

# Aplicación de la Minería de Datos al Diagnóstico y Evaluación de la Enfermedad de Parkinson, mediante la Voz

## Primera parte: Minería de Datos

Francisco Díaz Pérez  
Alfonsa García López



## 1. Introducción a la Minería de datos

## 2. Problemas de Clasificación

### 2.1 Conceptos generales

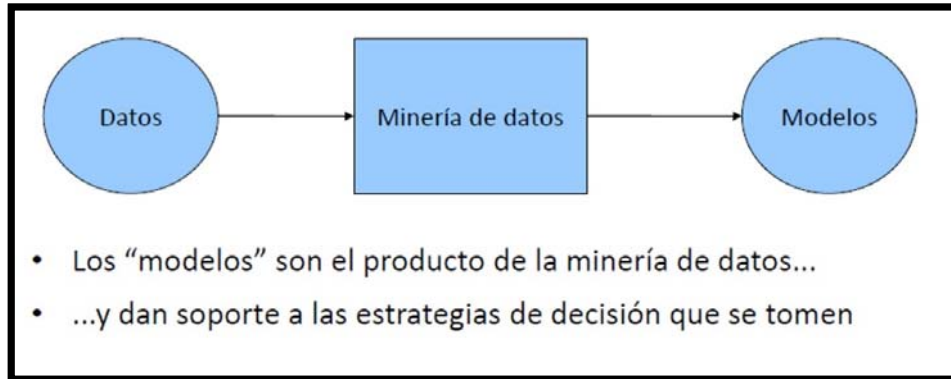
### 2.2 Evaluación de los modelos

### 2.3 Algoritmos de clasificación

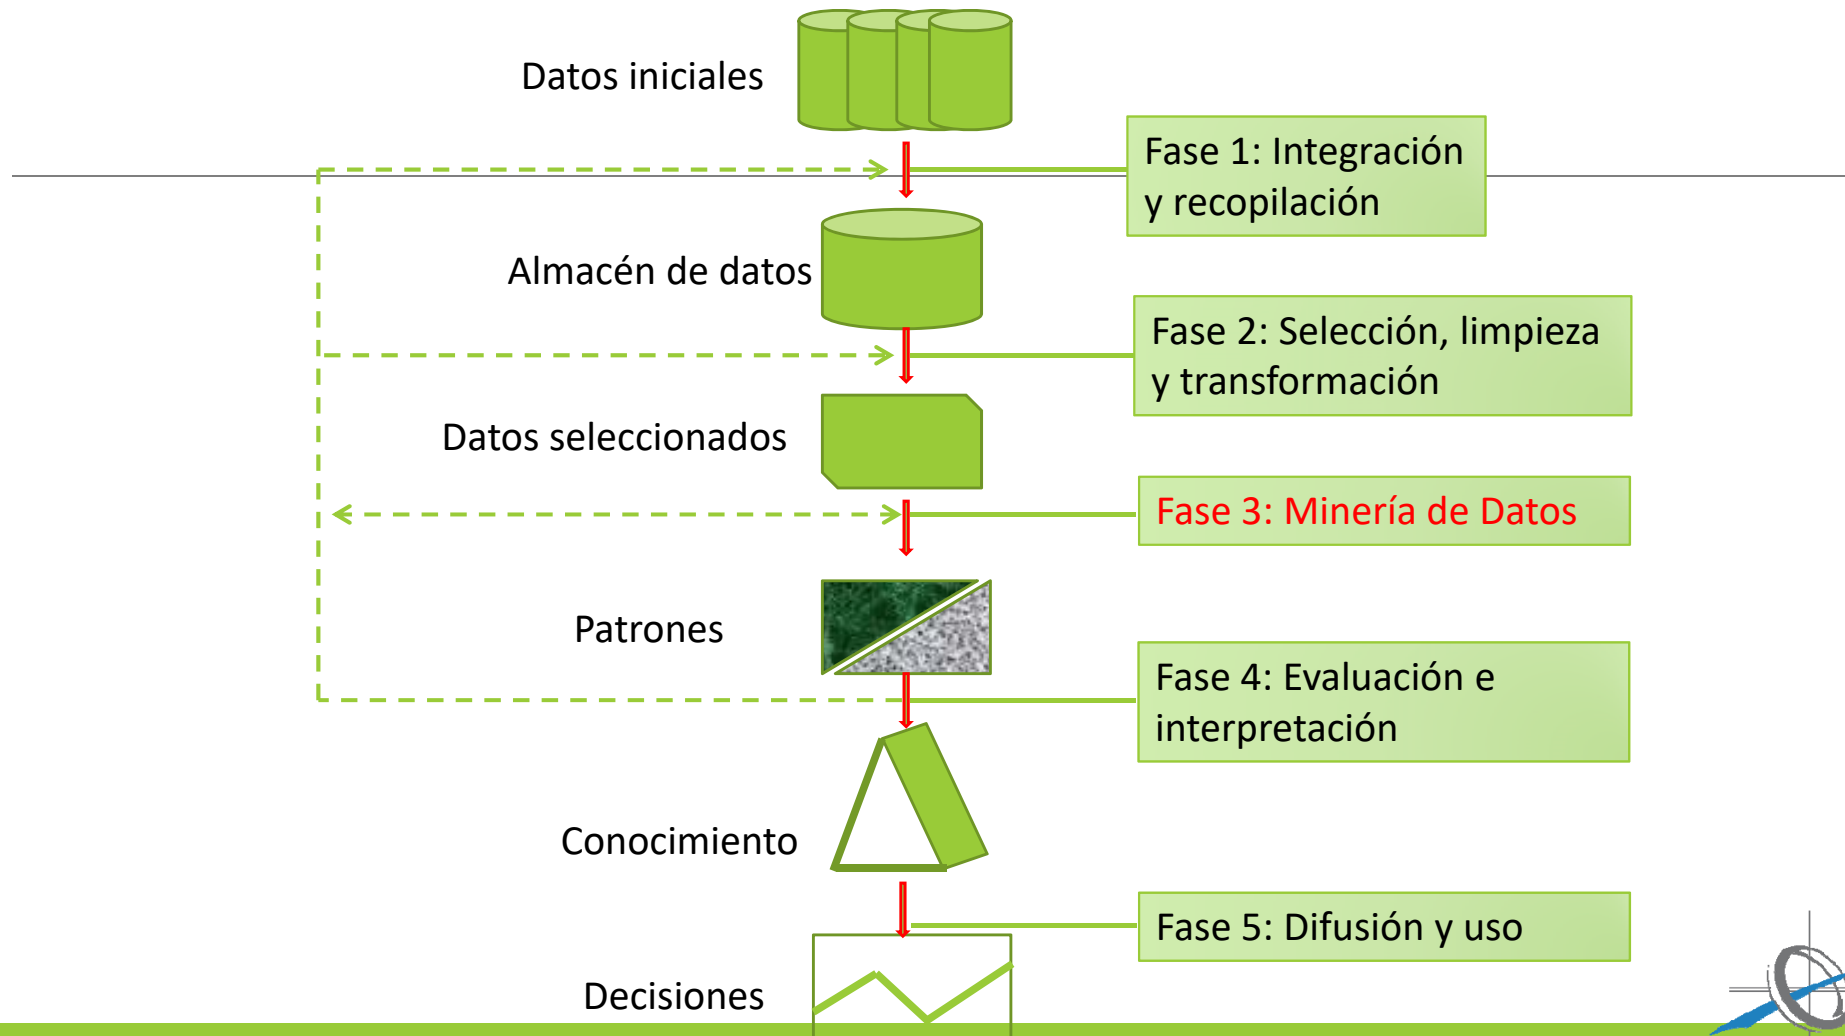
## 3. Algunas referencias

## 1. Introducción a la Minería de Datos

- La Minería de Datos (Data Mining) comprende una serie de **técnicas, algoritmos y métodos** cuyo fin es la exploración y análisis de grandes volúmenes de datos con vistas al **descubrimiento de información previamente desconocida** y que pueda servir de ayuda en el proceso de **toma de decisiones**.
- No existe un solo enfoque sino un conjunto de técnicas que se pueden usar de manera independiente o combinada.



## Encuadrada en el proceso del Análisis Inteligente de Datos

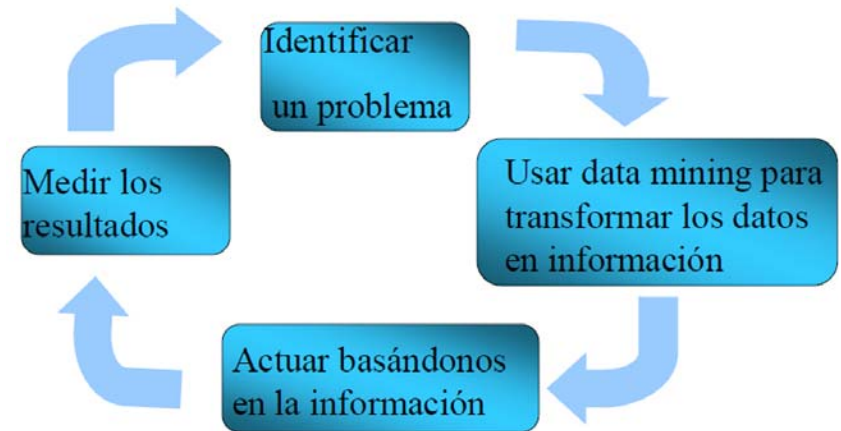


## Técnicas de Minería de Datos

**Técnicas descriptivas:** Orientadas a describir un conjunto de datos (incluyen métodos estadísticos tradicionales, como análisis de varianza, análisis discriminante, contrastes de hipótesis, componentes principales, etc.)

**Técnicas predictivas:** Orientadas a encontrar un modelo para estimar valores de salida de una variable (respuesta) a partir de los datos de un conjunto de variables (predictores).

### El ciclo de data mining



## Problemas típicos de Minería de Datos

- **Problema de Clasificación:** Partiendo de un conjunto de observaciones, con los valores de  $p$  variables  $X_1, \dots, X_p$  (**atributos** o **características**) y el de la variable **categorica**  $Y$  (denominada **respuesta**) correspondiente a cada observación, se pretende **separar** los datos según los valores de  $Y$ .
- **Problema de Regresión:** Partiendo de los valores de los atributos  $X_1, \dots, X_p$ , en el conjunto de datos de entrenamiento, y de una variable respuesta  $Y$  (**que puede ser discreta o continua**), se pretende definir una función modelo  $Y=f(X_1, \dots, X_p)$ .
- **Reducción Dimensional** (selección de características) Cuando el número  $p$  de variables predictoras es grande puede haber problemas por información redundante y hay que intentar eliminar del modelo variables innecesarias.

## 2. Problema de Clasificación


Partiendo de unos **datos de entrenamiento**, con los valores de las variables  $X_1, \dots, X_p$  (**características**) y el de la variable categórica  $Y$  (**respuesta**) correspondiente a cada observación, se pretende separar los datos según los valores de  $Y$  (de modo que se pueda determinar el valor de  $Y$  a partir de los valores de  $X_1, \dots, X_p$ )

Cuando la variable respuesta  $Y$  solo toma dos valores distintos, se dice clasificación **binaria**.

Por ejemplo las  $X$  pueden ser características de una grabación de voz, cada registro contiene los valores de cada una de las características para una persona y la respuesta  $Y$  puede ser  $Y=1$  si la persona tiene Parkinson,  $Y=-1$  si no lo tiene.


**Objetivo:** Encontrar un **modelo de clasificación**, es decir una función  $G$  tal que  $G(X)=Y$ . Para ello se intenta separar los datos en regiones mediante una **frontera de decisión** (si existen hiperplanos que separan los datos, según los valores de  $Y$ , se dice que hay **frontera lineal**).

**Clasificador:** Aproximación sistemática a un modelo, construido usando un Algoritmo de aprendizaje



## 2.1 Conceptos generales

- Para construir el modelo se usan **algoritmos de aprendizaje** que puede ser **supervisado** (cuando el conocimiento de los valores de la variable respuesta guía el aprendizaje) o **no supervisado**, cuando no se usan los valores de la variable respuesta.
- **Training set**: Conjunto de instancias de entrenamiento que se usan en el algoritmo de aprendizaje para definir el modelo.
- **Test set**: Conjunto de instancias de prueba que se usan para ver la eficacia del modelo.



Se dice que el Training set es linealmente separable si existe un hiperplano que pueda separar los datos de acuerdo con los valores de la variable Y.

Para elegir el modelo, el algoritmo de aprendizaje necesita evaluar de algún modo el error del clasificador



## Métodos para seleccionar los conjuntos Training y Test

**Holdout:** Se reparten los registros disponibles en dos grupos (mitad y mitad ó 2/3 y 1/3), se usa un grupo para entrenar y otro para probar.

- Inconvenientes:
- Menos registros para entrenar (mayor varianza).
  - El modelo puede depender de la partición.
  - Las dos clases no están igualmente representadas.

**Randon Subsampling:** Repetir Holdout k veces, con particiones aleatorias y tomar como tasa de la media aritmética de las de las k pruebas.

Inconveniente: Unos registros se pueden usar muchas veces para entrenar y otros pocas.

**Cross-Validation (CV):** Es el más usado. Todos los registros se usan el mismo número de veces para entrenar y una vez para testear.

**K-fold CV:** Se distribuyen los registros en k subconjuntos de igual tamaño. Repetimos el algoritmo k veces y en cada una se utiliza uno de los subconjuntos como Test set y la unión de los k-1 restantes como Training set.

El más barato es con k=2, cada registro se usa una sola vez para entrenar y una para testear. El más caro es k=N (leave-one-out).

**Bootstrap** Se entrena con datos elegidos aleatoriamente, con reemplazo. Con N registros y N extracciones, la probabilidad de que un registro concreto esté entre ellos es  $1-(1-1/N)^N$ , que converge a  $1-1/e \approx 0.632$ . Luego el Training set tendrá aproximadamente el 63% de los registros y el resto se usan para el Test set.

## 2.2 Evaluación de los modelos

Supongamos un problema de clasificación binaria cuya variable respuesta toma valores 1 y -1.

Se propone un modelo y se aplica a los registros de los conjuntos de entrenamiento y prueba se asigna a cada caso uno de los siguientes valores:

TP	El modelo lo predice como positivo y acierta ( $G(X)=1=Y$ )
TN	El modelo lo predice como negativo y acierta ( $G(X)=-1=Y$ )
FP	El modelo lo predice como positivo y falla ( $G(X)=1, Y=-1$ )
FN	El modelo lo predice como negativo y falla ( $G(X)=-1, Y=1$ )

**Training error:** Número de clasificaciones incorrectas sobre los registros de entrenamiento.

**Generalization error:** Error esperado del modelo, que se estima mediante la evaluación en los registros del conjunto de prueba.

**Overfitting:** Training error pequeño, pero error grande en los datos de prueba.

## Métricas (clasificación binaria)

- Matriz de confusión: esquematiza valores predichos y reales

		Valores predichos	
		+	-
Valores reales	+	TP	FN
	-	FP	TN

TP= Número de registros con valor True Positive,  
 TN= Número de True Negative,  
 FP = Número de Falsos Positivos  
 FN = Número de Falsos Negativos

En la diagonal principal: aciertos. En la secundaria: fallos.

- Éxito= Predicciones Correctas/total predicciones  $Acc = \frac{TP+TN}{TP+TN+FP+FN}$
- Error= Predicciones Fallidas/total predicciones  $\frac{FP + FN}{TP + TN + FP + FN}$
- Coef. de correlación de Mathews:  

$$MCC = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$

Si está cerca de 1 el modelo es bueno y cerca de -1 es muy malo

## Problemas no equilibrados

- En algunos problemas de clasificación la cantidad de etiquetas positivas es significativamente inferior a la de etiquetas negativas (Ej: problema del abandono universitario, usos fraudulentos de tarjetas de crédito, prevalencia de ciertas enfermedades, etc.)
- La tasa de éxito puede no ser medida adecuada (por ejemplo si solo el 0.2% de las operaciones realizadas con una tarjeta de crédito son fraudulentas, un modelo predictivo con una tasa de éxito del 99% no vale para nada).
- En casos así interesa conocer la tasa de aciertos entre los positivos.

## Métricas alternativas


- **Sensitividad o Recall:** fracción de positivos predichos correctamente por el modelo (TPR)  $R = TP/(TP+FN)$ .
- **False Positive Rate:** fracción de negativos predichos como positivos  $FPR = FP/(TN+FP)$ .
- **Especificidad:** fracción de negativos predichos correctamente por el modelo:  $TNR = TN/(TN+FP)$ .
- **Precisión:**  $Pr = TP/(TP+FP)$  (tasa de acierto en los clasificados como positivos)
- **Fscore:** media armónica de precisión y recall  $F = \frac{2PrR}{Pr+R} = \frac{2TP}{2TP+FP+FN}$

El modelo predice  $G(X)=-1$ , para todo  $X \Rightarrow R=FPR=Pr=0$   
El modelo predice  $G(X)=1$ , para todo  $X \Rightarrow TPR=FPR=R=1$   
 $R=1, FPR=0 \Rightarrow$ Modelo ideal

Puede ser  $R=1$  y  $Pr$  puede ser pequeña.  
Como la media armónica de dos números está más cerca del más pequeño,  
si  $F$  es grande, tanto  $Pr$  como  $R$  deben ser grandes

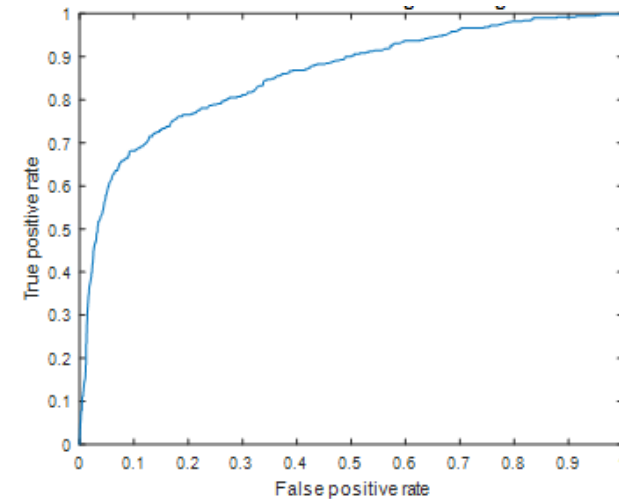
## Receiver Operating Characteristic Curve

1. Representación del rendimiento de un clasificador
2. El espacio ROC es un cuadrado unidad en el que se representa TPR frente a FPR
3. Como lo mejor que podría ocurrir es que  $TPR=1$  y  $FPR=0$ , un buen modelo debe estar localizado en la parte superior izquierda del cuadrado unidad  $[0,1]$ .
4. Un clasificador aleatorio que asigne  $+1$  y  $-1$  a cada registro con una probabilidad  $p$  estará sobre la diagonal del cuadrado.
5. Un clasificador es bueno si está por encima de la diagonal. Si invertimos los valores (cambiando  $1$  por  $-1$ ) de un mal clasificador ( $C$ ) tendremos un buen clasificador ( $C'$ ).
6. Lo que marca el poder de predicción de un modelo es la distancia a la línea de predicción aleatoria.
7. Para poder dibujar la curva el modelo debe ser capaz de generar una salida continuamente evaluada, de los registros con mayor probabilidad de ser clasificados como positivos a los de menor probabilidad.
8. Para determinar un punto de la curva, se toma un valor umbral (por ejemplo  $0.8$ ), si la probabilidad de una instancia es mayor o igual que  $0.8$  se predice como positiva y si es menor como negativa. Se obtiene la matriz de confusión y se dibuja el punto correspondiente. Variando los valores del umbral, se tienen nuevos puntos de la curva.



## Generando una curva ROC con Matlab

```
% Obtenemos un modelo de clasificación
% Calculamos curva ROC, usando la probabilidad estimada
% En la variable Respuesta tenemos los valores reales
% En scores, la distribución de probabilidad del clasificador
[X,Y,T,AUC]=perfcurve(Respuesta, scores,'1');
disp('Area bajo la curva')
AUC
%Si el área bajo la curva es cercana a 1, el modelo es bueno
%Dibujar la curva:
plot(X,Y)
xlabel('False positive rate')
ylabel('True positive rate')
title('Curva ROC del modelo de regresión logística')
```



## 2.3 Algoritmos de clasificación

- Análisis Discriminante Lineal (LDA)
- Árboles de decisión
- Reglas de asociación
- Clasificadores por vecindad (Nearest Neighbord)
- Redes neuronales artificiales (ANN)
- Algoritmos genéticos
- Clasificadores Bayesianos
- Máquinas de soporte vectorial (SVM)




## 2.3.1 Análisis Discriminante Lineal (LDA)

Algoritmo de clasificación, basado en el discriminante definido por Fisher en 1936. Pretende separar dos clases mediante un hiperplano (combinación lineal de los atributos)

$$Z = X \beta = \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p$$

- Supongamos que tenemos un problema de clasificación binaria (con  $N_0$  respuestas -1 y  $N_1$  respuestas 1) y un conjunto de entrenamiento, con matriz de atributos normalizados y linealmente independientes,  $X$  (de dimensión  $N \times p$ ,  $N = N_0 + N_1$ ).
- Se supone que  $P(X|Y=-1)$  y  $P(X|Y=1)$  están normalmente distribuidas con medias  $m_0$  y  $m_1$  (son los vectores, denominados centroides) y la misma matriz de covarianzas  $C$ .
- Los coeficientes de la combinación lineal son  $\beta = C^{-1}(m_0 - m_1)'$
- Para clasificar un nuevo elemento  $x$ , se calcula  $Z = x\beta$  y se elige el lado correspondiente del hiperplano comparando con  $Z_0 = \frac{m_0 + m_1}{2} \beta$ .
- El clasificador es  $G(X) = \text{signo}(Z - Z_0)$ .



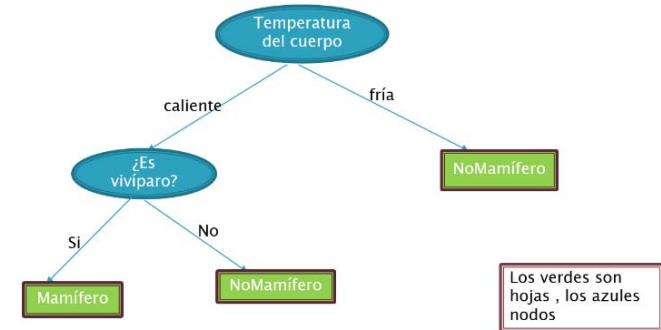
Si los elementos de las dos clases tienen matrices de covarianzas distintas  $C_0$  y  $C_1$ , se puede trabajar con la matriz de covarianzas agrupadas  $C = (N_0 C_0 + N_1 C_1) / N$ .

Matlab tiene implementado LDA en la función classify

## 2.3.2 Árboles de decisión

- Algoritmos de clasificación empleados para el descubrimiento de reglas y relaciones.
- Objetivo: Segmentar la población en grupos homogéneos según la variable respuesta.
- Se construye partiendo el conjunto de registros en dos o más subconjuntos. Cada subconjunto a su vez es particionado.
- La presentación, en forma de árbol, es muy clara para el usuario. Hay un nodo raíz, nodos internos y hojas terminales. La raíz y nodos internos corresponden a atributos, las hojas corresponden a las etiquetas.
- Clasificar un registro consiste en partir del nodo raíz y haciendo las preguntas llegar a una hoja y asignar la etiqueta correspondiente.

### Ejemplo: Clasificar una especie animal



## ¿Cómo construir un árbol de decisión?

La cantidad de posibles árboles es exponencial y hallar el óptimo es computacionalmente inviable. Pero hay algoritmos que utilizan una estrategia "greedy" para construir un árbol con un éxito razonable

### Algoritmo de Hunt

Input:  $X$  conjunto de registros de entrenamiento. Para cada nodo  $t$ , sea  $D(t)$  el conjunto de registros de  $X$  asociados con  $t$  y sea  $Y=\{Y_1, Y_2, \dots, Y_k\}$  el conjunto de etiquetas.

1. Si todos los registros de  $D(t)$  pertenecen a la misma clase  $Y_t$ , entonces  $t$  es un nodo hoja etiquetado con  $Y_t$
2. Si  $D(t)$  contiene registros de más de una clase se selecciona un atributo condición para partir  $D(t)$  en conjuntos más pequeños

Si los atributos corresponden a variables binarias el árbol es binario

Matlab tiene implementados distintos métodos de clasificación por árboles que además se pueden entrenar en modo interactivo desde la APP Classification Learner

### 2.3.3 Reglas de asociación

- Algoritmo de clasificación, con aprendizaje supervisado, que permite predecir comportamientos futuros a partir de un análisis de coincidencias, descubriendo correlaciones o co-ocurrencias en los sucesos de la base de datos.
- Una asociación entre dos atributos ocurre cuando la frecuencia con la que se verifican simultáneamente es relativamente alta.
- Se formaliza la obtención de reglas del tipo **SI... ENTONCES**, permitiendo obtener una consecuencia a partir de un conjunto de antecedentes.
- **Las reglas deben ser mutuamente excluyentes y el conjunto de reglas debe ser exhaustivo**

**Ejemplo:** Gestión de estantes de un supermercado

**Objetivo:** Identificar productos comprados simultáneamente por muchos clientes.

**Enfoque:** Procesar datos recogidos en punto de venta.

**Una posible regla:** Si un cliente compra pañales y leche es muy probable que compre compotas.

**Ejemplo de conjunto de reglas para un problema de clasificación de vertebrados:**

r1: (Vivíparo=NO) Y (Volador=SI) → Pájaro

r3: (Vivíparo=NO) Y (Acuático=SI) → Pez

r2: (Vivíparo=NO) Y (Volador=No) → Reptil

r3: (Vivíparo=SI) Y (Temperatura corporal=Caliente) → Mamífero

r4: (Acuático=semi) → Anfibio

Es un mal conjunto de reglas. A una tortuga se le puede aplicar la 2 y la 4 y a un tiburón no se le puede aplicar ninguna

## ¿Cómo construir un conjunto exhaustivo de reglas excluyentes?

Necesitamos extraer un conjunto de reglas que establezcan relaciones clave entre los atributos y las etiquetas.

Métodos directos → extraen las reglas directamente de los datos

Métodos indirectos → extraen las reglas de otros clasificadores

Dado un conjunto de datos  $D$  y una regla  $r: A \rightarrow Y$  se define

Cobertura( $r$ ) =  $|A|/|D|$

(proporción de datos de  $D$  que satisfacen  $A$ )

Éxito ( $r$ ) =  $|A \cap Y|/|A|$  (proporción de aciertos en los datos clasificados con la regla)

### Algoritmo de cobertura secuencial (Método directo)

Datos de entrada:  $E$  = training set,  $A = \{(A_j, v_j)\}$ ,

$A_j$  = atributos,  $v_j$  = valores

$Y = \{y_1, \dots, y_k\}$  conjunto ordenado de clases

1. Se inicializa a vacío el conjunto de reglas  $R = \{\}$
2. Para cada clase  $y \in Y - \{y_k\}$  do  
Aprende una regla  $(E, A, y) \rightarrow r$   
Borra los registros cubiertos por la regla  $r$   
Incorpora la regla:  $R = R \cup r$
3. Inserta al final de la lista la regla por defecto  $\{\} \rightarrow y_k$

La idea es ir clasificando primero los elementos de una clase, luego los de otra, ...

## 2.3.4 Aprendizaje por vecindad o K-Nearest-Neighbor (KNN)

Algoritmo de clasificación que para predecir el valor de  $G(x)$  usa las respuestas correspondientes a los registros de entrenamiento más cercanos a  $x$ .

Si  $N_k(x)$  es el entorno de  $x$  definido por los  $k$  puntos del conjunto de entrenamiento más próximos a  $x$  (por ejemplo con distancia euclídea) se predice la respuesta a  $x$  como la clase mayoritaria.

### Pseudo-algoritmo:

Datos de entrada :  $D$ = set training;  $k$ =número de vecinos a considerar

Para cada dato del conjunto test,  $z = (x', y')$  hacer:

Calcular  $d(x', x)$ , para todos los  $x / (x, y) \in D$

Seleccionar el subconjunto  $N_k(z)$  con los  $k$  elementos de  $D$  con menor distancia

Estimar  $y'$  a partir de los  $y_i$ , con  $x_i$  en  $N_k(z)$

Puede ser  
comp. costoso

La frontera de  
decisión es una  
curva arbitraria

Es importante  
elegir una  
distancia  
adecuada

El carácter local lo hace sensible al ruido y a la diferencia de magnitudes entre atributos. Conviene trasladar los valores de todas las características al intervalo  $[0,1]$ .

El training error es una función creciente de  $k$  y es 0 si  $k=1$

Matlab tiene implementados algoritmos KNN y permite elegir el número de vecinos y la distancia

### 2.3.5 Redes neuronales artificiales (ANN)


- Algoritmos bio-inspirados capaces de detectar y aprender patrones y características de los datos.
- Las reglas de aprendizaje permiten ajustar los parámetros del modelo mediante un conjunto de pesos.
- La elección del algoritmo de aprendizaje importante. Una vez adiestradas las redes pueden hacer previsiones y clasificaciones.

<b>Neurona Biológica</b>	<b>Neurona Artificial</b>
Señales que llegan a la sinapsis	Entradas a la neurona
Carácter excitador o inhibidor de la sinapsis de entrada	Pesos de entrada
Estimulo total de la neurona	Sumatoria de pesos por entradas
Activación o no de la neurona	Función de activación
Respuesta de la neurona	Función de salida

## Ej: Perceptron lineal

$x_1, x_2, \dots, x_n$  son las **señales de entrada** y cada una pasa a través de un peso  $w$ , llamado **peso sináptico** de la conexión, cuya función es análoga a la de la **función sináptica de la neurona biológica**

El **nodo sumatorio** acumula todas las señales de entrada multiplicadas por los pesos y las pasa a la salida a través de una **función de activación** o transferencia  $f(n)$ , ( $b$  es el sesgo).



El algoritmo converge si  $D$  es linealmente separable

Modelo:

$$\hat{y} = f(w_n x_n + \dots + w_1 x_1 - b)$$

Como función de activación  $f$ , se puede usar la identidad, la función escalón, la función signo...

### Algoritmo de aprendizaje: Perceptron

1. Training set:  $D = \{(X_i, y_i) / i=1..N\}$
2. Inicializamos el vector de pesos con valores aleatorios  $w^{(0)}$ .
3. Para cada  $i$  hacemos:
  - Calcular el output predicho  $\hat{y}_i^{(k)}$
  - Para cada  $j$  actualizar el peso  $w_j^{(k+1)} = w_j^{(k)} + \lambda(y_i - \hat{y}_i^{(k)})x_{ij}$
4. Condición de parada

El parámetro  $\lambda$  (tasa de aprendizaje) toma valores entre 0 y 1, controla la cantidad de ajuste en cada iteración. Se puede ir adaptando: tomar un valor grande en las primeras iteraciones y luego ir bajando.



## 2.3.6 Clasificadores Bayesianos

En algunos casos la relación entre los atributos y la respuesta no es determinista. No se puede predecir con seguridad la respuesta a un dato test ni aun cuando todos sus atributos coincidan con los de un datos de entrenamiento (puede ocurrir por la presencia de ruido o de factores que afecten a la clasificación, pero no estén incluidos en el análisis, por ejemplo con los mismos valores de los atributos una persona puede estar enferma y otra no).

Si la relación entre los atributos  $X$  y la respuesta  $Y$  es no determinista, se puede considerar la probabilidad condicionada  $P(Y|X)$  y durante la fase de entrenamiento se trata de aprender esta probabilidad. Una vez conocida, para un registro test  $X'$  podemos clasificar  $Y'$  de modo que se maximice  $P(Y' | X')$

Supongamos que  $Y$  es binaria, con valores  $-1$  y  $1$ . Para cada  $X$  del conjunto de test hemos de calcular  $P(Y=-1|X)$  y  $P(Y=1|X)$ . Si la primera es más grande se clasifica como  $-1$  y de lo contrario como  $1$ .

Para obtener esas probabilidades se puede usar el T. de Bayes:  $P(Y|X) = \frac{P(X|Y) P(Y)}{P(X)}$

## Naïve Bayes

Cuando queremos comparar los valores de  $P(Y=y|X)$  para un  $X$  fijo y distintos valores de  $y$ , usando el teorema de Bayes, el denominador es el mismo y podemos ignorarlo, cada  $P(Y=y)$  se estima por la frecuencia relativa en los datos de entrenamiento y para estimar  $p(X|Y=y)$  **se supone independencia condicional de los atributos**, es decir:  $P(X|Y = y) = \prod_{i=1}^p P(X_i=x_i|Y=y)$

Cada probabilidad  $P(X_i=x_i|Y=y)$  se estima mediante la proporción de instancias de entrenamiento que tienen respuesta  $y$  y valor  $x_i$  en el atributo  $X_i$ .

Cliente	Casa propia	Ingresos Miles €	Estado civil	Moroso
1	SI	125	Soltero	NO
2	NO	100	Casado	NO
3	NO	70	Soltero	NO
4	SI	120	Casado	NO
5	NO	95	Divorc.	SI
6	NO	60	Casado	NO
7	SI	200	Divorc.	NO
8	NO	85	Soltero	SI
8	NO	75	Casado	NO
10	SI	90	Soltero	SI

**Ejemplo:** con los datos de entrenamiento de la tabla adjunta, queremos clasificar a un **soltero con casa propia e ingresos anuales de 70 mil euros**.

$X_1=SI, X_2=70, X_3=Soltero$

Estimamos:  $P(Y=Si)= 3/10, P(Y=No)= 7/10$

$P(X_1=Si | Y=Si)=1/3; P(X_1= Si | Y=No)=3/7$

$P(X_2=70 | Y=Si)=0; P(X_2= 70 | Y=No)=1/7$

$P(X_3=Soltero | Y=Si)=2/3; P(X_3= Soltero | Y=No)=2/7$

Entonces

$P(X|Y=Si)=0; P(X|Y=NO)=6/7^3$

$P(Y=Si|X) < P(Y=NO|X)$

Clasificaría a  $X$  como NO MOROSO

## 2.3.7 Máquinas de soporte vectorial (SVM)


Las máquinas de soporte vectorial son algoritmos de clasificación, que son lineales, cuando la frontera de decisión es un hiperplano  $X^T \beta + \beta_0 = 0$ .

Si el problema es de clasificación binaria (con valores 1 o -1 para  $y$ ), la respuesta a un elemento  $z$  del conjunto test se predice por  $\text{signo}(z^T \beta + \beta_0)$ , es decir

$$y = \begin{cases} 1 & \text{si } z^t \beta + \beta_0 > 0, \\ -1 & \text{si } z^t \beta + \beta_0 < 0, \end{cases}$$

El margen de la frontera de decisión es la distancia entre los hiperplanos


$X^T \beta + \beta_0 = 1$  y  $X^T \beta + \beta_0 = -1$ , que es  $2/\|\beta\|$



Si el conjunto es linealmente separable, hay infinitos hiperplanos, para elegir uno, se impone la condición de maximizar el margen de la frontera de decisión, lo que es equivalente a minimizar  $\|\beta\|$ , con la restricción  $y_i(x_i^T \beta + \beta_0) \geq 1$  (problema de optimización)

Es aconsejable estandarizar los predictores

## SVM: Diferencia entre el caso separable y el no separable



Se puede reformular el problema de modo que la frontera de decisión sea tolerante a pequeños errores en los datos de entrenamiento

En el caso no separable, se trata de minimizar  $\|\beta\|$ , con la restricción  $y_i(x_i^T \beta + \beta_0) \geq 1 - \varepsilon_i$   
 $\varepsilon_i \geq 0$  y  $\sum \varepsilon_i \leq cte$

Un problema multiclase se puede descomponer en varios problemas de clasificación binaria

## Modelos SVM no lineales

**Transformación de atributos:** Cuando el conjunto de datos de entrenamiento no es linealmente separable, se pueden transformar los atributos, mediante una función  $\phi(X)$ , de modo que se pueda usar una frontera de decisión lineal y aplicar el algoritmo SVM anterior. El clasificador sería  $G(X) = \text{sign}(\phi(X)^T \beta + \beta_0)$ .

Pero puede ser complicado encontrar la transformación  $\phi$ , sobre todo en problemas de dimensión alta. Lo que pasa es que para resolver el problema de optimización, no es necesario conocer una expresión explícita de  $\phi$ , sino solo productos escalares  $\langle \phi(X), \phi(X_i) \rangle$ .

**Kernel trick:** El producto escalar se puede usar como medida de similitud entre dos vectores. La función  $K(u,v) = \langle \phi(u), \phi(v) \rangle$ , computada sobre el espacio de los atributos se puede utilizar como función núcleo (K debe ser simétrica y semi-definida positiva).

**Algunas funciones núcleo:**

Polinomial:  $K(u,v) = 1 + \langle u, v \rangle^d$

Radial basis (RBF) o Gaussian:  $K(u,v) = \exp(-|u-v|^2)$

## 4. Algunas referencias

- Pang-Ning Tan, Michael Steinbach, Vipon Kumar. **Introduction to Data Mining**, Pearson International Ed, 2006
- Jiawei Han (University of Illinois at Urbana-Champaign): **Data Mining: Concepts and Techniques**, 2006
- Trevor Hastie, Robert Tibshirani, Jerome Friedman. **The Elements of Statistical Learning**. Springer, 2009.
- Bryan F.J. Manly and Jorge A. Navarro Alberto. **Multivariate Statistical Methods**. A primer. (4ªEd) Chapman & Hall, 2016 (con código R de los algoritmos).

### Para Clasificación Multiclase:

- J. Li, J and J. P. Fine. *ROC analysis with multiple classes and multiple tests: methodology and its application in microarray studies* Biostatistics 9 (3) (2008) pp.566-576 (generalización del AUC a HUM (hiper-área bajo una variedad) (<https://academic.oup.com/biostatistics/article-lookup/doi/10.1093/biostatistics/kxm050>))
- Marina Sokolova, Guy Lapalme. A systematic analysis of performance measures for classification tasks. *Information Processing an Management*. 45 (2009) pp.427-437.
- I. Psorakis, T. Damoulas, M. A. Girolami. *Multiclass Relevance Vector Machines: Sparsity and Accuracy*, IEEE Trans on Neural Networks, 21, pp.1588-1598.

**MUCHAS GRACIAS POR SU ATENCIÓN**



Anoten las preguntas para el final

## Aplicación de la Minería de Datos al Diagnóstico y Evaluación de la Enfermedad de Parkinson por la Voz

Francisco Díaz Pérez  
Alfonsa García López



### Objetivos:

- Exponer la problemática general de la detección de la Enfermedad de Parkinson mediante la voz.
- Analizar las posibilidades reales actuales para el desarrollo de sistemas de diagnósticos de la EP.



# INDICE

**Visión Global, Síntomas, Diagnóstico y Cuantificación.**

**Sistema Básico de diagnóstico por voz.**

**Algunas aportaciones importantes.**


**Caracterización de la EP por la voz.**

**Disponibilidad de Conjuntos de Datos.**

**Valoración de algunas publicaciones recientes.**



**Anxiety and Depression with Parkinson's Disease**



**Causas de la enfermedad de Parkinson**

## La enfermedad de Parkinson (EP)

La enfermedad de Parkinson (EP) es una alteración **neurodegenerativa** de curso crónico, progresivo e irreversible.

La enfermedad de Parkinson consiste en un **desorden crónico y degenerativo** de una de las partes del cerebro que controla el sistema motor y se manifiesta con una **pérdida progresiva de la capacidad de coordinar los movimientos**.

Se produce cuando las células nerviosas de la **sustancia negra** del mesencéfalo, área cerebral que controla el movimiento, **mueren o sufren algún deterioro**.

## La enfermedad de Parkinson (EP)

Un factor de riesgo para la enfermedad es la edad. La edad promedio de inicio es de 60 años, y la incidencia aumenta significativamente con la edad.

Sin embargo, alrededor del 5 al 10 por ciento de las personas con enfermedad de Parkinson tienen una enfermedad de "inicio temprano" que comienza antes de los 50 años de edad.

## La enfermedad de Parkinson (EP)

Muchos pacientes en las etapas tempranas de la enfermedad suponen que sus síntomas se deben al envejecimiento normal y no buscan ayuda médica.

## La Enfermedad de Parkinson.



Médicos realizan una serie de pruebas para diagnosticar el mal.

## La Enfermedad de Parkinson. Síntomas motores.

### **Bradicinesia:**

(lentitud en los movimientos), desaceleración o pérdida de los movimientos espontáneos y voluntarios.

### **Rigidez:**

inflexibilidad inusual en una extremidad u otra parte del cuerpo.

### **Temblor en reposo:**

un movimiento incontrolable que afecta una extremidad cuando está en reposo y desaparece durante un movimiento voluntario.

### **Otros síntomas motores en esta enfermedad:**

Inestabilidad postural: problemas al estar de pie o al caminar, o disminución del equilibrio y la coordinación, dificultades en la marcha y una disminución de las expresiones faciales.

## La Enfermedad de Parkinson. Síntomas no motores.

### **Deterioro cognitivo:**

- disminución de la capacidad para concentrarse y reducción del funcionamiento intelectual.

### **Trastornos del estado de ánimo:**

- depresión y ansiedad

Problemas para dormir.

Presión arterial baja al estar de pie.

Estreñimiento.

Dolores de origen desconocido, babeo y pérdida del olfato.

**Dificultades en el habla** y para tragar.

## La Enfermedad de Parkinson. Diagnóstico.

El **diagnóstico** es a veces **difícil e incierto** debido a que otras enfermedades pueden causar síntomas similares.

**No existe una prueba definitiva** para el diagnóstico de la enfermedad.

## UPDRS - Unified Parkinson's Disease Rating Scale

Escala Unificada de Valoración de la Enfermedad de Parkinson (UPDRS, siglas en inglés).

Esta escala tiene valoraciones múltiples que miden el funcionamiento mental, la conducta, el ánimo; las actividades de la vida cotidiana y la función motora.

- El rango de puntuación de la escala UPDRS varía desde "0", ninguna incapacidad hasta incapacidad total (valor máximo 159), PDRS->68.

**Parte I: Estado mental, de comportamiento y humor.**


**Parte II: Actividades de la vida diaria.**

**Parte III: Examen motor.**

## ¿Es posible detectar el mal de Parkinson a través de la voz?

● 10 de diciembre de 2014

Si bien todavía se precisa investigar más, tres científicos argentinos creen que será posible diagnosticar el mal de Parkinson en forma temprana a través de la voz con la ayuda de un programa.



### Científicos argentinos buscan detectar el mal de Parkinson por la voz

Tomado de:  
<http://www.perfil.com/ciencia/cientificos-argentinos-buscan-detectar-el-mal-de-parkinson-por-la-voz-1205-0053.phtml>

27/02/2018

FRANCIASO DÍAZ Y ALFONSA GARCÍA

15

### Una iniciativa pionera

- 1** Así como el Parkinson afecta las extremidades, también afecta las cuerdas vocales.
- 2** Estos efectos vocales pueden ser muy sutiles pero se pueden captar con un micrófono digital. Basta escuchar una llamada telefónica grabada para detectar estos signos en la voz.
- 3** Las personas con mal de Parkinson presentan un temblor irregular de las cuerdas vocales. El discurso se vuelve más tranquilo y aspirado.

Normal	
Con Parkinson	
- 4** Mediante un software preciso de análisis de voz se pueden reconocer estos síntomas y diagnosticar en forma temprana la enfermedad.

Fuente: Parkinson Initiative Voice. Infografía: S. Ucedo

Tomado de: <http://www.perfil.com/ciencia/cientificos-argentinos-buscan-detectar-el-mal-de-parkinson-por-la-voz-1205-0053.phtml>

27/02/2018

FRANCIASO DÍAZ Y ALFONSA GARCÍA

16



English Español Français Like 2.8K Tweet 644

**PVI**  
Parkinson's Voice Initiative

[Inicio](#) [Visión](#) [FAQ](#) [Ciencia](#) [Retroalimentación](#) [Equipo](#) [Prensa](#)

*Las enfermedades neurológicas como el Parkinson destruyen la habilidad para moverse; hay más de 6 millones con la enfermedad en el mundo, sin curación. Hasta que tengamos la cura necesitamos pruebas objetivas. Desgraciadamente no hay marcadores biológicos (p.ej. análisis de sangre).*


Actualmente, las pruebas diagnósticas para el Parkinson son caras, lentas y, son logísticamente difíciles, así que en su mayoría sólo se llevan a cabo en pruebas clínicas. Sin embargo, hay algo interesante: la voz se ve afectada de igual manera que los movimientos de las extremidades por lo que hemos desarrollado la tecnología necesaria para comprobar los síntomas utilizando únicamente grabaciones de voz.

Esto puede proporcionar unos avances radicales, ya que las pruebas basadas en la voz son tan precisas como las clínicas, pero además, pueden llevarse a cabo a distancia y los pacientes pueden hacerlas ellos mismos. Además, son rápidas (se realizan en menos de 30 segundos), y son muy baratas (no requieren tiempo de especialistas). Por ello, pueden hacerse a gran escala.

27/02/2018 FRANCIASO DÍAZ Y ALFONSA GARCÍA 17

**Algunas aportaciones importantes.**

27/02/2018 FRANCIASO DÍAZ Y ALFONSA GARCÍA 18



## Athanasios Tsanas

University of Oxford  
Biomedical engineering, signal processing, statistical machine learning  
Verified email at maths.ox.ac.uk - Homepage

[Follow](#)

Title	Cited by	Year
<a href="#">Accurate telemonitoring of Parkinson's disease progression by noninvasive speech tests</a> A Tsanas, M Little, PE McSharry, LO Ramig Biomedical Engineering, IEEE Transactions on 57 (4), 884-893	168	2010
<a href="#">Novel speech signal processing algorithms for high-accuracy classification of Parkinson's disease</a> A Tsanas, M Little, P McSharry, J Spielman, L Ramig Biomedical Engineering, IEEE Transactions on 59, 1264-1271	84	2012
<a href="#">Nonlinear speech analysis algorithms mapped to a standard metric achieve clinically useful quantification of average Parkinson's disease symptom severity</a> A Tsanas, MA Little, PE McSharry, LO Ramig	66	2011

27/02/2018
FRANCIASO DÍAZ Y ALFONSA GARCÍA
19

## Por la voz se descubre el alzheimer

La ULPGC acoge un foro internacional sobre avances científicos en el procesamiento del habla para el diagnóstico y control de enfermedades

🕒 08:55 ☆☆☆☆

📄
👤
👍 G+1
🐦 Tweet 3
👍 Recomendar

🔍 9

**MARÍA JESÚS HERNÁNDEZ**  
**LAS PALMAS DE GRAN CANARIA** A través de la voz se pueden [diagnosticar enfermedades como el alzheimer o el Parkinson](#), evaluar el éxito de un tratamiento, o la progresión de la enfermedad. Así lo manifestó el ingeniero Pedro Gómez Vilda, catedrático del Departamento de Arquitectura y Tecnología de Sistemas Informáticos de la Universidad Politécnica de Madrid en el Congreso internacional tecnológico sobre procesamiento del habla que se celebra en la capital grancanaria, organizado por el Instituto para el Desarrollo Tecnológico y la Innovación en Comunicaciones (IdeTic) de la Universidad de Las Palmas.



ampliar

Por la voz se descubre el alzheimer

NOTICIAS RELACIONADAS

Tomado de <http://www.laprovincia.es/sociedad/2011/11/08/voz-descubre-alzheimer/414003.html>

27/02/2018
FRANCIASO DÍAZ Y ALFONSA GARCÍA
20



**Chapter**

Artificial Computation in Biology and Medicine

Volume 9107 of the series Lecture Notes in Computer Science pp 238-248

## Parkinson's Disease Monitoring from Phonation Biomechanics

P. Gómez-Vilda , M. C. Vicente-Torcal, J. M. Ferrández-Vicente, A. Álvarez-Marquina, V. Rodellar-Biarge, V. Nieto-Lluis, R. Martínez-Olalla

 [Download Book \(PDF, 45727 KB\)](#)



Springer Link

Search

Home • Contact Us

Look Inside Get Access

**Article**  
Cognitive Computation  
December 2013, Volume 5, Issue 4, pp 399-425  
First online: 22 February 2013

### Characterizing Neurological Disease from Voice Quality Biomechanical Analysis

Pedro Gómez-Vilda , Victoria Rodellar-Biarge, Víctor Nieto-Lluis, Cristina Muñoz-Mulas, Luis Miguel Mazaira-Fernández, Rafael Martínez-Olalla, Agustín Álvarez-Marquina, Carlos Ramírez-Calvo, Mario Fernández-Fernández

Article Metrics

Download PDF Export Search ScienceDirect Advanced search

**Journal of Neurolinguistics**  
Volume 17, Issue 6, November 2004, Pages 439–453

**Acoustic characteristics of Parkinsonian speech: a potential biomarker of early disease progression and treatment**

Brian T. Harel<sup>a, \*</sup>, Michael S. Cannizzaro<sup>a</sup>, Henri Cohen<sup>a</sup>, Nicole Reilly<sup>a</sup>, Peter J. Snyder<sup>a, b, c</sup>

[Show more](#)

<http://dx.doi.org/10.1016/j.jneuroling.2004.06.001> [Get rights and content](#)

**Abstract**

One of the frequent signs of Parkinson's disease (PD) is the presence of a progressive hypokinetic dysarthria. Numerous studies have since documented speech motor impairment, but attempts at quantifying any such changes longitudinally throughout the early course of the disease have been rare. In this study, a retrospective analysis of

**Recommended articles**

- Variability in fundamental frequency**  
2004, Brain and Cognition [more](#)
- An acoustic investigation of Parkinson's**  
2007, Journal of Neurolinguistics [more](#)
- Acoustic analysis of clear versus coar**  
2005, Journal of Communication Disorders [more](#)

[View more articles >](#)

**Citing articles (41)**

**Related book content**

Fee

27/02/2018 FRANCIASO DÍAZ Y ALFONSA GARCÍA 23


## Caracterización de la EP por la voz

El **habla del parkinsoniano** se caracteriza por tener una sonoridad e intensidad monótona, de bajo tono que tiende a desvanecerse al final de la fonación.

El habla se produce en lentos ataques y significativas pausas para respirar entre palabras y sílabas, reduciéndose la fluidez verbal y el ritmo [Sko.08].

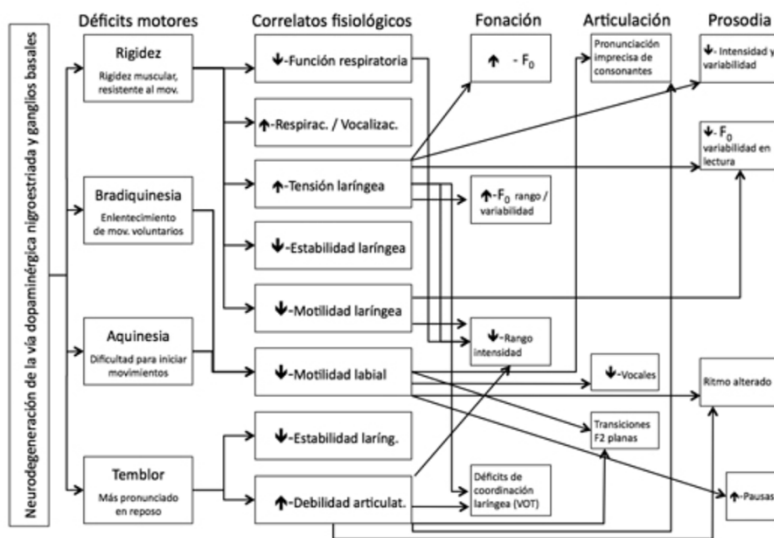
El **sistema fonatorio** se ve alterado principalmente en el ritmo vibratorio de las cuerdas vocales, cuantificado por la **frecuencia fundamental (F0) o Pitch**, (F0: número de veces que las cuerdas vocales se abren y cierran por segundo)

El **incremento en los niveles de la F0** es uno de los principales marcadores de alteración en la voz en la EP (Mori *et al.* [Mor.05] ).



Supplementary Fig. 1 (b) The same signal zoomed in. The horizontal axis is time in seconds and the vertical axis is amplitude (no units).

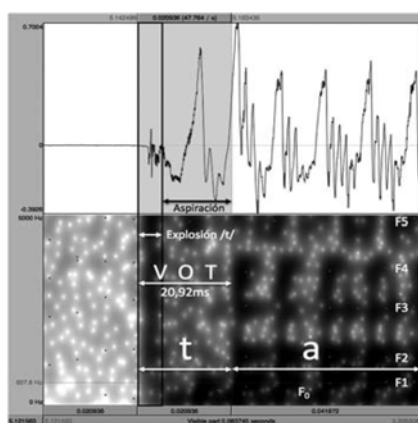
## Efectos de la EP en el aparato fonatorio.



[ Tomado de [www.neurologia.com](http://www.neurologia.com) Rev Neurol 2010; 51 (9): 542-550 ]

28

## VOT- voice onset time



El *voice onset time* (VOT) o tiempo de inicio de la sonoridad es un procedimiento empleado para valorar el sistema fonatorio en la EP.

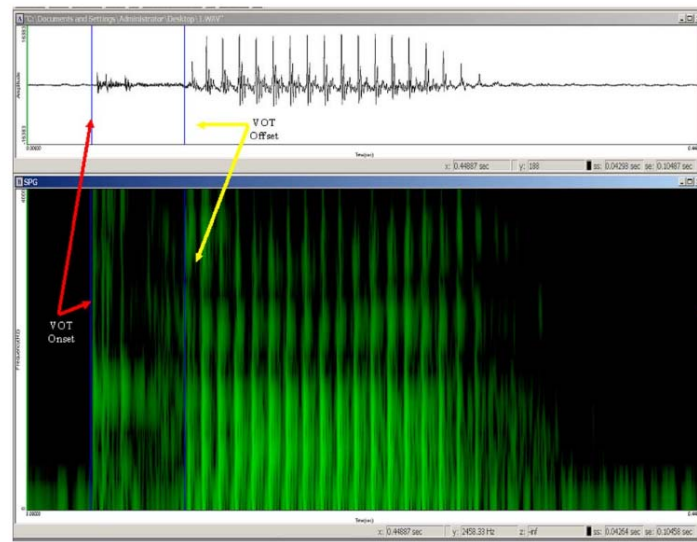
– intervalo transcurrido entre el final de la consonante y el inicio de vocalización de la siguiente vocal, es un índice fiable de falta de coordinación laríngeo y supralaríngeo.

El VOT recoge el tiempo que tardan los repliegues vocales en comenzar a vibrar en relación con la retirada del obstáculo en las cavidades supraglóticas, e implica la coordinación temporal entre la articulación oral en el fin de una consonante y los mecanismos laríngeos requeridos para producir la vibración de las cuerdas vocales

Tomado de [www.neurologia.com](http://www.neurologia.com) Rev Neurol 2010; 51 (9): 542-550 ]

29

## VOT



27/02/2018


FRANCIASO DÍAZ Y ALFONSA GARCÍA

Tomado de [cite{Hare12004439}]

30

Los cambios involuntarios producidos en los pacientes con EP reflejan la disminución en la capacidad de los músculos laríngeos para mantener una posición fija en la prolongación de las vocales [Gall.01, MIDI-08] .

Los parámetros de la perturbación en cada ciclo de voz en la **variabilidad frecuencial (*jitter*)** y la **variabilidad en amplitud (*shimmer*)** también han mostrado la existencia de diferencias significativas al comparar controles y pacientes con EP [Rah.07].



. Jitter and Shimmer perturbation measures in speech signal [6].

27/02/2018

FRANCIASO DÍAZ Y ALFONSA GARCÍA

31

## Medidas de Jitter y Shimmer

Jitter (local), Jitter (local, absolute), Jitter (rap), Jitter (ppq5), Jitter (ddp),

$$jitta = \frac{1}{N-1} \sum_{i=1}^{N-1} |T_i - T_{i-1}|$$

Donde  $T_i$  es la longitud del período glotal y  $N$  es el número de períodos extraídos



## Medidas de Jitter y Shimmer

Shimmer (local), Shimmer (local, dB), Shimmer (apq3), Shimmer (apq5), Shimmer (apq11), Shimmer (dda)

$$ShdB = \frac{1}{N-1} \sum_{i=1}^{N-1} \left| 20 * \log \left( \frac{A_{i+1}}{A_i} \right) \right|$$

Donde  $A_i$  es la amplitud pico a pico extraída y  $N$  es el número de períodos (frecuencia fundamental) utilizados.

<http://www.fon.hum.uva.nl/praat/>

Praat: doing phonetics by computer		
<p><b>Download Praat:</b></p> <ul style="list-style-type: none"> <li>• <a href="#">Macintosh</a></li> <li>• <a href="#">Windows</a></li> <li>• <a href="#">Linux, FreeBSD</a></li> <li>• <a href="#">SGI, Solaris, HPUX</a></li> <li>• <a href="#">the source code</a></li> </ul>	<p><b>Information on Praat:</b></p> <ul style="list-style-type: none"> <li>• Introductory tutorial: choose <b>Intro</b> from Praat's <b>Help</b> menus.</li> <li>• Extensive manuals and tutorials: in Praat's <b>Help</b> menus.</li> <li>• <a href="#">Beginner's manuals by others</a>.</li> <li>• Paul Boersma's <a href="#">publications</a> on algorithms and tutorials.</li> </ul>	
 <p><a href="#">Paul</a></p>	<p><b>The authors</b></p> <p>Paul Boersma and David Weenink  <a href="#">Phonetic Sciences</a>, University of Amsterdam                  Spuistraat 210                  1012VT Amsterdam                  The Netherlands</p>	 <p><a href="#">David</a></p>

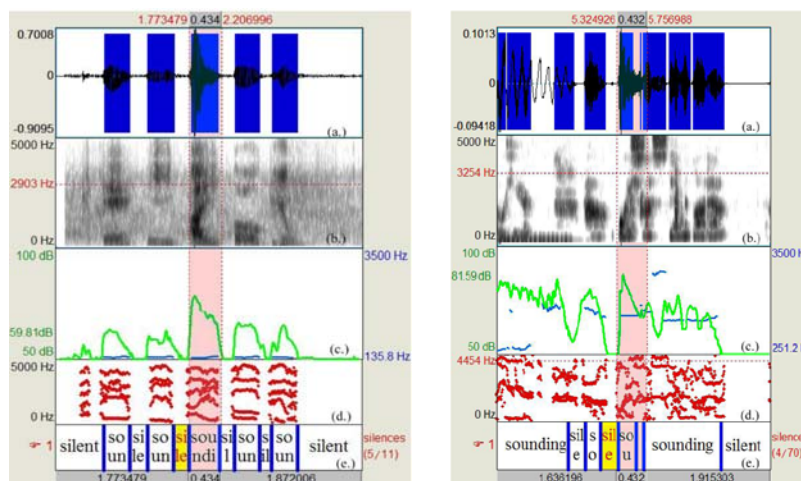
<http://www.fon.hum.uva.nl/praat/>

**Functionality**

The following gives you an idea of the features of the Praat program. The links take you into the web copy of the manual. The same manual is also available from Praat's Help menus, in which case you can see the pictures and do searches.

<p><b>Speech analysis:</b></p> <ul style="list-style-type: none"> <li>• <a href="#">spectral analysis (spectrograms)</a></li> <li>• <a href="#">pitch analysis</a></li> <li>• <a href="#">formant analysis</a></li> <li>• <a href="#">intensity analysis</a></li> <li>• <a href="#">jitter, shimmer, voice breaks</a></li> <li>• <a href="#">cochleagram</a></li> <li>• <a href="#">excitation pattern</a></li> </ul>	<p><b>Speech synthesis:</b></p> <ul style="list-style-type: none"> <li>• <a href="#">from pitch, formant, and intensity</a></li> <li>• <a href="#">articulatory synthesis</a></li> <li>• <a href="#">Klatt acoustic synthesis</a></li> </ul>
<p><b>Labelling and segmentation:</b></p> <ul style="list-style-type: none"> <li>• <a href="#">label intervals and time points on multiple files</a></li> <li>• <a href="#">use phonetic alphabet</a></li> <li>• <a href="#">use sound files up to 2 gigabytes (3 hours)</a></li> </ul>	<p><b>Listening experiments:</b></p> <ul style="list-style-type: none"> <li>• <a href="#">identification and discrimination tests</a></li> </ul>
<p><b>Speech manipulation:</b></p> <ul style="list-style-type: none"> <li>• <a href="#">change pitch and duration contours</a></li> <li>• <a href="#">filtering</a></li> </ul>	

## Extracción de Rasgos usando PRAAT



27/02/2018

FRANCIASO DÍAZ Y ALFONSA GARCÍA

Tomado de \cite{dixit20149}

Table 2: Extracted Voice features of PD subjects.

Parameters	Extracted Features of PD subjects
<b>Time range</b>	From 1.773479 to 2.206996 seconds (duration: 0.433517 seconds)
<b>Pitch</b>	Median pitch: 128.091 Hz Mean pitch: 135.782 Hz Standard deviation: 16.079 Hz Minimum pitch: 117.279 Hz Maximum pitch: 168.229 Hz
<b>Pulses</b>	Number of pulses: 49 Number of periods: 48 Mean period: 7.393613E-3 seconds
<b>Pulses</b>	Standard deviation of period: 0.853359E-3 seconds
<b>Voicing</b>	Fraction of locally unvoiced frames: 34.909% (15/44) Number of voice breaks: 2 Degree of voice breaks: 28.300% (0.122275 seconds / 0.432062 seconds)
<b>Jitter</b>	Jitter (local): 2.224% Jitter(local,absolute):164.445E-6 seconds Jitter (rap): 1.108% Jitter (ppq5): 1.073% Jitter (ddp): 3.325%
<b>Shimmer</b>	Shimmer (local): 14.835% Shimmer (local, dB): 1.559 dB Shimmer (apq3): 5.712% Shimmer (apq5): 8.325% Shimmer (apq11): 15.067% Shimmer (dda): 17.136%
<b>Harmonicity of the voiced parts</b>	Mean autocorrelation: 0.856674 Mean noise-to-harmonics ratio: 0.184752 Mean harmonics-to-noise ratio: 8.709 dB

27/02/2018

FRANCIASO DÍAZ Y ALFONSA GARCÍA

Table 3: extracted voice features of Control subjects.

Parameters	Extracted Features of Control subjects
<b>Time range</b>	5.324926 to 5.756988 seconds (duration: 0.432062 seconds)
<b>Pitch</b>	Median pitch: 230.776 Hz Mean pitch: 251.198 Hz Standard deviation: 61.258 Hz Minimum pitch: 218.066 Hz Maximum pitch: 456.348 Hz
<b>Pulses</b>	Number of pulses: 71 Number of periods: 68 Mean period: 4.013338E-3 seconds Standard deviation of period: 0.726909E-3 seconds
<b>Voicing</b>	Fraction of locally unvoiced frames: Fraction of locally unvoiced frames: 16.279% (7 / 43) Number of voice breaks: 0 Degree of voice breaks: 0 (0 seconds / 0.433517 seconds)
<b>Jitter</b>	Jitter (local): 3.132% Jitter (local, absolute): 125.698E-6 seconds Jitter (rap): 1.452% Jitter (ppq5): 1.512% Jitter (ddp): 4.356%
<b>Shimmer</b>	Shimmer (local): 15.974% Shimmer (local, dB): 1.487 dB Shimmer (apq3): 7.283% Shimmer (apq5): 10.777% Shimmer (apq11): 16.007% Shimmer (dda): 21.849%
<b>Harmonicity of the voiced parts</b>	Mean autocorrelation: 0.839082 Mean noise-to-harmonics ratio: 0.218698 Mean harmonics-to-noise ratio: 8.546 dB

Tomado de \cite{dixit20149}



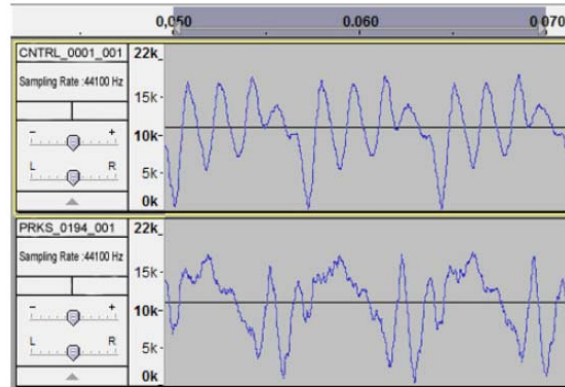


Fig. 1. Waveform of a voice sample belonging to a PWP (bottom) and a healthy individual (top). Amplitude of the signal ( $y$ -axis) is plotted against time duration ( $x$ -axis).

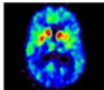
Fuente: \cite{Sakar2013828}

## Disponibilidad de Conjuntos de Datos

**UCI Machine Learning Repository**  
Center for Machine Learning and Intelligent Systems

**Parkinsons Data Set**  
Download: [Data Folder](#), [Data Set Description](#)

**Abstract:** Oxford Parkinson's Disease Detection Dataset



<b>Data Set Characteristics:</b>	Multivariate	<b>Number of Instances:</b>	197	<b>Area:</b>	Life
<b>Attribute Characteristics:</b>	Real	<b>Number of Attributes:</b>	23	<b>Date Donated</b>	2008-06-26
<b>Associated Tasks:</b>	Classification	<b>Missing Values?</b>	N/A	<b>Number of Web Hits:</b>	91091

27/02/2018 FRANCIAZO DÍAZ Y ALFONSA GARCÍA 40

	Features	Group
T	Jitter (local)	<b>Frequency parameters</b>
	Jitter (local, absolute)	
	Jitter (rap)	
	Jitter (ppq5)	
	Jitter (ddp)	
	Number of pulses	<b>Pulse Parameters</b>
	Number of periods	
	Mean period	
Standard dev. of period	<b>Amplitude parameters</b>	
Shimmer (local)		
Shimmer (local, dB)		
Shimmer (apq3)		
Shimmer (apq5)		
Shimmer (apq11)		
Fraction of locally unvoiced frames	<b>Voicing Parameters</b>	
Number of voice breaks		
Degree of voice breaks		
Median pitch	<b>Pitch Parameters</b>	
Mean pitch		
Standard deviation		
Minimum pitch		
Maximum pitch		
Autocorrelation	<b>Harmonicity Parameters</b>	
Noise-to-Harmonic		
Harmonic -to-Noise		

Fuente: \cite{Sakar2013828}

27/02/2018 FRANCIAZO DÍAZ Y ALFONSA GARCÍA 41

TABLE V  
AVERAGE AND BEST RESULTS OF 1000 RUNS OF SELECTING  
A RANDOM VOICE SAMPLES FROM EACH INDIVIDUAL

Classifier	Parameter	Result	Acc. (%)	MCC	Sens. (%)	Spec. (%)
k-NN	1	average	50.61	.0124	52.71	48.52
		best	<b>82.50</b>	<b>.6580</b>	85.00	80.00
	3	average	49.49	-.0102	54.61	44.37
		best	77.50	.5563	70.00	85.00
	5	average	48.52	-.0298	56.12	40.93
		best	75.00	.5103	65.00	85.00
	7	average	48.12	-.0383	57.18	39.07
		best	77.50	.5563	85.00	70.00
SVM	linear kernel	average	52.06	.0416	54.92	49.22
		best	<b>85.00</b>	<b>.7035</b>	80.00	90.00
	RBF kernel	average	46.91	-.0618	49.21	44.62
		best	80.00	.6030	85.00	75.00

$$accuracy = \frac{TP + TN}{TP + FP + TN + FN}$$

$$sensitivity = \frac{TP}{TP + FN}$$

$$specificity = \frac{TN}{TN + FP}$$

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$

TABLE VI  
SVM CLASSIFICATION ACCURACIES OF INDIVIDUAL VOICE SAMPLES  
THAT YIELDED THE BEST RESULTS

Voice Sample	Kernel Type	Accuracy (%)	MCC	Sensitivity (%)	Specificity (%)
Sustained "o"	Linear Kernel	<b>72.50</b>	<b>.4506</b>	70.00	75.00
	RBF Kernel	50.00	.0000	55.00	45.00
"four"	Linear Kernel	72.50	.4506	75.00	70.00
	RBF Kernel	<b>75.00</b>	<b>.5000</b>	75.00	75.00

TABLE VII  
 $k$ -NN CLASSIFICATION ACCURACIES (%) ON INDEPENDENT TEST SET

$k$	LOSO	s-LOO (1-4)	s-LOO (2-5)	s-LOO (3-6)	s-LOO (all)
1	50.60	60.71	67.86	57.14	64.29
3	48.21	57.14	53.57	71.43	67.86
5	53.57	<b>78.57</b>	67.86	<b>78.57</b>	71.43
7	59.52	75.00	71.43	75.00	67.86

**Central tendency metrics:** 1: mean 2: median 3: trimmed mean (25% removed)

**Dispersion metrics:** 4: standard deviation 5: mean absolute deviation 6: interquartile range

TABLE VIII  
 SVM CLASSIFICATION ACCURACIES (%) ON INDEPENDENT TEST SET

kernel	LOSO	s-LOO (1-4)	s-LOO (2-5)	s-LOO (3-6)	s-LOO (all)
linear	58.33	60.71	67.86	67.86	60.71
RBF	68.45	<b>82.14</b>	71.43	71.43	75.00

**Central tendency metrics:** 1: mean 2: median 3: trimmed mean (25% removed)

27/02/2018

FRANCIASO DÍAZ Y ALFONSA GARCÍA


Fuente: \cite{Sakar2013828}

44

## Datasets

[http://www.stimmdatenbank.coli.uni-saarland.de/help\\_en.php4](http://www.stimmdatenbank.coli.uni-saarland.de/help_en.php4)

Saarbrücken Voice Database, Institute of Phonetics, Univ. of Saarland,  
<http://www.stimmdatenbank.coli.unisaarland.de/>

version 2.0 Saarbruecken Voice Database 

Database request

**Speaker:**  male  female Age:  No.:

**Recording session:**  healthy  pathological No.:

**Pathologies and Diagnosis:**

Obligatory pathologies:

Excluded pathologies:

Remarks w.r.t. diagnosis:

**Selection:**

- Amyotrophe Lateralsklerose
- Aryluxation
- Balbuties
- Bulbäparalyse
- Carcinoma in situ
- Chondrom
- Chordektomie
- Cyste
- Diplophonie

**Sorting criteria:**

Speaker number 
 Date of recording 
 Sex of the speaker

27/02/2018

FRANCIASO DÍAZ Y ALFONSA GARCÍA

45

TABLE VI  
SVM CLASSIFICATION ACCURACIES OF INDIVIDUAL VOICE SAMPLES  
THAT YIELDED THE BEST RESULTS

Voice Sample	Kernel Type	Accuracy (%)		Sensitivity (%)	Specificity (%)
			MCC		
Sustained "o"	Linear Kernel	72.50	.4506	70.00	75.00
	RBF Kernel	50.00	.0000	55.00	45.00
"four"	Linear Kernel	72.50	.4506	75.00	70.00
	RBF Kernel	75.00	.5000	75.00	75.00

Fuente: \cite{Sakar2013828}

<https://www.synapse.org/#!Synapse:syn2321745/wiki/61482>

**Patient Voice Analysis (PVA)** Search  Register Log in Help

Synapse ID: syn2321745 Storage Location: Synapse Storage Annotations

Wiki Files Tables Discussion Docker

Patient Voice Analysis (PVA)

- 1. Data Description
- 2. Accessing Data
- 3. PVA Dry-Run Analysis Report
- 4. PVA Team
- Tips and Tricks



patientslikeme



DARPA



Sage

Building a Next Generation Model for Biomedical Research

Validation of health sensors using online community registries and collaborative data interpretation

The **Patient Voice Analysis** project is an effort to assess the severity and fluctuations in Parkinson's disease symptoms from voice recordings. PatientsLikeMe and Dr. Max Little have joined with Sage Bionetworks to collect data and initiate a crowd-sourced analysis. This project is a first in leveraging voice recordings, self-reported outcomes (PDRS) and demographic information from people with Parkinson's disease to address the following question:

**Can we predict the total PDRS score and/or PDRS sub-scores of people from their voice?**

**Goals:**

1. Prove that crowdsourcing approaches to collect voice recordings can be linked to self-reported outcomes and analyzed safely in a distributed competition to validate the use of health sensors in diagnostic and biomedical research.
2. Combine three methods that have each been established independently.
  - a. Collecting validated patient-reported outcomes (PRO) through an online patient community (PatientsLikeMe)
  - b. Mass collection of voice samples to characterize Parkinson's disease (Parkinson's Voice Initiative)
  - c. Community-based, reproducible collaborative data analysis on Synapse (Sage Bionetworks)
3. Identify barriers and solutions to expand the scope of this work into a novel, rapid, cost-effective way of validating the therapeutic value of new health sensors in brain diseases.

# Resumen de algunas publicaciones recientes

27/02/2018

FRANCIASO DÍAZ Y ALFONSA GARCÍA

48

Expert Systems with Applications 37 (2010) 1568–1572



Contents lists available at ScienceDirect

Expert Systems with Applications

journal homepage: [www.elsevier.com/locate/eswa](http://www.elsevier.com/locate/eswa)

## A comparison of multiple classification methods for diagnosis of Parkinson disease

Resul Das

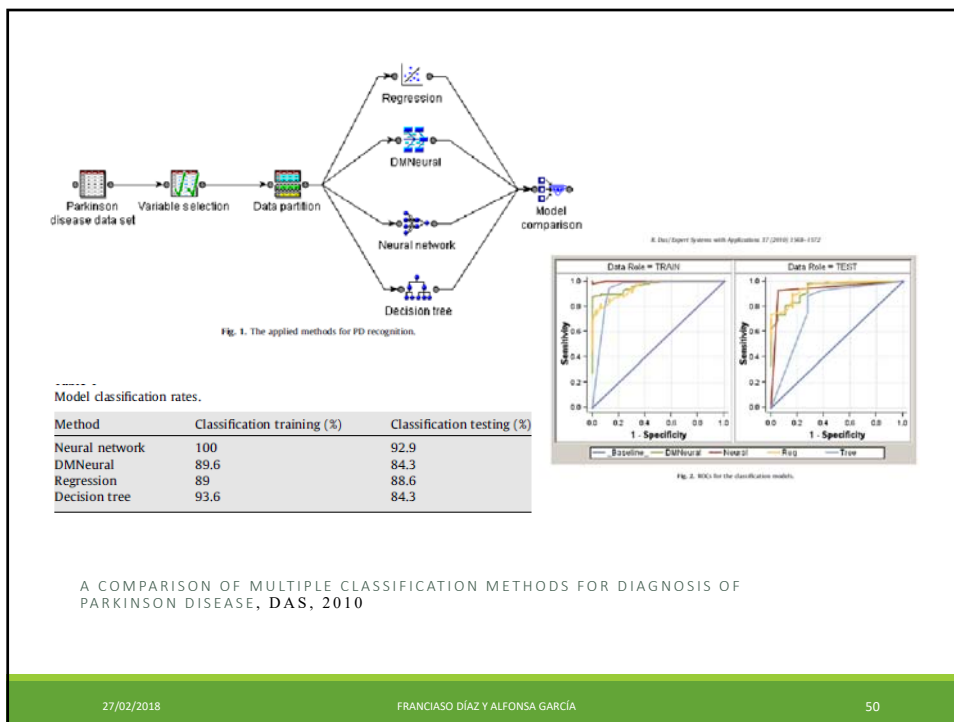
*Department of Informatics, Firat University, 23119 Elazığ, Turkey*

**THIS DATASET IS COMPOSED OF A RANGE OF BIOMEDICAL VOICE MEASUREMENTS FROM 31 PEOPLE, 23 WITH PARKINSON'S DISEASE (PD). EACH COLUMN IN THE TABLE IS A PARTICULAR VOICE MEASURE, AND EACH ROW CORRESPONDS ONE OF 195 VOICE**

27/02/2018

FRANCIASO DÍAZ Y ALFONSA GARCÍA

49



A COMPARISON OF MULTIPLE CLASSIFICATION METHODS FOR DIAGNOSIS OF PARKINSON DISEASE, DAS, 2010

Expert Systems with Applications 40 (2013) 263–271

Contents lists available at SciVerse ScienceDirect

**Expert Systems with Applications**

journal homepage: [www.elsevier.com/locate/eswa](http://www.elsevier.com/locate/eswa)

An efficient diagnosis system for detection of Parkinson's disease using fuzzy *k*-nearest neighbor approach

Hui-Ling Chen<sup>a,\*</sup>, Chang-Cheng Huang<sup>a</sup>, Xin-Gang Yu<sup>b</sup>, Xin Xu<sup>c</sup>, Xin Sun<sup>d</sup>, Gang Wang<sup>d</sup>, Su-Jing Wang<sup>d</sup>

<sup>a</sup> College of Physics and Electronic Information, Wenzhou University, Wenzhou, Zhejiang 325035, China  
<sup>b</sup> Guangzhou Military Region, Guang Zhou, Guang Dong 510000, China  
<sup>c</sup> China Classification Society, Digital Easy Technology Development Co. LTD, Beijing 100007, China  
<sup>d</sup> College of Computer Science and Technology, Jilin University, Changchun 130012, China

Las muestras son asignadas a categorías según :

$$u_i(x) = \frac{\sum_{j=1}^k u_{ij} (1/\|x - x_j\|^{2/(m-1)})}{\sum_{j=1}^k (1/\|x - x_j\|^{2/(m-1)})},$$

donde  $i = 1, 2, \dots, C$ , y  $j = 1, 2, \dots, K$ , con el número de clases igual a  $C$  y  $k$  el número de vecinos cercanos.

El parámetro de fuerza fuzzy  $m$  se utiliza para determinar cuánto pesa la distancia cuando se calcula la contribución de cada vecino al valor de pertenencia, y su valor se suele elegir como  $m \in (1, \infty)$ .

$\|x - x_j\|$  es la distancia entre  $x$  y su  $j$ -ésimo vecino más cercano  $x_j$ ,  
 $U_{ij}$  Es el grado de pertenencia de la Patrón  $x_j$  del conjunto de entrenamiento a la clase  $i$ , entre los  $k$  más cercanos Vecinos de  $x$ .

Hay dos maneras de definir  $U_{ij}$ , una manera es la membrecía cruda, es decir, cada patrón de entrenamiento tiene membrecía completa en su clase conocida y no es miembro de las otras clases.

La otra forma es la pertenencia borrosa restringida, es decir, los  $k$  más cercano vecinos de cada patrón de entrenamiento (por ejemplo,  $x_k$ ), y la pertenencia de  $x_k$  en cada clase se asigna como:

$$u_{ij}(x_k) = \begin{cases} 0.51 + (n_j/K) \cdot 0.49, & \text{if } j = i, \\ (n_j/K) \cdot 0.49, & \text{if } j \neq i. \end{cases}$$

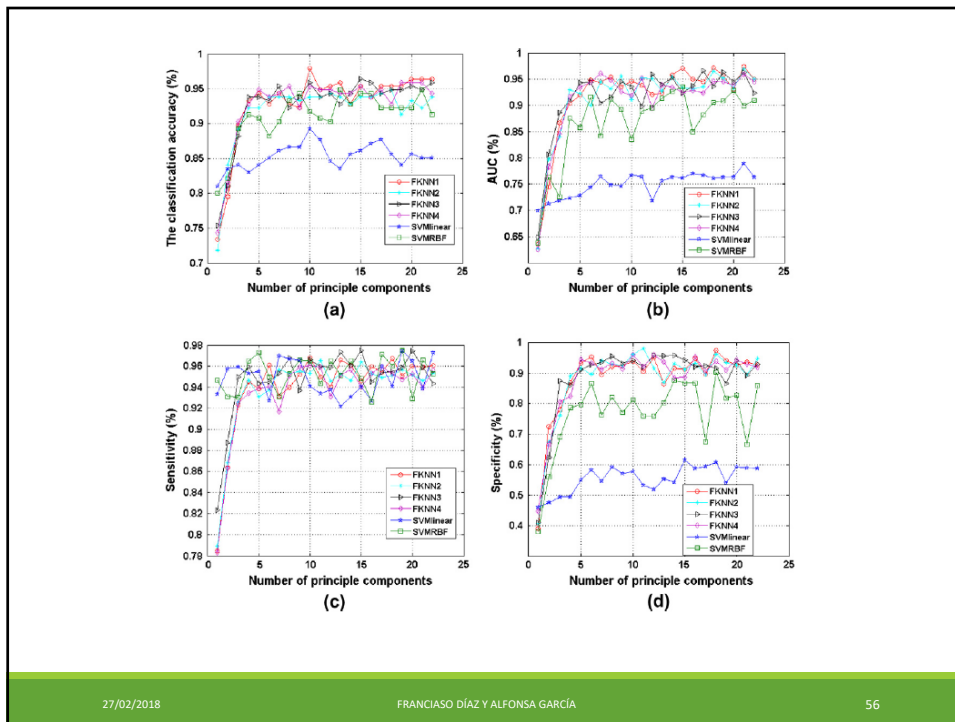
$$\sum_{i=1}^C u_{ij} = 1, \quad j = 1, 2, \dots, n,$$

$$0 < \sum_{j=1}^n u_{ij} < n,$$

$$u_{ij} \in [0, 1].$$

$$C(x) = \arg \max_{i=1}^C (u_i(x))$$





Neurocomputing 000 (2017) 1–14

Contents lists available at [ScienceDirect](http://www.sciencedirect.com)



## Neurocomputing

journal homepage: [www.elsevier.com/locate/neucom](http://www.elsevier.com/locate/neucom)




**Parkinson's disease monitoring by biomechanical instability of phonation**

Pedro Gómez-Vilda\*, Daniel Palacios-Alonso, Victoria Rodellar-Biarge, Agustín Álvarez-Marquina, Víctor Nieto-Lluis, Rafael Martínez-Olalla

*Biomedical Technology Center, Universidad Politécnica de Madrid, Campus de Montegancedo, s/n, 28223 Pozuelo de Alarcón, Madrid, Spain*

**Biomechanical analysis of phonation :**

P. Gómez-Vilda et al., Disease monitoring by biomechanical instability of phonation, Neurocomputing (2017)



$$f_c = \mu_{cl} \frac{\partial v_{cl}}{\partial t} + \xi_{cl} \left( \int_{\tau=t_0}^t (v_{cl} - v_{bl}) d\tau \right) + \sigma_{cl} v_{cl} + \mu_{bl} \frac{\partial v_{bl}}{\partial t} + \xi_{bl} \int_{\tau=t_0}^t v_{bl} d\tau + \sigma_{bl} v_{bl}$$

Fig. Vocal fold 2-mass biomechanical model used in the study: the body and cover structures (diagonal and horizontal line textures), behave as dynamic masses, corresponding to musculus vocalis and lamina propria. The visco-elastic wall links and Reinke's space ligaments behave as damped springs. [Tomado de: P. Gómez-Vilda et al., Disease monitoring by biomechanical instability of phonation, Neurocomputing (2017),]

Journal of Communication Disorders 51 (2014) 19–28



Contents lists available at ScienceDirect

Journal of Communication Disorders



**Articulatory–acoustic vowel space: Application to clear speech in individuals with Parkinson's disease**



Jason A. Whitfield\*, Alexander M. Goberman

Department of Communication Sciences and Disorders, 200 Health and Human Services Building, Bowling Green State University, Bowling Green, OH 43403, USA

BUSQUEDA DE DIFERENCIAS SIGNIFICATIVAS EN EL ESPACIO VOCAL ARTICULATORIO-ACÚSTICO (AAVS).


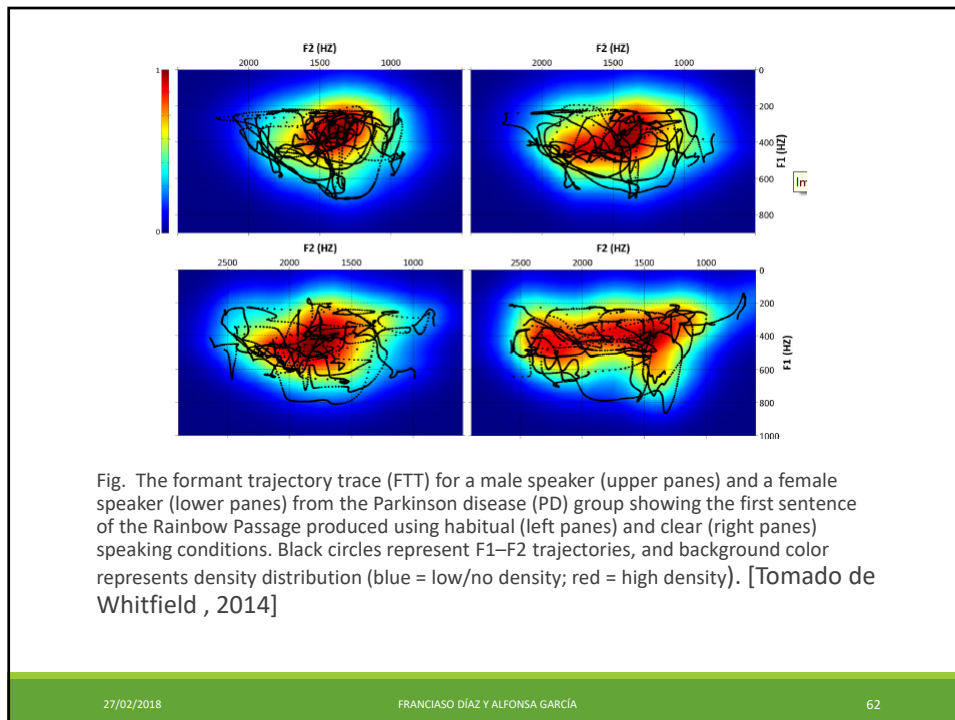


Fig. A model formant trajectory trace (FTT) for the first sentence of the Rainbow Passage produced using habitual speech by an older adult control female participant. Black circles represent F1–F2 trajectories, and background color represents density distribution (blue = low/no density; red = high density). (For interpretation of the references to color in this figure legend, the reader is referred to the web version of this article.) [Tomado de Whitfield , 2014]

La AAVS se calcula a partir de trayectorias de formantes continuamente muestreadas.

La medida de AAVS fue significativamente menor en individuos con EP.

En el estudio actual, la nueva medida de AAVS se muestra como sensible a las diferencias de grupo relacionadas con la enfermedad y los cambios en la función articulatoria.



27/02/2018

FRANCIASO DÍAZ Y ALFONSA GARCÍA

62

Articulatory–acoustic vowel space: Medida calculada con las varianza de F1 y F2.

Table 1 Means and standard deviations (SD) of the articulatory–acoustic vowel space (AAVS) and perceptual rating of speech clarity (clarity rating) for males and females in the control group (OA) and in individuals with Parkinson disease (PD).

	AAVS (kHz <sup>2</sup> )	
	Male	Female
OA Group		
Habitual	Mean = 38.45, SD = 5.20	Mean = 64.59, SD = 9.77
PD Group		
Habitual	Mean = 26.88, SD = 5.73	Mean = 49.33, SD = 21.58
Clear	Mean = 31.97, SD = 7.81	Mean = 61.43, SD = 21.30

[Tomado de Whitfield , 2014]

27/02/2018

FRANCIASO DÍAZ Y ALFONSA GARCÍA

63

BIOCYBERNETICS AND BIOMEDICAL ENGINEERING 34 (2014) 35–45



Available online at [www.sciencedirect.com](http://www.sciencedirect.com)

**ScienceDirect**

journal homepage: [www.elsevier.com/locate/bbe](http://www.elsevier.com/locate/bbe)



**Original Research Article**

**Classification of speech intelligibility in Parkinson's disease** 

Taha Khan<sup>a,b,\*</sup>, Jerker Westin<sup>b</sup>, Mark Dougherty<sup>b</sup>

<sup>a</sup> School of Innovation, Design and Technology, Mälardalen University, Västerås, Sweden  
<sup>b</sup> School of Technology and Business Studies, Computer Engineering, Dalarna University, Falun, Sweden

---

27/02/2018
FRANCIASO DÍAZ Y ALFONSA GARCÍA
66

Running Speech Tests (RST). RST-1, RST-2, RST-3

- “The North Wind and the Sun”,
- “The Rainbow Passage”
- “The Grandfather Passage”

---

<sup>a</sup> Running Speech Test-1: “The north wind and the sun were disputing which one is the stronger when a traveler came along wrapped in a warm cloak. They agreed that the one who first succeeded in making the traveler’s take his cloak off should be considered the stronger. Then the north wind blew as hard as it could but the more he blew the more closely the traveler pulled his cloak around him and at last the north wind gave up the attempt. Then the sun shined out and immediately the traveler took off his cloak and so the north wind was agreed that the sun was the stronger of the two.”

<sup>b</sup> Running Speech Test-2: “When the sunlight strikes rain drops in the air, they act like a prism and form a rainbow. The rainbow is a division of white light into many beautiful colors. These take the shape of a long round arch with its path high above and its two ends apparently beyond the horizon. There is according to a legend a boiling part of gold at one end. People look but no one ever finds it. When a man looks for something beyond his reach, his friends say he is looking for the part of gold at the end of the rainbow.”

<sup>c</sup> Running Speech Test-3: “Do you wish to know all about my grandfather; well he is nearly 93 years old. He dresses himself in an ancient black frock coat usually minus several buttons. Yeah he still thinks he is swifty as ever. A long flowing beard clings to his chin giving those who observe him a pronounced feeling of an outmost respect. When he speaks, his voice is just a bit cracked and covers the trifle. Twice each day, he plays skillfully and with a zest upon a small organ except in the winter when the ooze or snow or ice prevents he slowly takes a short walk in the open air each day. We have often urged him to walk more and smoke less but he always answers ‘banana oil’. Grandfather likes to be modern in his language.”

---

27/02/2018
FRANCIASO DÍAZ Y ALFONSA GARCÍA
67



**USING CLASIFICATION ALGORITHMS FOR TELEMONITORING PARKINSON'S DISEASE SEVERITY**

Francisco DÍAZ-PEREZ<sup>1</sup>, Alfonsa GARCÍA-LÓPEZ<sup>1</sup>, Manuel RUBIO-SÁNCHEZ<sup>2</sup>, Agustín ÁLVAREZ-MARQUINA<sup>1</sup>

1: Universidad Politécnica de Madrid (Spain), 2: Universidad Rey Juan Carlos, Madrid (Spain)



**INTRODUCTION**

Parkinson's Disease (PD) is a neurodegenerative disorder of central nervous system that affect the control mechanisms of the human body [1]. People with Parkinson (PWP) suffer tremors, slowness of movement, rigidity and postural instability.

The early PD symptoms include disorders in the patient's voice.

There has been much recent research into the connection between PD and voice.

**Analysis of vocal disorders can be a procedure in diagnosing and monitoring PD progression.**

- **MAX**: Five categories in motor symptoms.
- **Unified Parkinson's Disease Rating Scale (UPDRS)**: Motor and non-motor symptoms.
- **PDVS scale**: An abbreviated version of the UPDRS, that rates the clinical observations and assesses the impact of PD on the day-to-day life of PWP.
- **PVA questionnaire**: 17 questions about sensory problems, hallucinations, mood, activities, speech, executive skills, swallowing, handwriting, eating, fluid, driving, hygiene, falling, falling, freezing, walking, tremors and confusion. It can be self-administered and completed easily and quickly.

**OBJECTIVE**

To analyze the relationship between voice features and PD severity in a PD telemonitoring system.



PD TELEMONITORING



PVA Challenge  
www.synapse.org

**THE PVA DATA SET**

- 170 samples from 630 PWP (with voice report calls), including:
- Brief voice recordings of sustained vowel phonations (3-30 seconds)
- 38 features extracted from the voice recordings (Table 1)

**METHODOLOGY**

1. To analyze the data set and define the train subset.
2. To explore correlation coefficients for doing a feature selection.
3. To use classification methods in a standard supervised learning setup.

**Criteria for feature selection:** Correlation coefficients, for group of features.

**Classification algorithms:**

- Decision tree (DT), with Gini index and Manhattan/10 or 40.
- Support Vector Machines (SVM), with linear, Gaussian, linear and cubic.
- K-nearest neighbors (KNN), with different distances and 1, 3 or 10 neighbors.

All the classifiers have been experimented both, with feature selection and without feature selection.

Our approach assumes that the data set is a good representation of the overall data. As validation procedure we use resubstitution (5:1:5 R).

All the algorithms were implemented in MATLAB®/R2014b/200 runs on each model. First with all the features together and then with made and female subsets separately.

We compared model performance on the basis of mean absolute error:

$$MAE = \frac{1}{N} \sum_{i=1}^N |f_i - y_i|$$

where  $f_i$  is the predicted class,  $y_i$  the actual class,  $N$  the number of phonations in the test subset and  $i$  contains the index of that set.

For each model experiment, the MAE over the 200 realizations has been averaged and we have chosen the best classifier as the one with the highest rate of correctly classified items (CCT).

**RESULTS**

Some dysphasia symptoms are highly correlated with each other, which suggested the use of feature selection methods.

**Our Feature Selection:**  
 $f_1, f_2, f_3, f_4, f_5, f_6, f_7, f_8, f_9, f_{10}, f_{11}, f_{12}, f_{13}, f_{14}, f_{15}, f_{16}, f_{17}, f_{18}, f_{19}, f_{20}$

**CONCLUSIONS**

- This research has been based on a public dataset created by Synapse through an online patient community.
- The speech sound samples of PD patients can be used as an input to a telemonitoring support system.
- This innovative approach facilitates remote tracking of disease progression, minimizing the need of regular visits to the clinic.
- Synapse PVA challenge facilitates, non-invasive remote tracking of disease progression and contributes to research by generating accessible data bases.
- Despite possible lack of precision, due to the fact the test have been self-administered (without medical check), the results prove that it is possible to estimate the severity of PD from the analysis of the vocal features collected on line.
- The best classifier has been a KNN with 15 features and 3 neighbors.
- However, working with PVA data set we observed that the quality of the data itself limited the potential accuracy of the methods.
- For future work we propose to include quality control strategies in data acquisition. Improving the quality of voice recordings and PVA questionnaire answers could bring better results in the performance of the classification models.
- Undoubtedly the increase of the database would facilitate large-scale clinical trials in PD treatment.

27/02/2018

FRANCIASO DÍAZ Y ALFONSA GARCÍA

71

## Conclusiones

- Estudios multidisciplinares.
- Técnicas de Procesado de señales y minería de datos son determinantes.
- La poca disponibilidad de Conjuntos de datos es una limitante importante.
- Las investigaciones orientadas al diagnóstico y seguimiento utilizan una de tres opciones (formular nuevos biomarcadores, selección de características o modelos de predicción).

27/02/2018

FRANCIASO DÍAZ Y ALFONSA GARCÍA

72

## Bibliografía

[Ack.91] Ackermann H, Ziegler W. Articulatory deficits in parkinsonian dysarthria: an acoustic analysis. *J Neurol Neurosurg Psychiatry*, 1991; 54: 1093-8.

[Sko.08] Skodda S, Schlegel U. Speech rate and rhythm in Parkinson's disease. *Mov. Disord.* 2008; 23: 985-92.

[Mil.07] Miller N, Allcock L, Jones D, Noble E, Hildreth AJ, Burn D. Prevalence and pattern of perceived intelligibility changes in Parkinson's disease. *J Neurol Neurosurg Psychiatry* 2007; 78: 1188-90.

[Mor.05] Mori H, Kobayashi Y, Kasuya H, Kobayashi N, Hirose H. Evaluation of fundamental frequency (F0) characteristics of speech in dysarthrias: a comparative study. *Acoust. Sci. Technol.* 2005; 26: 540-3.

[Rah.07] Rahn DA, Chou M, Jiang JJ, Zhang Y. Phonatory impairment in Parkinson's disease: evidence from nonlinear dynamic analysis and perturbation analysis, *J Voice* 2007; 2164-71.

[Gall.01] Gallena S, Smith PJ, Zeffiro T, Ludlow CL. Effects of levodopa on laryngeal muscle activity for voice onset and offset in Parkinson disease. *J Speech Lang Hear Res* 2001; 44: 1284-99.

[Mid.08] Midi I, Dogan M, Koseoglu M, Can G, Sehitoglu MA, Gunal DI. Voice abnormalities and their relation with motor dysfunction in Parkinson's disease. *Acta Neurol Scand* 2008; 117: 26-34.

Muchas gracias por vuestra atención.