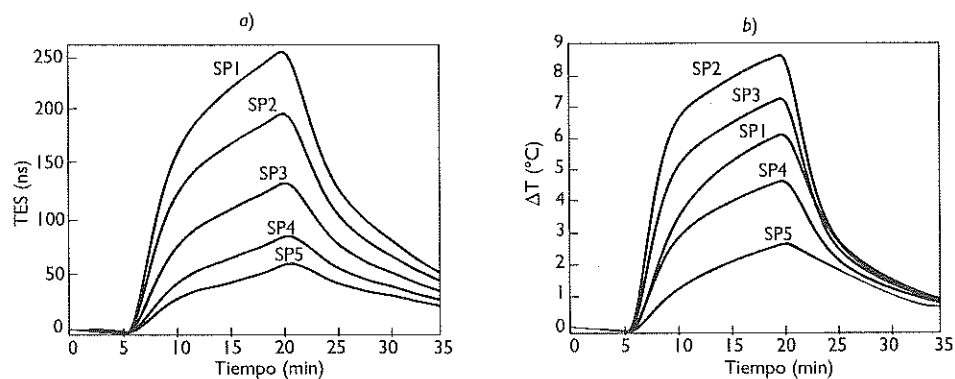
fueron digitalizadas a 50.0 MHz usando un osciloscopio digital (TDS2024, Tektronix, Beaverton, OR, USA). La adquisición de la temperatura en los cinco puntos sujetos a estudio fue lograda por un multiplexor de 20 canales, con la compensación integrada de unión fría (CJC, por sus siglas en inglés: cold junction compensation). Este multiplexor es parte de un multímetro digital (2700/7700, Keithley, Cleveland, OH, USA). Cada 10 s, los valores de la temperatura y una señal digitalizada de BSU fueron transferidos del multímetro y del osciloscopio a la PC vía un bus GPIB. Cada ensayo experimental duró 35 min, los primeros 5 min se adquiere de la línea de base de la temperatura, seguidos por 15 min de calentamiento y 15 min de enfriamiento. En los primeros 5 min, el dispositivo de TUS está inactivo y no existe ninguna señal de modulación. En esta situación, el pulser/receptor debe ser controlado por una señal interna del disparador. Cuando empieza la aplicación de calor (dispositivo activo de TUS), el modo del disparo del pulser/receptor debe cambiar de interno a externo para evitar interferencia acústica entre los transductores. Durante el tiempo de enfriamiento, el dispositivo de TUS está otra vez inactivo y el modo de disparo del pulser/receptor debe ser interno otra vez. El interruptor entre los modos de disparo es realizado por la PC vía el bus GPIB. La señal de disparo producida por el generador de funciones es enviada a la PC mediante el puerto paralelo, y cuando esta señal se mantiene en 0 V, significa que el dispositivo de TUS está inactivo y el modo pulser/receptor del disparador debe ser interno. De la otra forma, el disparador debe ser fijado como externo.

Se realizaron seis repeticiones del mismo ensayo de medición, es decir, usando la misma intensidad de TUS. Esto significa que se hicieron 24 ensayos de medición; cada uno correspondiente a 210 señales de BSU y a 210 valores de temperatura por punto espacial (SP1, SP2, SP3, SP4 y SP5).

## 21.3 Procesamiento de datos

Una vez adquiridos, los datos se procesan para construir las estimaciones propuestas de temperatura. Como se mencionó con anterioridad, se eligió como entrada al modelo los últimos valores de la temperatura y el desplazamiento temporal del eco (*TES*, por sus siglas en inglés) inducido por los cambios de temperatura. Se aislaron los ecos originados por los termopares y por las interfaces de la capa; así como el desplazamiento temporal de eco computado para cada punto espacial a lo largo de cada ensayo experimental. El cómputo de *TES* fue realizado aplicando el algoritmo propuesto por Viola y Walker (2005). Este algoritmo estima los retrasos continuos temporales de los datos de la muestra mediante la aplicación de una interpolación spline a una señal de referencia (en nuestro caso, a los ecos de la primera señal de BSU de cada ensayo experimental). Posteriormente, se encontró la suma del error cuadrático entre la referencia y la señal retrasada (los ecos en la señal BSU a lo largo de cada experimento), y el retardo relativo fue determinado.

En la Figura 21.4 se presentan el *TES* vs. tiempo y las señales de incremento de temperatura vs. tiempo.



**Figura 21.4** Desplazamiento de las señales de eco temporal acumulado a) comparado con las señales de cambio de temperatura medidas b), para las diferentes localizaciones espaciales (véase SP1, SP2, SP3, SP4, y SP5 en la Figura 21.2).

En esta figura, se puede ver que existe una relación clara pero no lineal entre la temperatura y las señales de *TES*. Además, la temperatura máxima no corresponde necesariamente al desplazamiento del eco máximo ya que se computó un *TES* acumulativo. Por ejemplo, el desplazamiento del eco originado en SP1 es dependiente en la temperatura a lo largo de toda la trayectoria del recorrido, e, incluso si la temperatura en SP1 no cambia, el *TES* relativo será mayor o igual a los otros *TES* que están más cercanos al transductor de IUS. Los métodos lineales tales como el publicado por Simon *et al.* (1998), primero computan el *TES* acumulativo y en seguida aplican un operador de diferencia a lo largo de la trayectoria del haz del transductor IUS para determinar los *TES* inducidos localmente, que son entonces relacionados linealmente con la temperatura. Después del cómputo de *TES*, los datos fueron filtrados y normalizados a valores entre -0.5 y 0.5. Esta normalización significa adecuar las diferencias en escala entre la temperatura y las señales de *TES*. El filtrado es nece-

sario para minimizar el ruido de la medición. Después del procesamiento de datos, los pares de señales de cambios de temperatura obtenidos ( $\Delta T$ )/TES fueron ordenados en filas separadas, de acuerdo con la respectiva intensidad y la posición espacial.

Dado que cada ensayo de medida origina 20 pares de señales (5 posiciones espaciales  $\times$  4 intensidades), entonces se obtuvieron 120 (6 ensayos  $\times$  20) archivos (subconjuntos) para la prueba de entrenamiento y validación del modelo. El entrenamiento se refiere al cómputo de los parámetros de RBFNN; la prueba se refiere a la evaluación del modelo con datos frescos durante el entrenamiento y el procedimiento de selección de la estructura. La validación consiste en la evaluación del modelo final con nuevos datos al final del entrenamiento y de la selección de la estructura. La Tabla 21.1 muestra los puntos de datos seleccionados para la construcción de las diferentes fases del modelo.

**Tabla 21.1 Cantidad de datos presentes en los conjuntos del entrenamiento, de prueba y validación.**

	Entrenamiento	Prueba	Validación
# de pruebas experimentales	4	1	1
# de archivos de datos	80	20	20

## 21.4 Entrenamiento y selección de la estructura de RBFNN

Según lo mencionado anteriormente, los modelos aplicados en este capítulo son estructuras de NARX compuestas por RBFNNs con dinámica externa inducida por sus entradas, como se muestra en la Figura 21.5.

Un RBFNN es una red neuronal no recursiva (feed-forward) de tres capas. La primera es un conjunto de entradas que conecta la red con el ambiente. La segunda capa (la única capa oculta) contiene un conjunto de elementos de procesamiento (las neuronas), y realiza una transformación no lineal en los datos de entrada. Cada neurona define una función de base radial sobre el espacio de entrada.


Estas funciones son generalmente del tipo Gaussiano, como en el siguiente caso:

$$\varphi_i(x_j) = e^{-\frac{\|x_j - c_i\|_2^2}{2\sigma_i^2}}, \quad (21.1)$$

donde  $\|\cdot\|_2$  representa la norma Euclidiana,  $\varphi_i$ ,  $c_i$ , y  $\sigma_i$  son la función de base, el vector de centro y la dispersión relacionados con la neurona  $i$ -ésima, respectivamente. El vector  $x_j$  es el  $j$ -ésimo patrón de entrada que se define, así como el  $c_i$ , en  $R^d$  donde  $d$  es el número de entradas. La tercera y última capa de RBFNN combina linealmente las salidas de las neuronas ocultas para obtener la salida total. La relación de entrada-salida de un RBFNN está dada por:

$$y(x_j) = b + \sum_{i=1}^n \alpha_i \varphi_i(x_j) \quad (21.2)$$

donde  $b$  es el término de sesgo,  $\{\alpha_i\}_{i=1}^n$  son los pesos lineales, y  $n$  es el número de neuronas. Las posibles entradas de red son los retrasos de  $\Delta T$  y de las señales computadas de TES. El retraso



**Figura 21.5** Estructura del modelo aplicado. Las flechas discontinuas representan las entradas que pueden seleccionadas por el MOGA. Las flechas continuas representan las entradas permanentes relacionadas con la intensidad y la posición espacial. El símbolo  $z^{-1}$  representa la unidad-retraso operador ideal usado para retrasar las variables de entrada consideradas.

máximo considerado fue 25 porque este valor fue utilizado con éxito en trabajos previos, y también se obtuvieron resultados consistentes en el ambiente de valoración propuesto. De esta forma, las entradas posibles relacionadas con  $\Delta T$  y  $TES$  son:

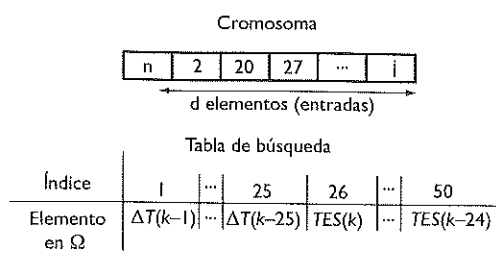
$$\Omega = \{\Delta T(k-1), \dots, \Delta T(k-25), TES(k), \dots, TES(k-24)\}. \quad (21.3)$$

La selección de la estructura apropiada del modelo para un ambiente en particular puede resultar difícil debido a la gran cantidad de soluciones posibles. En este capítulo, el problema de la selección de la estructura consiste en la selección apropiada tanto de las entradas de  $\Omega$ , como del número de neuronas en la capa oculta del RBFNN. Este problema de selección de la estructura se puede formular como un procedimiento de optimización con varios objetivos, y luego el algoritmo genético multi-objetivos (MOGA, por sus siglas en inglés) (Fonseca y Fleming 1993) es aplicado a la tarea. Este algoritmo es parte de un conjunto mayor de métodos computacionales que se basan en la selección natural y la supervivencia del más apto. El MOGA, así como el algoritmo genético estándar, empieza con una población de soluciones posibles generadas aleatoriamente (individuos), después cada una de las soluciones se evalúa para extraer descriptores de desempeño. Estos descriptores entonces se utilizan para ordenar la población, esencial para la selección de los mejores individuos para la recombinación y la mutación. Después de este procedimiento, se crea una nueva población y una nueva iteración empieza.

La estructura de NARX, tal como la presentada en la Figura 21.5, se compone por un conjunto de entradas y de un número de neuronas ocultas. La aplicación de la optimización de la estructura implica que cada modelo se codifique (es decir, deben ser representados por un cromosoma), para

permitir el uso de operadores genéticos (mutación y cruce). Una manera directa de representar cada NARX es considerar un cromosoma donde el primer elemento es el número de neuronas, y los otros son índices para los términos disponibles de entrada.

El conjunto de índices de términos de entrada en cada cromosoma es un subconjunto del conjunto total de índices posibles de término de entrada relacionados con la tabla de búsqueda presentada en la Figura 21.6.



**Figura 21.6** Cromosoma RBFNN y tabla de búsqueda de términos.  $d$  es el número de entradas, y  $n$  el número de neuronas en una estructura particular.

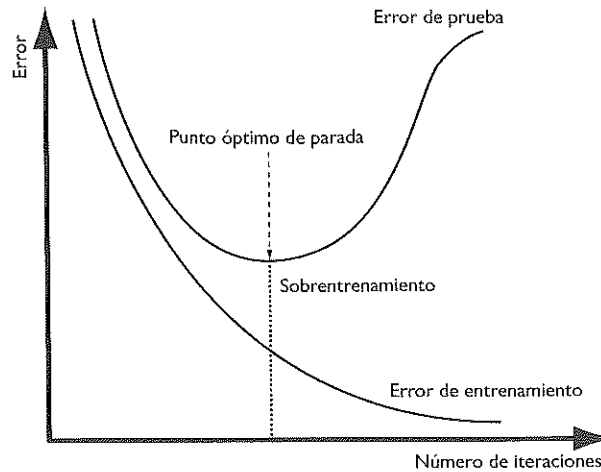
Esta clase de selección de término de entrada fue aplicada por Fonseca (1995) para identificación de modelos del tipo (NARMAX). La longitud del cromosoma es variable, de acuerdo al número de entradas en la estructura correspondiente. En la Figura 21.6 se pueden ver la representación del cromosoma y la tabla de búsqueda.

La evaluación de la población NARX abarca el entrenamiento de un conjunto de RBFNNs. Las redes neuronales fueron entrenadas usando una metodología que implica el algoritmo de Levenberg-Marquardt (LM) y la minimización de un criterio que explote la posibilidad de separación de los parámetros de NN en lineal ( $b$  y  $\{\sigma_i\}_{i=1}^n$ ) y no lineal ( $\{c_i, \sigma_i\}_{i=1}^n$ ), lo que mejora el funcionamiento del algoritmo del entrenamiento (Ruano *et al.*, 2005). El LM optimizó solamente los parámetros no lineales, mientras que los lineales fueron encontrados usando una estrategia lineal de mínimos cuadrados. Los valores iniciales de los centros fueron fijados por el método de agrupamiento de media-k adaptativo óptimo (OAKM, por sus siglas en inglés: optimal adaptative k-means) (Chinrungrueng y Séquin 1995), y los valores iniciales de las dispersiones fueron encontrados empleando el método propuesto por Haykin (1999):

$$\sigma_i = \frac{d_{\max}}{\sqrt{2n}}, i = 1, \dots, n, \quad (21.4)$$

donde  $d_{\max}$  es la distancia máxima entre los centros, y  $n$  es el número de neuronas. El criterio LM de detención fue el de "Detención Temprana".

Según lo ilustrado en la Figura 21.7, el error de entrenamiento siempre disminuye (para un conjunto de entrenamiento grande) con el número de iteraciones. Por otra parte, durante el entrenamiento, el error (prueba) en datos frescos disminuye inicialmente pero en una cierta iteración arbitraria, empieza a aumentar, lo que indica que el NN comienza a sobre entrenarse. El sistema de "Detención Temprana" utiliza esta información para terminar el entrenamiento; con lo que previene



**Figura 21.7** El criterio de detención temprana indica el punto de parada óptimo para la generalización.

el sobre entrenamiento y facilita el logro de un NN con una buena capacidad de generalización. Este criterio se conoce como el procedimiento de detención ideal para aplicaciones en mundo real (Principe *et al.*, 2000).

Después de entrenar, los descriptores de desempeño de cada modelo deben ser computados. Los descriptores considerados fueron organizados en dos grupos: error del modelo y complejidad del modelo. En términos de errores del modelo, se consideraron los siguientes descriptores: raíz del error cuadrático medio en el conjunto de entrenamiento ( $RMSE_{TR}$ ), error cuadrático medio máximo absoluto estimado para todos los subconjuntos de la prueba ( $MAE_{TE}$ ). El  $RMSE_{TR}$  fue obtenido usando el error del "siguiente paso" con los datos del entrenamiento. El  $MRMSE_{TE}$  fue encontrado considerando la raíz del el error cuadrático medio de un paso adelante para todos los subconjuntos de prueba y eligiendo su máximo. El  $MAE_{TE}$  fue obtenido computando el error (varios pasos adelante) en todos los subconjuntos de prueba, después se considera el error absoluto máximo en cada uno de ellos, y finalmente se escoge el máximo de estos errores absolutos máximos. Una estimación de varios pasos adelante se obtiene retroalimentando los valores de temperatura previamente estimados, según lo deseado para un ambiente de valoración no invasivo, por medio de un ensayo experimental completo (calentamiento y enfriamiento).

Los descriptores de complejidad del modelo elegidos eran la norma de los pesos lineales (LWN, por sus siglas en inglés), y el número de parámetros (NP, por sus siglas en inglés), definidos de la manera siguiente:

$$LWN = \sqrt{\sum_{i=1}^n \alpha_i^2 + b^2}, \quad (21.5)$$

$$NP = NC \times NI + NS + NW. \quad (21.6)$$

$NC$  es el número de centros,  $NI$  el número de las entradas,  $NS$  el número de dispersiones, y  $NW$  el número de pesos lineales. Se escoge minimizar los  $LWN$  porque los modelos con un alto  $LWN$

están mal acondicionados y normalmente se especializan en los datos de entrenamiento; presentan un alto error en datos nuevos (mal desempeño de generalización). En aplicaciones reales, los recursos son limitados y por lo tanto, el logro de modelos con errores pequeños y baja complejidad de cómputo es importante; por lo anterior,  $NP$  debe minimizarse. En este capítulo, se definieron metas para cada objetivo pues existen limitaciones de viabilidad (por ejemplo, un máximo de error absoluto inferior a  $0.5\text{ }^{\circ}\text{C}$  es esencial). Además, cada objetivo tiene una prioridad asociada que define su importancia relativa. Después del cómputo de las características antes mencionadas para todas las estructuras NARX, en la población actual, se realizó un ordenamiento que considera las metas y prioridades definidas y se seleccionaron las soluciones más aptas para producir la población siguiente.

Debe mencionarse que, además de las entradas seleccionadas por el MOGA, hay dos entradas siempre presentes en los modelos ( $I(k)$  y  $P(k)$  en la Figura 21.5). Estas entradas discriminan la intensidad ( $I(k)$ ) y la localización espacial ( $P(k)$ ) relacionadas con la forma de la onda de la temperatura bajo estimación.

## 21.5 Resultados y discusión

Se hicieron diferentes de MOGA buscando la mejor parametrización. El espacio de búsqueda fue delimitado definiendo el número posible de neuronas, el número posible de entradas, y el retraso máximo para las variables de entrada ( $\Delta T$  y  $TES$ ). El número posible de neuronas se definió como un número entero en el intervalo  $[8,20]$ , el número de entradas fue definido como un número entre 2 y 20, y el retraso máximo, como se mencionó anteriormente, era considerado como 25. Las metas definidas para cada objetivo así como las prioridades asociadas se presentan en la Tabla 21.2.

**Tabla 21.2 Metas y prioridades definidas para cada objetivo de MOGA.**

Objetivo	$RMSE_{TR}$	$MRMSE_{TR}$	$MAE_{TR}$	$LWN$	$NP$
Meta	$0.15\text{ }^{\circ}\text{C}$	$0.48\text{ }^{\circ}\text{C}$	$0.48\text{ }^{\circ}\text{C}$	2.0	200
Prioridad	1	2	2	1	1

Los errores de la prueba fueron definidos como de alta prioridad, pues se relacionan con la capacidad de generalización. De acuerdo a lo mencionado con anterioridad, el umbral un estimador deseado o indeseado en hipertermia/diatermia es  $0.5\text{ }^{\circ}\text{C}$ ; ésta es la razón para que las metas definidas para  $MRMSE_{TE}$  y  $MAE_{TE}$  sean  $0.48\text{ }^{\circ}\text{C}$  (un poco debajo el umbral). Se encontró que si no se define ninguna meta para  $RMSE_{TR}$ , el MOGA intenta minimizar excesivamente este objetivo lo que resulta en modelos especializados solamente en datos de entrenamiento, y por lo tanto tienen un mal desempeño general. Así, se estableció un valor de meta de  $0.15\text{ }^{\circ}\text{C}$ . La meta para  $NP$  fue elegida después de que varias corridas y sus observaciones mostraron que los modelos consistentes tienen complejidad debajo de 200. La meta de  $LWN$  fue definida considerando la normalización empleada y el número máximo de neuronas permitido.

El MOGA se corrió cuatro veces usando la parametrización presentada previamente. Se obtuvieron 100 generaciones de 200 individuos por generación en cada corrida. Se obtuvo un conjunto de 82 modelos preferibles para todas las corridas. Estos individuos son los más aptos desde el punto


de vista de MOGA; *i. e.* son los modelos que presentan los mejores valores objetivos de acuerdo a las metas y las prioridades definidas. En la Tabla 21.3 se pueden ver las estadísticas para los valores de los objetivos presentadas para los modelos considerados.

**Tabla 21.3 Estadísticas de los objetivos obtenidos para los modelos preferibles.**

Objetivo	RMSE <sub>TR</sub> (° C)	MRMSE <sub>TE</sub>	MAE <sub>TE</sub> (° C)	LWN	NP
Mínimo	$6.13 \times 10^{-2}$	0.10	0.39	1.18	64
Máximo	0.15	0.27	0.48	1.99	166
Promedio	0.13	0.23	0.46	1.64	109.89
Desv. Estand.	$1.54 \times 10^{-2}$	$2.98 \times 10^{-2}$	$1.54 \times 10^{-2}$	0.23	22.96

Si se observa esta tabla, se puede ver que todas las metas definidas fueron satisfechas (en los aspectos máximos y promedio), especialmente las metas prioritarias relacionadas con *MRMSE<sub>TE</sub>* y *MAE<sub>TE</sub>*. La consecución de la meta definida para el *LWN* significa que todos los individuos preferibles están bien condicionados. La Tabla 21.3 también indica que la complejidad requerida, es decir, el número de parámetros, es compatible con la exactitud deseada, lo cual es un aspecto importante en términos de viabilidad. Pequeñas desviaciones estándar también fueron observadas, lo que significa que el MOGA convergió a una región bien definida en el espacio de los objetivos.

La frecuencia absoluta de las entradas individuales preferidas se presenta en la Figura 21.8, donde es posible observar que el MOGA seleccionó preferiblemente los intervalos de  $\Delta T$  para un largo plazo. Por otro lado, los retrasos a corto plazo de *TES* son los más frecuentes, más del 50% de los modelos tienen *TES(k)* como entrada. Considerando todas las entradas seleccionadas, el 73% está

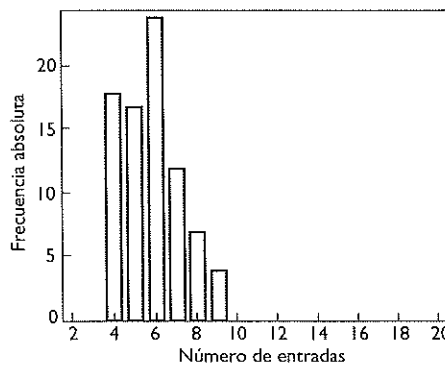


**Figura 21.8** Frecuencias absolutas de las entradas de los modelos preferidos, seleccionadas por el MOGA. a) Entradas relacionadas con  $\Delta T$ , y b) entradas relacionadas con *TES*.

relacionado con *TES*, y solamente el 27% se relaciona con  $\Delta T$ . Esto sucede porque la estructura del modelo se optimiza para la valoración multi-paso-adelante, que es posible retroalimentando los valores anteriores de temperatura estimados. Esta retroalimentación introduce errores acumulativos en las entradas, lo que disminuye el desempeño. Además, las señales de *TES* no introducen errores acumulativos ya que se obtienen directamente de las señales de BSU en cada instante, y tienen la calidad necesaria para superar la carencia de los retrasos de corto plazo de  $\Delta T$  lo que permite el cumplimiento de los objetivos de error definidos. Sin embargo, la información de largo plazo de  $\Delta T$  parece ser importante, en el especial los retrasos 23 y 24, que aparecen en 16 y 19 de los modelos preferidos, respectivamente. En cada uno de los modelos preferidos, por lo menos una entrada relacionada con temperatura está presente.

Si sólo se desean los modelos de un-paso-adelante, o las señales de *TES* no tienen la calidad necesaria para satisfacer los objetivos de error, entonces se seleccionarán los retrasos de corto plazo de la temperatura.

Como se puede ver en la Figura 21.9, los modelos preferidos tienen entre 4 y 9 entradas; la mayoría tiene 6 entradas.

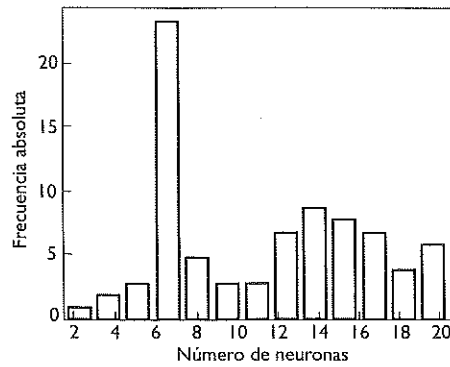


**Figura 21.9** Frecuencia absoluta del número de entradas por modelo. Los más frecuentes son los modelos con seis entradas.

La Figura 21.10 demuestra que la mayoría de los modelos tiene 11 neuronas (precisamente 24 modelos). Modelos con entre 15 y 18 neuronas también son frecuentes. Los parámetros de la estructura seleccionada apunta a que el MOGA selecciona una clase de modelos adecuada para el ambiente de valoración propuesto (*i. e.* que satisfagan las metas definidas *a priori*).

Después del entrenamiento y de la selección de la estructura, los individuos preferidos deben ser evaluados con *datos frescos*; es decir, con los datos de la validación.

En la Tabla 21.4 se presentan los valores mínimo, máximo, promedio y desviación estándar del error absoluto máximo obtenido en todos los subconjuntos de la validación ( $MAE_{VL}$ ). El  $MAE_{VL}$  se obtiene de la misma forma que el  $MAE_{TE}$  pero usando los datos de la validación. Si se observa esta tabla, se puede ver que, en promedio, los individuos preferidos están bien adaptados para la hipertermia/diatermia ( $MAE_{VL} < 0.50^{\circ}\text{C}$ ). La desviación estándar indica que la mayoría de los mejores modelos presentan un  $MAE_{VL}$  inferior a  $0.5^{\circ}\text{C} + 10\%$ . En el peor de los casos, se obtuvo un error máximo absoluto de  $0.66^{\circ}\text{C}$ , lo que no es un valor grande. El mejor de los modelos prefe-




**Figura 21.10** Frecuencia absoluta del número de neuronas por modelo; la mayoría tiene 11 neuronas.

ridos tienen un  $MAE_{VL}$  de 0.41 °C. La Figura 21.11 muestra las curvas de temperatura estimada en comparación con las curvas de las temperaturas medidas.

**Tabla 21.4**  $MAE_{VL}$  estadísticas (°C).

Mínimo	Máximo	Promedio	Dev. Estánd
0.41	0.66	0.49	0.048

Los métodos físicos publicados (tales como los presentados por Simon *et al.*(1998), y Amini *et al.* (2005)) sólo son convenientes para la estimación en medios homogéneos porque utilizan una única constante del medio para relacionar la característica extraída de BSU con temperatura, mientras que en medios de varias capas existe más de una constante. Los modelos propuestos aprenden de los datos, y no se requiere una determinación explícita de constantes de medio. El conocimiento de cómo cambia la temperatura en las diferentes capas fue obtenido de situaciones similares, observadas por los modelos, durante el entrenamiento. Además, los métodos físicos basados en desplazamientos temporales del eco para trabajar necesitan transformar los desplazamientos acumulados en desplazamientos inducidos localmente. Esta transformación entre los desplazamientos acumulados y locales es realizada aplicando operadores diferenciales a lo largo de la trayectoria del haz de ultrasonido. El método propuesto utiliza desplazamientos acumulados directamente (desechando el proceso adicional necesario para distinguirlos) debido a su comportamiento no lineal y adaptativo. En Simon *et al.* (1998), la exactitud del método se determina en tres puntos (cerca de los dos focos de un transductor de HIFU) y usando una intensidad única. Se calentó un phantom de goma homogéneo durante 40 s y se le permitió enfriarse en los 50 siguientes segundos; se alcanzó un incremento de temperatura máxima de 4.22 °C. Se reportó que se obtuvo un error máximo de 0.44 °C. Por otra parte, el método reportado en este capítulo fue validado en cinco puntos diferentes y a cuatro diferentes intensidades, lo que significa que se consideraron 20 puntos de funcionamiento (4 intensidades × 5 puntos) en vez de tres (1 intensidad × 3 puntos) considerados por Simon *et al.*



**Figura 21.11** La temperatura medida (líneas continuas) contra la temperatura estimada (líneas discontinuas) para el mejor modelo preferido en la validación. a)  $0.5 \text{ W/cm}^2$ , b)  $1.0 \text{ W/cm}^2$ , c)  $1.5 \text{ W/cm}^2$ , y d)  $2.0 \text{ W/cm}^2$ .

(1998). En términos del máximo error absoluto obtenido, la metodología propuesta alcanza un valor de  $0.41 \text{ }^{\circ}\text{C}$ , que es mejor que los resultados señalados por Simon *et al.* (1998). Esta exactitud fue obtenida para un tiempo total de valoración de 35 min (5 min temperatura base + 15 min de calentamiento + 15 min de enfriamiento), y para un incremento de la temperatura de aproximadamente  $9^{\circ}\text{C}$ .

## 21.6 Conclusiones

En este capítulo se presentó la estimación de la temperatura mediante una técnica no invasiva en medios (no homogéneos) de varias capas, usando las estructuras de NARX optimizadas genéticamente. Estas estructuras fueron compuestas por redes neuronales de función de base radial estáticas con dinámica externa inducida por sus entradas. Se encontró que fue posible obtener estimadores apropiados que presenten un máximo de error absoluto inferior al estándar de oro en hipertermia/diatermia ( $0.5 \text{ }^{\circ}\text{C}$ ) con estructuras poco complejas. El mejor modelo presentó un error absoluto máximo de  $0.41 \text{ }^{\circ}\text{C}$  para los cinco puntos bajo estimación y para todas las intensidades aplicadas.

Los méritos fundamentales de este trabajo son la exactitud lograda (error máximo absoluto inferior a 0.5 °C) en los puntos e intensidades consideradas; ninguna necesidad de determinar constantes físicas del medio, y el uso directo de las características extraídas (lo que elimina el procesamiento previo adicional).

La metodología propuesta fue construida y probada en un ambiente de estimación extenso, con el fin de desarrollar controladores de temperatura en tiempo real. Hasta donde ha sido posible investigar, éste es el primer acercamiento a la estimación de la temperatura mediante una técnica no invasiva aplicada en medios multicapa en los que se usa el ultrasonido tanto para aplicar calor como para estimación.

Estudios futuros incluirán el análisis de cómo la metodología propuesta puede superar los cambios del medio considerando posibles aplicaciones *in vivo*.

### Reconocimientos

El primer autor agradece los apoyos de SFRH/BD/14061/2003 y del proyecto POSC/EEA-SRI/61809/2004 de la Fundação para a Ciência e a Tecnologia, Portugal; así como del proyecto CNPq/CYTED/490.013/03-1 del Conselho Nacional de Desenvolvimento Científico e Tecnológico, Brasil. Se agradece a Guillermo Cortela por su ayuda para la elaboración de este trabajo.

### 217 Bibliografía recomendada

- ARTHUR RM, STRAUBE WL, TROBAUGH JW, AND MOROS EG (2005) Noninvasive temperature estimation of hyperthermia temperatures with ultrasound. *Int. J. Hyperthermia* 21:589–600
- PAULSEN KD, MOSKOWITZ M J, RYAN TP, MITCHELL SE, HOOPES PJ (1996) Initial *in vivo* experience with EIT as a thermal estimator during hyperthermia. *Int. J. Hyperthermia* 12:573–591
- MEANEY PM, PAULSEN KD (1996) Microwave imaging for tissue assessment: initial evaluation in multitarget tissueequivalent phantoms. *IEEE Trans. Biomed. Eng.* 43:878–890
- HYNYNEN K, CHUNG A, FJELD T, BUCHANAN M, DAUM D, COLUCCI V, LOPATH P, JOLESZ F (1996) Feasibility of using ultrasound phased arrays for MRI monitored noninvasive surgery. *IEEE Trans. Ultrason., Ferroelect., Freq. Contr.* 43:1043–1052
- SIMON C, VANBAREN P, EBBINI ES (1998) Two-dimensional temperature estimation using diagnostic ultrasound. *IEEE Trans. Ultrason., Ferroelect., Freq. Contr.* 45:1088–1099
- AMINI AN, EBBINI ES, GEORGIU TT (2005) Noninvasive estimation of tissue temperature via high-resolution spectral analysis techniques. *IEEE Trans. Biomed. Eng.* 52:221–228
- UENO S, HASHIMOTO M, FUKUKITA H, YANO T (1990) Ultrasound thermometry in hyperthermia. In *Proc IEEE Ultrasonics Symposium* 3:1645–1652
- ARTHUR RM, STRAUBE WL, STARMAN JD, MOROS EG (2003) Noninvasive temperature estimation based on the energy of backscattered ultrasound. *Medical Physics* 30:1021–1029
- FONSECA C, FLEMING P (1993) Genetic algorithms for multi-objective optimization: Formulation, discussion and generalization. In *Proc. 5th Int Conf Genetic Algorithms* 1:416–423
- TEIXEIRA CA, RUANO AE, NEGREIRA C, RUANO MG, PEREIRA WCA (2006) Non-invasive temperature prediction of *in-vitro* therapeutic ultrasound signals using neural networks. *Med. Biol. Eng. Comput.* 44:111–116
- TEIXEIRA CA, RUANO MG, RUANO AE, PEREIRA WCA (2008) A soft-computing methodology for non-invasive time-spatial temperature estimation. *IEEE Trans. Biomed. Eng.* 55:572:580
- VIOLA F, WALKER WF (2005) A spline-based algorithm for continuous time-delay estimation using sampled data. *IEEE Trans. Ultrason., Ferroelect., Freq. Contr.* 52:80–93
- FONSECA CM (1995) Multiobjective genetic algorithms with application to control engineering problems. Ph.D. dissertation, Department of Automatic Control and Systems Engineering, University of Sheffield, UK.

- RUANO AE, FERREIRA PM, FONSECA CM (2005) An overview of nonlinear identification and control with neural networks. In Ruano AE (ed) Intelligent Control Systems using Computational Intelligence Techniques, 1<sup>st</sup> edn. IEE Press, London.
- CHINRUNGRUENG C, SÉQUIN CH (1995) Optimal adaptive k-means algorithm with dynamic adjustment of learning rate. IEEE Trans. Neural Networks 6:157–169
- HAYKIN S (1999) Neural Networks: A comprehensive foundation. 2<sup>nd</sup> edn. Prentice Hall, New Jersey
- PRINCIPE JC, EULIANO NR, LEFEBVRE WC (2000) Neural and adaptive systems: Fundamentals through simulations. 1<sup>st</sup> edn. John Wiley & Sons, New York