

TELEDIAGNOSIS OF PARKINSON'S DISEASE USING FUZZY CLASSIFIER
CLASIFICADOR DIFUSO PARA DIAGNÓSTICO DEL MAL DE PARKINSON
VÍA TELEFÓNICA

Vanessa Caraballo, Cristian Cuadrado, Erick Herazo, Benjamín Pérez
PhD. Juan Antonio Contreras Montes

Escuela Naval de Cadetes Almirante Padilla
Escuela Naval Almirante Padilla, Facultad de Ingeniería Naval
Cartagena, Colombia., Tel.: 57-5-6694124
E-mail: epcontrerasj@ieee.org

Abstract: We present a novel method for diagnosis of Parkinson's disease by measuring of dysphonia. A fuzzy identification method is applied for discriminating healthy people from people with Parkinson's disease. The main aim is to discriminate healthy people from those with Parkinson disease from a dataset what is composed of a range of biomedical voice measurements from 31 people, 23 with Parkinson's disease (PD). The overall correct classification performance is upper than 95%.

Keywords: Parkinson's disease, dysphonia, fuzzy classifier, telemedicine

Resumen: En este artículo se presenta un novedoso método para el diagnóstico de la enfermedad de Parkinson a partir de una medida de disfonía. Se describe la aplicación de un algoritmo difuso de aproximación como clasificador para diferenciar entre pacientes saludables y pacientes con la enfermedad de Parkinson utilizando como entradas medidas de la voz del paciente que pueden ser adquiridas vía telefónica. Se presentan aplicaciones para el diagnóstico de la enfermedad de parkinson a partir de una base de datos que contiene 23 atributos relacionados con la medida de disfonía en los pacientes consultados, alcanzando una precisión superior al 95%.

Palabras clave: enfermedad de Parkinson, disfonía, clasificador difuso, telemedicina.

1. INTRODUCCIÓN

La enfermedad de Parkinson es una enfermedad degenerativa del sistema nervioso, un trastorno que afecta las células nerviosas, o neuronas, en una parte del cerebro que controla los movimientos musculares. Esto es ocasionado por la disminución en la producción de una sustancia química llamada dopamina debido a la muerte paulatina de las neuronas que producen. La dopamina se encarga de enviar señales que ayudan a coordinar los movimientos.

Los síntomas de la enfermedad de Parkinson pueden incluir: temblor en las manos, los brazos, las piernas, la mandíbula y la cara; rigidez en los brazos, las piernas y el tronco; lentitud de los movimientos y problemas de equilibrio y coordinación.

A medida que los síntomas empeoran, puede presentarse otros problemas como depresión, trastornos del sueño o dificultades para masticar, tragar o hablar.

El diagnóstico de un paciente con la enfermedad de Parkinson se hace tomando como base los síntomas de la persona y su historial médico. No existe ninguna prueba de sangre ni ninguna radiografía que pueda mostrar si una persona tiene la enfermedad de Parkinson, aunque algunos tipos de rayos x pueden ayudar al especialista para asegurarse que no es algo más lo que está causando los síntomas presentes en el paciente.

Estudios muestran que el 90% de los pacientes afectados con la enfermedad de Parkinson presentan trastorno de la voz (Ho et al., 1998), o disfonía, por lo que ese trastorno puede ser considerado como un indicador temprano del mal de Parkinson (Duffy, 2005). Es decir, la medida de la voz puede ser útil para descubrir y rastrear la progresión de los síntomas del parkinson (Rosen et al, 2006), lo que ha motivado un creciente número de investigaciones para detectar esta enfermedad a partir de un análisis de la voz (Little et al., 2008; Sakar and Kursun, 2009;), con el fin de poder diagnosticar al paciente de manera remota evitándole el traslado al sitio de atención médica.

2. CLASIFICADOR BORROSO

El algoritmo de clasificación se basa en un algoritmo de identificación borrosa (Contreras et al., 2007a; Contreras et al., 2008) que es empleado para aproximar a una función discontinua que representa valores numéricos asignados a cada clase.

2.1 Algoritmo de Identificación Borrosa

El algoritmo para generación de sistemas borrosos interpretables a partir de los datos se basa en la minimización del error de inferencia. El usuario solo debe introducir los datos de las variables de entrada y salida. El algoritmo determina los rangos de cada variable, distribuye las funciones de pertenencia en los universos de cada variable de entrada, ubica los consecuentes tipo *singleton* en el espacio de salida, determina las reglas y ajusta la ubicación de los consecuentes, empleando mínimos cuadrados, para minimizar el error de aproximación. El algoritmo se detiene cuando se ha alcanzado una métrica de error menor a la requerida por el usuario o cuando el número de conjuntos borrosos por variable de entrada es mayor a 9. La distribución de las funciones de pertenencia en cada universo de entrada se hace de manera uniforme para garantizar que la partición resultante sea suma 1; es decir, la suma de los grados de pertenencia de un dato en una variable de entrada será siempre igual a 1.

Dado una colección de datos experimentales de entrada y salida $\{x_k^{(i)}, y^{(i)}\}$, con $i = 1 \dots N$; $k = 1, \dots, p$, donde $x_k^{(i)}$ es el vector de entrada p -dimensional $x_1^{(i)}, x_2^{(i)}, \dots, x_p^{(i)}$ e $y^{(i)}$ es el vector unidimensional de salida

- Organización del conjunto de p variables de entrada y una variable de salida, cada una con N datos.




Fig. 1: Organización del conjunto de datos

- Determinación de los rangos de los universos de cada variable de acuerdo a los valores máximos y mínimos de los datos asociados $[x_k^-, x_k^+]$, $[y^-, y^+]$.
- Distribución de las funciones de pertenencia triangulares sobre cada universo. Se tiene como condición general que el vértice con valor de pertenencia uno (valor modal) cae en el centro de la región cubierta por la función de pertenencia mientras que los otros dos vértices, con valor de pertenencia iguales a cero, caen en los centros de las dos regiones vecinas. Para poder aproximar eficientemente los extremos inferior y superior de una función representada por los datos es necesario que en la partición triangular las funciones de pertenencia que cubren el inicio y final del universo coincidan sus vértices con valor de pertenencia uno con sus vértices izquierdo y derecho respectivamente, como se aprecia en la figura 2. Se inicia con $n = 2$ conjuntos triangulares.




Fig. 2: Partición triangular suma 1. a) partición inicial, $n=2$; b) partición con $n = 5$

- Cálculo de la posición de los valores modales de la(s) variable(s) de entrada, de acuerdo a

$$\text{Si } u_{A_k^{(n)}}(x_k^{(i)}) = 1$$

$$\text{Entonces, } yS_k^{(n)} = y[i] \quad (7)$$

Donde $y_s^{(n)}$ corresponde a la proyección sobre el espacio de salida de la evaluación del dato $x^{(i)}$ de la k -ésima variable de entrada en el n -ésimo conjunto de la partición correspondiente. El valor de la salida correspondiente a dicha proyección está dado por el valor de la i -ésima posición del vector de salida y , el cual se constituye en el singleton asociado a ese conjunto. De esta manera se aplica el criterio de error de inferencia nulo empleando consecuentes tipo singleton.

- e. Determinación de las reglas. El número máximo de reglas está determinado por el número de conjuntos de cada variable de entrada multiplicado por el número de variables; es decir igual a $n \times k$, que es igual al número de singletons generados en el paso anterior. Cuando existen singletons ubicados en la misma posición, se combinan los antecedentes de acuerdo a (4) en una sola regla, lo que permite reducir el número de reglas.
- f. Validación del modelo empleando el método de inferencia descrito por (5), donde \bar{y}^j es el valor del singleton correspondiente a la regla j .
- g. Ajuste de los parámetros, reubicando los singletons de salida mediante el empleo del método de mínimos cuadrados. La ecuación (5) puede expresarse de la forma

$$f(x^{(i)}) = \sum_{j=1}^L w_j(x^{(i)}) \bar{y}^j \quad (8)$$

Donde

$$w_j(x^{(i)}) = \frac{m_j(x^{(i)})}{\sum_{j=1}^L m_j(x^{(i)})} = w_j^i \quad (9)$$

La ecuación (8) puede expresarse en forma matricial como $Y = Wq + E$, donde Y representa los valores de salida reales, Wq representa la salida del modelo borroso, siendo W es la matriz de grados de pertenencia obtenida de (9) y q el vector de consecuentes, y E es el error de aproximación que debe ser minimizado. Es decir:

$$\begin{bmatrix} y^1 \\ y^2 \\ \vdots \\ y^L \end{bmatrix}_Y = \begin{bmatrix} w_1^1 & w_2^1 & \dots & w_L^1 \\ w_1^2 & w_2^2 & \dots & w_L^2 \\ \vdots & \vdots & \ddots & \vdots \\ w_1^n & w_2^n & \dots & w_L^n \end{bmatrix}_W \begin{bmatrix} -1 \\ y \\ -2 \\ y \\ \vdots \\ -L \\ y \end{bmatrix}_q + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix}_E \quad (10)$$

Empleando la norma del error cuadrático se tiene

$$E^2 = (Y - Wq)^2 = (Y^2 - 2YWq + (Wq)^2) \quad (11)$$

La solución a este problema de mínimos cuadrados está dada por

$$\frac{\partial E^2}{\partial q} = 0 = -2YW + 2W^T Wq \quad (12)$$

de donde se obtiene

$$q = \frac{Y^T W}{W^T W} = (W^T W)^{-1} Y^T W \quad (13)$$

Esta solución es válida si $(W^T W)$ es no singular, lo que quiere decir que todas las reglas deben recibir suficiente excitación durante el entrenamiento. En la práctica esto no es siempre posible, por lo que es recomendable recurrir a la aplicación de mínimos cuadrados recursivos, buscando garantizar que la adaptación solo afecte las reglas excitadas

- h. Terminar si la medida del error cuadrático medio MSE es menor a una medida previamente establecida ó si el número de conjuntos por variable de entrada es mayor a 9. De otra manera, incrementar en 1 el número n de conjuntos de la variable de entrada y volver al paso c).

Con el algoritmo descrito se consigue un modelo borroso interpretable con una buena precisión y solo se requiere del ajuste de los parámetros del consecuente, que son tipo singleton, lo que disminuye el tiempo de entrenamiento. Es posible lograr una mayor aproximación ("ajuste fino") si al finalizar el proceso mencionado se aplica el método del gradiente descendiente para ajustar la ubicación de los valores modales de los conjuntos triangulares del antecedente, conservando la partición suma 1 y, por lo tanto la interpretabilidad del sistema, como explica Espinosa et al. (2005).

3. DESCRIPCIÓN DEL PROBLEMA

El objetivo es poder discriminar las personas saludables de aquellas que padecen el mal de parkinson, a partir de información extraída de una base de datos creada por Max Little, de la Universidad de Oxford, en colaboración con el National Centre for Voice and Speech, en Denver, Colorado, quienes grabaron las señales de voces (Max Little et al, 2007, 2008).

La base de datos está compuesta por una serie de medidas biomédicas de la voz realizada a 31 personas, 23 de ellas afectadas por el mal de Parkinson. Cada columna en la tabla representa una particular medida de la voz. La columna 17, denominada "status", asigna 0 para las personas saludables y 1 para las que padecen de Parkinson. Cada fila corresponde a cada una de las 195 grabaciones realizadas a cada uno de los individuos participante. Hay alrededor de seis grabaciones por paciente. Los datos están en un formato ASCII CSV.

La tabla o matriz de datos tiene los siguientes atributos:

- name – ASCII: identificación del paciente y número de la grabación
- MDVP:Fo(Hz): Promedio de la frecuencia fundamental vocal
- MDVP:Fhi(Hz): Máximo de la frecuencia fundamental vocal
- MDVP:Flo(Hz): Mínimo de la frecuencia fundamental vocal
- MDVP:Fluctuación(%),
- MDVP:Fluctuación(valor absoluto),
- MDVP:RAP,MDVP:PPQ,Jitter:DDP: Varias medidas de la variación en la frecuencia fundamental
- MDVP:Shimmer,MDVP:Shimmer(dB),Shimmer:APQ3,Shimmer:APQ5,MDVP:APQ,Shimmer:DDA: Varias medidas de la variación en amplitud
- NHR, HNR: Dos medidas de la relación de ruido a componentes tonales en la voz
- Status: estado de la salud: Persona saludable (1) –Persona con mal de parkinson (0)
- RPDE, D2: Dos medidas de la complejidad dinámica no lineal
- DFA: exponente de escala de la señal fractal
- spread1, spread2, PPE: Tres medidas no lineales de la variación de la frecuencia fundamental

4. RESULTADOS

El proceso de entrenamiento se realizó de tal manera que el modelo difuso aproximara a la función discontinua de 1 y 0 dada por el estado del paciente. Es decir, el modelo borroso

inicialmente generado es más un aproximador que un clasificador. Se consideraron las 22 variables de entrada y se realizaron pruebas variando el número de conjuntos difusos desde 2 hasta 9. Es decir, el número de conjuntos difusos triangulares (y por ende de reglas) variará entre un máximo de 44 (para 2 conjuntos difusos por variable de entrada) hasta un máximo de 198 (para 9 conjuntos difusos por variable de entrada). La figura 3 muestra la variación del error cuadrático medio con respecto al número de conjuntos difusos por variable de entrada.




Fig. 3: Variación del error cuadrático medio del modelo borroso con respecto al número de conjuntos difusos por variable de entrada

A manera de ilustración, consideremos 3 conjuntos difusos por variable de entrada. Las etiquetas para los conjuntos difusos se pueden asignar como Bajo S, Medio M y Grande B. En este caso habrá 66 consecuentes tipo *singleton*. La salida del modelo difuso estará dada por

El modelo borroso toma los datos de entrada y genera una salida que trata de aproximarse a la salida real (estado del paciente), como se muestra en la figura 4.




Fig. 4: Comparación entre la salida real (estado real del paciente) y la salida del modelo borroso

En el caso del diagnóstico de parkinson que se trata en esta investigación, la salida del modelo borroso debe tomar solo dos valores: 1 y 0. Por lo tanto, se procedió a agregar a la salida del modelo una función de discriminación, así:

Si y^L es mayor a 0.5, entonces
 y^L se hace igual a 1

En caso contrario
 y^L se hace igual a 0

De esta manera se consiguió la aproximación mostrada en la figura 5, donde las "x" indican el diagnóstico del modelo borroso y las "o" indican el diagnóstico real




Fig. 5. Comparación entre el diagnóstico real (o) y el diagnóstico del modelo borroso (x)

Se puede apreciar que el sistema solo presentó 8 desaciertos en 195 diagnósticos; es decir, presenta una efectividad del 95.9%, la cual es superior a la encontrada en la literatura, la cual es del 95% (Little et al, 2008)

5. CONCLUSIONES

Se presentó un método de clasificación basado en lógica borrosa para detección de la enfermedad de Parkinson a partir del análisis de la voz. El método de clasificación es una derivación de un método de aproximación difusa que el autor ha desarrollado y aplicado anteriormente para el modelamiento de procesos complejos, y que solo requiere de la introducción del conocido condicional *IF-THEN-ELSE* para ser empleado como clasificador.

En el proceso de entrenamiento o de construcción de la estructura del modelo borroso no se requiere del apoyo de otras técnicas de Inteligencia Artificial, como redes neuronales o algoritmos genéticos; es decir, no es una técnica híbrida

El método propuesto alcanza la mayor precisión obtenida hasta ahora en la detección de la enfermedad de Parkinson a partir del análisis de la voz, lo que se constituye en un apoyo vital para el fomento de la telemedicina.

REFERENCIAS

- Contreras, J., Misa, R., Murillo, L., Paz J., Sarabia J. (2007). *Obtención de Modelos Borrosos Interpretables de Procesos Dinámicos*. RIAI: Revista Iberoamericana de Automática e Informática Industrial, vol. 5, No. 3, pp. 70-77.
- Contreras, J., Misa, R., Murillo, L., Paz J., Sarabia J. (2007) *Identificación Borrosa Eficiente Basada en Error de Inferencia*. Revista Tecnologías Avanzadas. Vol.1, No.9, pp. 62-67. Universidad de Pamplona. Colombia.
- Duffy, J.R., (2005). *Motor speech disorders: substrates, differential diagnosis, and management*. 2nd ed. St. Louis, Mo.: Elsevier Mosby.
- Ho, A.K., Lansek, R., Marigliani, C., Bradshaw, J.L. and Gates, S. (1998). *Speech impairment in a large sample of patients with Parkinson's disease*. Behav Neurol, vol. 11, pp. 131-137.
- Little, M. A., McSharry, P. E., Hunter, E. J., Ramig, L. O. (2008). *Suitability of dysphonia measurements for telemonitoring of Parkinson's disease*. IEEE Transactions on Biomedical Engineering, 56(4):1015-1022.
- Rosen, K. M., Kent, R. D., Delaney, A. L., and Duffy, J. R. (2006). *Parametric quantitative acoustic analysis of conversation produced by speakers with dysarthria and healthy speakers*. Journal of Speech, Language and Hearing Research, vol. 49, pp. 395-411
- Sakar, C. O., Kursun, O. (2009). *Telediagnosis of Parkinson's Disease Using Measurements of Dysphonia*. Journal of Medical Systems