

DETERMINACION DE LA ARQUITECTURA OPTIMA DE UNA RED NEURONAL TIPO PERCEPTRÓN MULTICAPA PARA LA EXTRACCIÓN DE CARACTERÍSTICAS RELEVANTES Y RECONOCIMIENTO DE SEÑALES MIOELÉCTRICAS.

(PARTE 1)

Vladimir Barrero
v.barrero@ieee.org

Juan Pablo León
juan_p_leon@hotmail.com

Carlos Sánchez
carlos.andres@ieee.org

Fernando Rosas
fernando.rosas@ieee.org

Resumen: En este artículo se muestran los procedimientos a seguir para determinar la arquitectura óptima de una red neuronal tipo perceptrón multicapa (MLP), además de la metodología para el entrenamiento y validación de la red mediante un caso de estudio de reconocimiento de señales mioeléctricas (EMG) del brazo de un paciente sano de 23 años, mediante la utilización del algoritmo de *Back-Propagation* (BP).

Palabras clave: Prótesis de miembro superior, Amputados de Miembro Superior, Señales Mioeléctricas (EMG), Redes Neuronales Artificiales (RNA), Algoritmo Backpropagation, Procesamiento Digital de Señales, Transformada Rápida de Fourier, Coeficientes Cepstrales, Análisis de correlación lineal.

1. INTRODUCCIÓN

La problemática de los discapacitados, y en especial de las personas amputadas, es de gran impacto en nuestra sociedad. Las prótesis actuales plantean soluciones que se alejan de las expectativas de un amputado, pero aún así, le dan consuelo y le permiten mejorar su estética personal y ser útil. Dichas prótesis van desde los ganchos, hasta elaboradas prótesis mioeléctricas, aunque estas últimas, por su elevado costo no son asequibles a la mayor parte de los discapacitados. A continuación se describe una serie de experiencias científicas que demostraron la factibilidad de implementar un prototipo funcional, es decir, una interfase electrónica que recibe, procesa, e identifica las señales mioeléctricas, con posibilidad de ser adaptada al interior de una prótesis electromecánica de mano.

2. PROBLEMA E HIPÓTESIS

El problema de las personas que ha sufrido la amputación de una o ambas manos es que dicha contingencia limitante tiene efectos fisiológicos, psicológicos y sociológicos que menoscaban e incapacitan al individuo e inciden negativamente en la economía del país. La pérdida de un miembro tan importante como la mano descompensa el equilibrio del organismo, deteriora los grupos musculares asociados a la extremidad ocasionando que acciones tan cotidianas y básicas como tomar alimentos, escribir, etc., afecta de forma negativa a la persona disminuyendo su autoestima y deteriorando la relación con el entorno. Esta situación se ve empeorada por la marginación que ejerce la comunidad, en particular en el entorno laboral, lo cual reduce aún más la productividad del individuo.

Con base en los anteriores hechos se llevó a cabo la investigación y la aplicación de tecnología de punta para

proponer soluciones concretas al problema de estos discapacitados en Colombia. En particular, se trabajó el diseño e implementación de una interfaz inteligente para control de una prótesis mioeléctrica de mano de bajo costo, eficiente desde el punto de vista energético y con capacidad para comandar un conjunto de tres motores al interior de la prótesis.

3. METODOLOGÍA

3.1 POBLACIÓN, MUESTRA Y GRUPO DE REFERENCIA

La población objeto de estudio está constituida por pacientes, hombres o mujeres, quienes han perdido una o ambas manos por causas traumáticas y se les practicó cirugía de amputación en el antebrazo a la altura del tercio proximal, en un lapso de tiempo no mayor a un año desde la amputación; no incluye a los discapacitados por causas genéticas.

3.2 ANÁLISIS DE RIESGOS

La experimentación por realizar es de carácter no invasivo, por tanto, la posibilidad de riesgos por heridas y consecuentes infecciones es prácticamente nula. La recolección de datos se hará por medio de un sistema de adquisición de señales que utiliza electrodos de superficie. Para el caso de señales eléctricas directas el riesgo es mínimo, porque tanto los potenciales que se producen en los electrodos como las corrientes que fluyen en los preamplificadores están muy por debajo de los niveles máximos permitidos para seres humanos.

3.3 RECOLECCIÓN DE DATOS

Entrevista. Con este instrumento se busca informar a los pacientes aptos acerca de la filosofía y alcances del proyecto.

Historia clínica. Con este instrumento se busca que los pacientes suministren información básica, de tipo informativo, acerca de su estado general de salud física y mental, y detalles específicos de su traumatismo.

3.4 SISTEMA DE ADQUISICIÓN

El sistema esta compuesto por un conjunto de electrodos, una tarjeta de adquisición de señales y un instrumento virtual.

3.4.1 ELECTRODOS

Se emplearon electrodos pleamplificados de la empresa Delsys, que tienen como características esenciales que han sido diseñado para electromiografía y no necesitan gel para prepara la piel.

Figura 1. Electrodo.



3.4.2 TARJETA DE ADQUISICIÓN

Se utilizó una tarjeta de adquisición de National Instruments® modelo PCI 6024E cuyas características análogas son:


Para la adquisición se utilizaron los canales del 0 al 3 en el modo de entrada RSE, que consiste en que todas las señales de entrada están referenciadas a una tierra común. La entrada negativa del amplificador diferencial está unida a la tierra análoga. Este tipo de configuración, RSE, es muy útil para medir fuentes de señales flotantes.

3.4.3 INSTRUMENTO VIRTUAL

Se utilizó el programa LabView® versión 6i, para diseñar la herramienta software que funcione como electromiógrafo para adquisición y almacenamiento de la señal.


A continuación se muestra el esquema del programa gráfico del electromiógrafo.

Figura 2. Detalle del instrumento virtual.




El instrumento permite visualizar la señal que proviene de los electrodos de manera individual o simultanea, permitiendo adicionalmente almacenarla en modo texto para un posterior procesamiento.

Figura 3. Carátula instrumento virtual.
SISTEMA DE ADQUISICION Y ALMACENAMIENTO SIMULTANEOS PARA 4 CANALES



3.5 MANIPULACIÓN DE LA SEÑAL

Figura 4. Secuencia de tratamiento de la señal.



3.6 CÁLCULO DE LOS COEFICIENTES CEPSTRALES

En 1963, Bogert, Healy y Tukey observaron que el logaritmo del espectro de potencia de una señal que contiene un eco tiene una componente periódica aditiva debida al eco, y en consecuencia la transformada de Fourier del logaritmo del espectro de potencia puede mostrar un pico en el retraso del eco. Esta función es llamada *cepstrum* (**cepstral**), un intercambio de letras de la palabra *spectrum* (**espectro**) porque “en general, nos encontramos operando en la frecuencia de una forma usual a la del lado del tiempo, y viceversa”. Bogert et al. definió un vocabulario extenso para describir esta nueva técnica de procesamiento de señal; sin embargo, sólo el término *cepstrum* ha sido ampliamente utilizado.

Analíticamente se define el cepstral como:

$$\hat{x}[n] = \frac{1}{2p} \int_{-p}^p \log[X(e^{jw})] e^{jwn} dw$$

$$\hat{x}[n] = \frac{1}{2p} \int_{-p}^p [\log|X(e^{jw})| + jX(e^{jw})] e^{jwn} dw$$

En contraste al cepstral complejo el cepstral $c_x[n]$ de una señal (algunas veces referido como el cepstral real) es definido como la transformada inversa de Fourier del logaritmo de la magnitud de la transformada de Fourier;

$$c_x[n] = \frac{1}{2\pi} \int \log|X(e^{jw})| e^{jwn} dw.$$

3.7 REDUCCIÓN DE CARACTERÍSTICAS RELEVANTES

Después de haber seleccionado las primeras componentes por ser las que concentran la mayor cantidad de energía de la señal, queda la tarea de reducir su número para tomar únicamente las que tengan mayor cantidad de información. Para tal hecho se realiza el procedimiento de correlación entre cada columna de componentes. La correlación nos permite saber si la información contenida en los ejemplos es redundante (en caso de que el coeficiente de correlación sea mayor que 0.707, según Looney [Looney, 1997]).

$$r_{x,y} = \frac{Cov(X,Y)}{s_x \cdot s_y}$$

donde:

$$-1 \leq r_{x,y} \leq 1$$

y:

$$Cov(X,Y) = \frac{1}{n} \sum_{j=1}^n (x_j - m_x)(y_j - m_y)$$

3.8 GENERACIÓN DE LAS BASES DE DATOS

Para poder decidir el tamaño de la base de datos que entrenará la RNA, debemos tomar un primer estimativo de las características que tendrá la misma.

Se definen los siguientes valores:

N: Número de Neurodos de entrada
M: Número de Neurodos de la capa media
J: Número de Neurodos de la capa de salida

Las salidas esperadas son:

J1: Apertura de la mano
J2: Cierre de la mano
J3: Flexión de la muñeca
J4: Extensión de la muñeca
J5: Pronación
J6: Supinación
J7: Reposo

De los demás datos N y M, no tenemos una precisión al respecto, pero podemos dar algunas pautas. De M, que es la capa media, podemos dar un valor estimado por experiencias semejantes relacionadas con el reconocimiento de patrones, donde M podría ser del orden de 50. Por último, de N se puede dar un estimativo a partir de lo observado en la característica de frecuencia de la señal (FFT), donde N=33; con un valor mayor las demoras en el entrenamiento de red se hacen muy grandes.

Si denominamos L como el tamaño de la base de datos de entrenamiento de la red, este se puede estimar a partir de la siguiente ecuación:

$$L = N * M + M * J + M + J$$

$$L = 2057$$

que podemos aproximar por debajo a $L = 2000$. Donde el valor anterior se considera como la quinta parte de la base total, pues el mismo corresponde al valor mínimo para poder afectar un peso a la vez, por lo tanto se toma un valor total de la base de 12.000 ejemplos.

3.9 DISTRIBUCIÓN DE LA BASES DE DATOS

A su vez, en la base de datos, no todos los movimientos tienen un igual número de muestras, pues estadísticamente no tienen la misma probabilidad de ocurrir. Donde se considera el 100% las 12000 muestras en la base de datos. A continuación se discrimina cuantas muestras debe haber por cada movimiento.

Tabla 1. Distribución de los ejemplos por movimiento.

J1:	REPOSO	(25%)
J2:	APERTURA DE LA MANO	(12.5%)
J3:	CIERRE DE LA MANO	(12.5%)
J4:	FLEXIÓN DE LA MUÑECA	(12.5%)
J5:	EXTENSIÓN DE LA MUÑECA	(12.5%)
J6:	PRONACIÓN	(12.5%)
J7:	SUPINACIÓN	(12.5%)

Se secciona la base de datos teniendo en cuenta que:

Tabla 2. Distribución de las bases de datos.

Base de datos	Porcentaje del total
Entrenamiento	60%
Validación	25%
Verificación	15%

Una vez se construye la base de datos con las columnas más relevantes, se prosigue a normalizar la base de datos, obteniendo por columna el promedio y la desviación

estándar, correspondiente cada una al valor DC y RMS de la columna.

Con los valores obtenidos se construye una base de datos madre, donde cada elemento se obtiene a partir de la fórmula:


$$\text{Elemento} = \frac{\text{elemento} - \text{promcolumna}}{\text{desvstdcol}}$$

Se procede a aleatorizar cada una de las bases de datos y se está listo para entrenar la red neuronal.

4. RESULTADOS OBTENIDOS

Para la suma de los coeficientes cepstrales de los 4 electrodos con los parámetros N=13, M=25, J=7 y 500 iteraciones se obtuvieron los siguientes resultados:

Figura 5. Curvas de error.



La gráfica de error se interpreta como la comparación de los errores de validación y verificación, entendiéndose que el error de validación es generado mientras se está entrenando y el de verificación se genera cuando la red se corre hacia delante con ejemplos nunca vistos. Se debe esperar que la curva de error de verificación siga a la del error de validación y cuando se separan se interpreta como que la red está memorizando los ejemplos.

Tabla 3. Matriz de confusión.

ENTRENAMIENTO										% Acerto	% Falla
Nºejemplos	REPOSO	FLEXION	EXTENSION	PRONACION	SUPINACION	APERTURA	CIEBRE	NO RECON			
1800	1800	0	0	0	0	0	0	0	100.00	0.00	
900	0	716	103	0	0	0	0	81	79.56	9.00	
900	0	0	806	3	0	7	0	84	89.56	9.33	
900	0	0	2	483	41	0	16	358	53.67	39.78	
900	0	0	0	77	426	0	50	347	47.33	38.56	
900	0	1	16	0	0	798	4	81	88.67	9.00	
900	0	0	0	7	15	0	769	109	85.44	12.11	
%Promedio										77.75	16.83
VERIFICACION										% Acerto	% Falla
Nºejemplos	REPOSO	FLEXION	EXTENSION	PRONACION	SUPINACION	APERTURA	CIEBRE	NO RECON			
450	448	0	0	0	0	0	0	2	99.56	0.44	
225	0	191	12	0	0	5	0	17	84.89	7.56	
225	0	8	182	1	0	8	0	26	80.89	11.56	
225	0	0	0	117	14	0	16	78	52.00	34.67	
225	0	0	0	13	102	0	43	67	45.33	29.78	
225	0	0	9	1	1	173	3	38	76.89	16.89	
225	0	0	0	1	11	0	183	30	81.33	13.33	
%Promedio										74.41	16.32

La primera columna corresponde a la cantidad de ejemplos que se pasaron por movimiento, las siguientes 7

columnas indican cuantos movimientos pudieron ser clasificados y la última columna indica la cantidad de movimientos que no se pudieron clasificar. Las columnas que contienen los porcentajes de acierto y falla indican en qué proporción se acertó o falló en la clasificación de los movimientos.

5. ANALISIS DE RESULTADOS

Cada configuración se corrió en tres oportunidades, y los resultados expuestos corresponden a la mejor respuesta. Esto se hace porque el algoritmo es propenso a caer en mínimos locales y se hace necesario realizar varias corridas de la RNA.

El mejor desempeño de la red se logró al entrenar con la base de datos completa (13 columnas) y con 25 neurodos. Aunque el rendimiento no es el más óptimo si se logra alcanzar un muy buen porcentaje de reconocimiento (en comparación con el 30% alcanzado con Fourier); esto es debido al comportamiento no estacionario de la señal mioeléctrica. Sin embargo cabe anotar que existen 2 movimientos en los cuales su desempeño es pobre (pronación y supinación) aún así la hipótesis es que al aumentar los ejemplos en la base de entrenamiento, estos 2 movimientos se puedan reconocer mejor.

Es importante resaltar, al observar las gráficas de error, que los valores iniciales son bajos en comparación a los de Fourier y que la curva del error de verificación tiende a seguir a la del error de validación.

Al aumentar o disminuir la cantidad de neurodos de la capa oculta no se obtuvo una mejoría significativa en el desempeño de la red. A partir de la experiencia se puede decir que al reducir el número de columnas (nodos de entrada - N) no se obtiene un mejor desempeño sino que por el contrario los resultados son más pobres.

También se puede apreciar que la RNA no se confunde fácilmente, es decir, o acierta o falla pero no da una respuesta errónea.

REFERENCIAS

1. ADRIAN del Boca, Dong C. Park. "Myoelectric signal recognition using fuzzy clustering and artificial neural networks in real time". IEEE Transactions on Biomedical Engineering, jun. 1990.
2. BEKEY, G. A., CHANG, C. W., PERRY, J. y HOFFER, M. M. Pattern recognition of multiple EMG signals applied to the description of human gait. *En*: Proceedings of the IEEE. Vol. 65, No. 5 (Mayo 1.977); p. 674-681.

3. BOWKER, John H y MICHAEL, John W. Atlas of links prosthetics: Surgical, prosthetic, and rehabilitation principles. St Louis: Mosby Year Book.1.992.
4. BRONZINO, Joseph. Biomedical engineer handbook. 1 ed. Boca Ratón, Florida: CRC Press - IEEE Press. 1.995.
5. BUNGE, Mario. La investigación científica. Su estrategia y filosofía. 2 ed. Barcelona: Editorial Ariel. 1985.
6. CARR, Joseph J. y BROWN, John M. Introduction to biomedical equipment technology. 3 ed. Upper Saddle River, New Jersey: Prentice-Hall, 1.998.
7. CHEN, C.H. Fuzzy logic and neural network handbook. 1 ed. New York: McGraw-Hill.1.996.
8. CHEN, Wai-Kai. The circuits and filters handbook. 1 ed. Boca Ratón, Florida: CRC Press - IEEE Press 1.995.
9. CONGRESO DE LA REPÚBLICA DE COLOMBIA. Ley 100 de 1.993. Sistema de seguridad social integral.
10. CONGRESO DE LA REPÚBLICA DE COLOMBIA. Ley 30 de 1.992. Servicio público de la educación superior.
11. DORATO, Peter and YEDAVALLI, Rama K. Recent advances in robust control. 1 ed. IEEE Press. 1.990.
12. EMBREC, Paul. C++ Algorithms for Real Time DSP. Prentice Hall, 1999.
13. GABRIUNAS, Vytautas. "Apuntes de electrónica". Universidad Distrital "Francisco José de Caldas", Bogotá, 1999.
14. Grisales Víctor, Sánchez Carlos, Rosas Fernando, Barrero Vladimir, León Juan. "Extracción de características relevantes y reconocimiento de señales EMG mediante una red neuronal tipo perceptrón multicapa". CIIC2001, Congreso Internacional en Inteligencia Computacional, Medellín - Colombia, 2001. ISBN: 958-9352-28-6.
15. HARRIS, Gerald F. y SMITH, Peter A. Human motion analysis. Current applications and future directions. 1 ed. IEEE Press. 1.996.
16. HERNÁNDEZ SAMPIERI, Roberto, FERNÁNDEZ COLLADO, Carlos, BAPTISTA LUCIO, Pilar. Metodología de la investigación. 1 ed.. Naucalpan de Juárez: McGraw-Hill, 1.991.
17. LEVINE, William S. The control handbook. 1 ed. Boca Ratón, Florida: CRC Press - IEEE Press. 1.995.
18. LINDSTRÖM, L. H. y MAGNUSSOM, R.I. Interpretation of myoelectric power spectra: a model and its applications. En: Proceedings of the IEEE. Vol. 65, No. 5 (Mayo 1.977); p.653-662.
19. LOONEY, Carl G. Pattern recognition using neural networks: Theory and algorithms for engineers and scientists. Oxford University Press, 1997.
20. MADISETTI, Vijai K. and WILLIAMS, Douglas B. The digital signal processing handbook. 1 ed. Boca Ratón, Florida: CRC Press - IEEE Press. 1.998.
21. Motors&Gearmotors. "Handbook of metric drive components". Capítulo 14 (motores y reductores).
22. NISHIKAWA Kaduhiko, Katsutoshi Kuribayashi. "Neural Network Application to a discrimination system for controlled prostheses". IEEE/RSJ International Workshop on Intelligent Robots and Systems, nov. 1991.
23. OH, Shin J. Clinical electromiography: Nerve conduction studies. 2 ed. s. l.: Williams & Wilkins.
24. OPPENHEIM Alan V, Discrete Time Signal Processing, Prentice Hall, 1999.
25. PARKER, P. A. , STULLER, J. A. y SCOTT, R. N. Signal processing for the multistate myoelectric channel. En: Proceedings of the IEEE. Vol. 65, No. 5 (Mayo 1.977); p. 662-674.
26. POULARIKAS, Alexander D. The transforms and applications handbook. 1 ed. Boca Ratón, Florida: CRC Press - IEEE Press 1.996.
27. PROAKIS, John G., MANOLAKIS, Dimitris G. Tratamiento digital de señales: Principios, algoritmos y aplicaciones. 3 ed. Madrid: Prentice may. 1998.
28. SMITH, Steven W, The Scientist and Engineer's Guide to digital signal processing, . California Technical Publishing ISBN 0-9660176-3-3 (1997).