

19



OFICINA ESPAÑOLA DE
PATENTES Y MARCAS

ESPAÑA



11 Número de publicación: **2 647 460**

51 Int. Cl.:

G06N 7/00 (2006.01)

G06N 3/08 (2006.01)

12

TRADUCCIÓN DE PATENTE EUROPEA

T3

96 Fecha de presentación y número de la solicitud europea: **09.10.2009** **E 09172642 (2)**

97 Fecha y número de publicación de la concesión europea: **16.08.2017** **EP 2180436**

54 Título: **Sistema de procedimiento de aprendizaje semi-supervisado para la clasificación de datos a partir de parámetros discriminatorios**

30 Prioridad:

23.10.2008 FR 0857194

45 Fecha de publicación y mención en BOPI de la traducción de la patente:

21.12.2017

73 Titular/es:

**COMMISSARIAT A L'ENERGIE ATOMIQUE ET
AUX ENERGIES ALTERNATIVES (100.0%)
BATIMENT "LE PONANT D" 25, RUE LEBLANC
75015 PARIS, FR**

72 Inventor/es:

**GAILLARD, PIERRE y
AUPETIT, MICHAËL**

74 Agente/Representante:

UNGRÍA LÓPEZ, Javier

ES 2 647 460 T3

Aviso: En el plazo de nueve meses a contar desde la fecha de publicación en el Boletín Europeo de Patentes, de la mención de concesión de la patente europea, cualquier persona podrá oponerse ante la Oficina Europea de Patentes a la patente concedida. La oposición deberá formularse por escrito y estar motivada; sólo se considerará como formulada una vez que se haya realizado el pago de la tasa de oposición (art. 99.1 del Convenio sobre Concesión de Patentes Europeas).

DESCRIPCION

Sistema de procedimiento de aprendizaje semi-supervisado para la clasificación de datos a partir de parámetros discriminatorios

5

Antecedente de la invención

La invención pertenece al campo de los sistemas de aprendizaje semi-supervisado para la clasificación de datos.

10 En este documento, la noción de datos debe comprenderse en el sentido más amplio y puede designar principalmente objetos o eventos.

15 La invención se puede aplicar principalmente, de manera no limitativa, al reconocimiento de caracteres, a la supervisión de eventos geofísicos, y a la clasificación de imágenes y de sonidos, al control de calidad de objetos o de productos fabricados y al mantenimiento preventivo de equipos.

20 Se recuerda que el aprendizaje semi-supervisado se distingue del aprendizaje supervisado porque utiliza a la vez datos etiquetados y datos no etiquetados. Para más información, el técnico puede recurrir principalmente al documento Web http://en.wikipedia.org/wiki/Semi-supervised_learning.

25 Un procedimiento conocido de aprendizaje semi-supervisado se describe en el Artículo « Harmonic mixtures : combining mixture models and graph-based methods for inductive and scalable semi-supervised learning » de X. Zhu y J. Lafferty, publicado en el documento Proceedings of the 22nd International Conference on Machine Learning, páginas 1052-1059, New York, USA, 2005, ACM.

30 Este procedimiento consiste principalmente en representar los datos por un cierto número de prototipos, etiquetas estos prototipos, crear un grafo, cuyas cimas están constituidas por los datos y cuya cima está conectada por un arco a sus K vecinos más próximos, ponderar estos arcos, propagar las etiquetas en el grafo, teniendo en cuenta la ponderación citada anteriormente, informar sobre los prototipos a las etiquetas de los datos que representan y clasificar los datos en función de la etiqueta llevada por sus prototipos después de la propagación.

Este método presenta un inconveniente principal en que necesita parametrizar manualmente el número de prototipos, el parámetro K de la vecindad del grafo y la ponderación de los arcos.

35 Además, este método es muy sensible al ruido sobre los datos.

40 Se conoce igualmente el documento de Gaillard et al « Learning topology of a labeled data set with the supervised generative Gaussian graph » Neurocomputing, Elsevier Science Publishers, Amsterdam, NL, vol 17, no 7-9, 1 de Febrero de 2008. Este documento describe un método de aprendizaje supervisado, en el que todos los datos están etiquetados; este método no describe ningún método de clasificación de los datos.

45 Se conoce igualmente el documento « A mixture of experts classifier with learning based on both labelled and unlabelled data » de Miller y Uyar publicado en "Neural Information Processing Systems"; MIT PRESS en 1997, que describe un clasificador de aprendizaje basado en datos etiquetados y en datos no etiquetados.

45

Objeto y resumen de la invención

La presente invención tiene por objeto principal resolver los inconvenientes mencionados anteriormente.

50 A este efecto, la invención se refiere a un procedimiento de aprendizaje semi-supervisado ejecutado por ordenador para la clasificación de datos, al menos algunos de los cuales están etiquetados con una etiqueta seleccionada entre una pluralidad de clases predeterminadas, no estando etiquetadas las otras, comprendiendo este procedimiento:

- 55
- una etapa de construcción de un modelo local en el curso de la cual se representa cada uno de dichos datos por un prototipo; y
 - una etapa de etiquetado de cada prototipo con una etiqueta que comprende para cada clase una probabilidad de que dicho prototipo pertenezca a dicha clase;
 - una etapa de definición de un grafo generador, cuyos nudos están constituidos por dichos prototipos;
 - una etapa de atribución de un peso a cada uno de los arcos de este grafo, siendo estimado este peso por
 - 60 la densidad de los datos alrededor de este arco;
 - una etapa de propagación de dichas etiquetas en el grado hasta un estado de convergencia, la propagación de una etiqueta asociada a un primer prototipo hacia un segundo prototipo unido a dicho primer prototipo por un arco que consiste en modificar las probabilidades de la etiqueta del primer prototipo;
- y

- una etapa de clasificación de dichos datos en función de la etiqueta de los prototipos que representan dichos datos después de dicha propagación, siendo atribuida la clase de los datos no etiquetados según la regla del máximo a posteriori.

5 De manera más ventajosa, la utilización de un grafo generador permite una ponderación automática de los arcos, es decir, sin intervención del usuario.

10 Un "grafo generador" se define en el Artículo de M. Aupetit « Learning Topology with the Generative Gaussian Graph and the EM Algorithm » publicado en el documento Advances in Neural Information Processing Systems 18, páginas 83-90, MIT Press Cambridge MA, 2006.

Conforme a la invención, los nudos del grafo generador no están constituidos por datos ellos mismos, sino por los prototipos de estos datos.

15 Gracias a esta característica, el procedimiento de aprendizaje es muy robusto al ruido sobre los datos. Además, permite tratar datos incompletos, por ejemplo reconocer caracteres incompletos, para los que uno o varios píxeles han sido mal adquiridos o perdidos.

20 En un modo particular de realización, el posicionamiento de los prototipos y la ponderación de los arcos del grafo generador son optimizados utilizando el algoritmo EM descrito también en el documento mencionado anteriormente.

El algoritmo EM es un método iterativo no paramétrico que permite encontrar automáticamente los parámetros de un modelo incrementando al máximo la verosimilitud.

25 El grafo generador de la invención presenta de esta manera la ventaja de ser optimizado por aprendizaje estadístico siguiendo el criterio objetivo del máximo de verosimilitud, de ser generador y, por consiguiente, de tener en cuenta el ruido en los datos, de permitir el tratamiento de datos incompletos, imprecisos o inciertos.

30 En un grafo obtenido de esta manera, el peso de un arco que se basa en dos prototipos representa la densidad alrededor de este arco (cuanto mayor es la densidad entre dos prototipos, mayor es el peso del arco que se basa en estos dos prototipos).

En un modo particular de realización, los arcos del grafo generador están definidos por un sub-grafo de Delaunay.

35 Tal grafo es un grafo no paramétrico. Su utilización presenta la ventaja, con relación a la técnica anterior, de no necesitar parametrización manual del parámetro K de la vecindad.

40 Para más información sobre el método de Delaunay, el técnico puede recurrir documento "O. Okabe, B. Boots et K. Sugihara - Spatial Tessellations : concept and applications of Voronoï diagrams, John Wiley, Chichester, 1992."

45 En un modo particular de realización, el número N de prototipos se determina utilizando un modelo de mezcla, cada uno de cuyos componentes está centrado sobre un prototipo y un criterio estadístico BIC « Bayesian Information Criterion » propuesto por G. Schwartz en el Artículo « Estimating the dimension of a model » publicado en 1978 en el documento « The Annals of Statistics, 6(58), páginas 461-464 ».

Esta característica permite ventajosamente evitar la parametrización manual del número de prototipos.

En un modo particular de realización, se utiliza un modelo de mezcla gaussiano.

50 Se obtiene un procedimiento de aprendizaje muy robusto al ruido sobre los datos, cuando este ruido es de naturaleza gaussiana.

55 En un modo particular de realización, los arcos del grafo generador están definidos por un sub-grafo (o aproximación) del grafo de Delaunay del tipo « Topology Representing Network » (TRN) tal como se presenta en el documento de T. Martinetz y K. Schulten "Topology Representing Networks", Neural Networks Elsevier Londres, vol. 7 páginas 507-522, 1994.

Se recuerda que un grafo TRN conecta dos cimas, si éstas son las dos cimas más próximas de un dato.

60 Tal grafo presenta la ventaja de construirse muy rápidamente y de optimizar el tiempo de cálculo.

En un modo particular de realización, la modificación de las probabilidades de la etiqueta del segundo prototipo después de la propagación de la etiqueta del primer prototipo es también función de las probabilidades de la etiqueta de dicho segundo prototipo.

En un modo particular de realización, las diferentes etapas del procedimiento de aprendizaje están determinadas por instrucciones de programas de ordenadores.

5 En consecuencia, la invención se refiere también a un programa de ordenador sobre un soporte de informaciones, siendo este programa susceptible de ser ejecutado en un ordenador, comprendiendo este programa instrucciones adaptadas a la ejecución de etapas de un procedimiento de aprendizaje, tal como se ha descrito anteriormente.

10 Este programa puede utilizar cualquier lenguaje de programación, y puede estar en forma de código fuente, código objeto, o de código intermedio entre código fuente y código objeto, tal como en una forma parcialmente compilada, o en cualquier otra forma adecuada.

La invención se refiere también a un soporte de informaciones legible por ordenador, y que comprende instrucciones de un programa de ordenador, tal como se ha mencionado anteriormente.

15 El soporte de informaciones puede ser cualquier entidad o dispositivo capaz de almacenar el programa. Por ejemplo, el soporte puede comprender un medio de almacenamiento, tal como una ROM, por ejemplo una CD ROM o una ROM de circuito microelectrónico, o incluso un medio de registro magnético, por ejemplo, un disquete (floppy disc) o un disco duro.

20 Por otra parte, el soporte de informaciones puede ser un soporte transmisible tal como una señal eléctrica u óptica, que puede ser conducida a través de un cable eléctrico u óptico, por radio o por otros medios. El programa según la invención puede ser, en particular, telecargado sobre una red de tipo Internet.

25 Alternativamente, el soporte de informaciones puede ser un circuito integrado en el que el programa está incorporado, estando el circuito adaptado para ejecutar o para ser utilizado en la ejecución del procedimiento en cuestión.

Breve descripción de los dibujos

30 Otras características y ventajas de la presente invención se deducirán a partir de la descripción siguiente, realizada con referencia a los dibujos anexos que ilustran un ejemplo de realización desprovisto de cualquier carácter limitativo. En las figuras:

35 La figura 1 representa cifras manuscritas que pueden ser clasificadas por un procedimiento y un sistema de aprendizaje según la invención.

La figura 2 representa, en forma de organigrama, las principales etapas de un procedimiento de aprendizaje conforma a la invención en un modo particular de realización.

40 Las figuras 3A a 3C son grafos intermedios que pueden ser utilizados por un procedimiento y un sistema de aprendizaje según la invención.

La figura 4 representa etiquetas que pueden ser utilizadas en la invención; y

45 La figura 5 ilustra las actuaciones de la invención.

Descripción detallada de un modo de realización

50 La presente invención se describirá ahora en el contexto del reconocimiento de caracteres, por ejemplo para una aplicación de clasificación automática de correo postal.

Con la finalidad de simplificación, se limitará a describir el procedimiento para reconocer cifras 1 y 2 manuscritas por diferentes personas.

55 Se supone en este contexto que se dispone de un cierto número de imágenes de cifras 1 y 2 manuscritas, tal como se representa en la figura 1.

60 Cada imagen se define por un vector a M componentes (64 en el ejemplo de la figura 1), cada uno de cuyos componentes representa el nivel de gris de un pixel de la imagen.

Estas ciertas imágenes están, además, etiquetadas por un usuario, comprendiendo la etiqueta la cifra << 1 >> o << 2 >> reconocida por el usuario.

El procedimiento de aprendizaje según la invención se refiere a etiquetar los datos no etiquetados, dicho de otra

manera, a detectar automáticamente si una imagen representa un << 1 >> o un << 2 >>.

La figura 2 representa en forma de organigrama las principales etapas de un procedimiento de aprendizaje según la invención.

5 En el curso de una primera etapa E10, se representan datos etiquetados o no por M variables, correspondiendo cada variable a un pixel, en un espacio de M dimensiones.

10 Un ejemplo de representación en un espacio de 2 dimensiones se da en la figura 3A. En este ejemplo, cada dato D_i se representa por un círculo en un espacio E de dos dimensiones.

La invención pertenece al campo de los procedimientos de aprendizaje semi-supervisado, lo que significa que cada uno de estos datos D_i puede ser etiquetado o no.

15 En el ejemplo descrito aquí, los datos D_i pueden pertenecer a 2 clases posibles y se adopta la representación gráfica siguiente:

- los datos D_i etiquetados de la primera clase con apuntados por una flecha F_1 ;
- los datos D_i etiquetados de la segunda clase con apuntados por una flecha F_2 ;
- los datos no etiquetados no son apuntados.

De esta manera, en el ejemplo de la figura 3A, sólo dos datos están etiquetados.

25 La etapa E10 de representación de los datos está seguida por una etapa E20 de construcción de un modelo local, que consiste en representar cada uno de los datos D_i por un prototipo (o representante) P_j .

30 En el ejemplo de realización descrito aquí, los datos son explicados localmente con un modelo de mezcla gaussiana propuesto por D. Miller y S. Uyar en el Artículo «A mixture of experts classifier with learning based on both labelled and unlabelled data», publicado en 1997 en el documento "Neural Information Processing Systems; volumen 9 páginas 571 à 577, MIT Press 1997.

En un modo de realización descrito aquí, el número N de densidades gaussianas se determina con la ayuda del criterio estadístico BIC.

35 La figura 3B representa el resultado de esta modelización para N determinado igual a 12 por el criterio BIC, estando representado cada prototipo P_j por un rombo.

40 El procedimiento según la invención comprende a continuación una etapa E30 de etiquetado de cada uno de los prototipos P_j .

En la figura 3B, la etiqueta de un prototipo P_j está referenciada E_j .

45 En un modo de realización de la invención descrito aquí, se atribuye a cada etiqueta E_j y para cada clase posible C_k , una probabilidad $p_{j,k}$ de que el prototipo P_j asociado a esta etiqueta E_j pertenece a esta clase.

En el ejemplo descrito aquí, las probabilidades son las siguientes.

	$P_{j,1}$	$P_{j,2}$
E1	0,5079	0,4931
E2	0,9854	0,0146
E3	0,5137	0,4863
E4	0,4988	0,5012
E5	0,4966	0,5034
E6	0,5001	0,4999
E7	0,0038	0,9962
E8	0,4997	0,5003
E9	0,4972	0,5028
E10	0,4727	0,5273
E11	0,4997	0,5003
E12	0,4999	0,5001

Dos etiquetas E_1, E_2 se representan a título de ejemplo en la figura 4.

Se comprende a partir de este ejemplo que la probabilidad $p_{1,1}$ (o bien $p_{1,2}$) de que el prototipo P_1 asociado a esta etiqueta E_1 pertenezca a la primera clase (o bien a la segunda clase) es 0,7 (o bien 0,3).

De la misma manera, la probabilidad $p_{1,2}$ (o bien $p_{2,2}$) se que el prototipo p_2 asociado a la etiqueta E_2 pertenezca a la primera clase (o bien a la segunda) es 0 (o bien 1).

En el ejemplo de realización descrito aquí, cada probabilidad $p_{j,k}$ atribuida a una etoqueta E_j es equivalente a la proporción de datos D_i de la clase C_k con relación a todos los datos que el prototipo P_j representa.

El técnico puede encontrar las ecuaciones de estas probabilidades en el documento de D. Miller et S. Uyar citado anteriormente.

La etapa E30 de etiquetado está seguida por una etapa E40 de definición de un grado G generador representado en la figura 3C, en el que:

- los nudos están constituidor por los prototipos P_j identificados en la etapa E20;
- y los arcos están definidos por un sub-grupo de Delaunay, y más precisamente por un grafo TRN.

Se recuerda que un sub-grafo de Delaunay, como un grafo TRN, puede ser utilizado para definir la base de un grafo generador, estando definido tal grafo en el Artículo de M. Aupetit « Learning Topology with the Generative Gaussian Graph and the EM Algorithm » publicado en el documento Advances in Neural Information Processing Systems 18, páginas 83-90, MIT Press Cambridge MA, 2006.

En el modo de realización descrito aquí, los parámetros del grafo de Delaunay son optimizados utilizando el algoritmo EM descrito en el documento citado anteriormente.

De esta manera, a cada arco A del grafo G se atribuye un peso W teniendo en cuenta la densidad de los datos alrededor de este arco.

La etapa E40 de definición y de ponderación del grafo G está seguida por una etapa R50 de propagación de las etiquetas E_j de los prototipos P_j en el grafo G .

Esta etapa tiene por objeto combinar la información local contenida en las etiquetas del prototipo con la información global representada por la estructura del grafo G .

En el ejemplo de realización descrito aquí, se utiliza la propagación armónica descrita en el artículo « Semi-supervised learning using Gaussian fields and harmonic functions » de X. Zhu, Z. Grahramani y J. Lafferty, publicado en el documento Proceedings of the 20th International Conference on Machine Learning, páginas 912-919 en 2003.

En el modo de realización descrito aquí, la probabilidad de propagación de una etiqueta E_j a lo largo de un arco A_{j_1,j_2} definido por dos extremos P_{j_1}, P_{j_2} tiene en cuenta :

- el peso W_{j_1,j_2} de este arco;
- las probabilidades $p_{j,k}$ asociadas a esta etiqueta E_j para cada una de las clases C_k ; y
- las probabilidades $p_{j_1,k}, p_{j_2,k}$ asociadas a las etiquetas E_{j_1}, E_{j_2} de los extremos P_{j_1}, P_{j_2} .

Este método puede verse como el resultado de una marcha aleatoria que propaga las clases a través del grafo de tal manera que la probabilidad de pertenencia de un prototipo a una clase juega un papel de potencial.

De esta manera, cuando más se aproxime a 1 un prototipo de una probabilidad de pertenencia a una clase C_k , mejor se propagará esta clase C_k hacia un prototipo vecino en el grafo.

A la recíproca, cuando más se aproxime a 1 un prototipo de una probabilidad de pertenencia a una clase C_k , menos se propagarán las otras clases de los prototipos vecinos hacia él.

En el ejemplo descrito aquí, las probabilidades, después de la propagación, han evolucionado como sigue:

	$P_{j,1} P_{j,20}$	$P_{j,20}$
E1	0,9989	0,0011
E2	0,9988	0,0012

E3	0,8728	0,1272
E4	0,2144	0,7856
E5	0,1583	0,8417
E6	0, 8261	0,1739
E7	0,0004	0,9996
E8	0,8161	0,1839
E9	0,8086	0,1914
E10	0,0032	0,9968
E11	0,0032	0,9968
E12	0,0032	0,9968

La etapa E50 de propagación es seguida por una etapa E60 de clasificación de los datos D_i en función de la etiqueta de los prototipos P_j que representan estos datos después de la propagación.

5 En el ejemplo de realización descrito aquí, se atribuye la clase de datos no etiquetados según la regla del máximo a posteriori (la clase más probable).

La figura 5 permite ilustrar las actuaciones del procedimiento de aprendizaje según la invención, en su aplicación al reconocimiento de cifras manuscritas.

10 Imágenes normalizadas al formato de mapas binarios son extraídas a partir de cifras manuscritas con la ayuda del programa de tratamiento previo NIST [GARRIS 97]. Treinta personas diferentes han contribuido allí. Las imágenes de mapas binarios de tamaño 32x32 están divididas en 64 bloques de tamaño 4x4 se recubrimiento y el número de píxeles blancos es contado en cada bloque. Cada procedimiento genera una matriz de tamaño 8x8, en la que cada elemento es un entero comprendido entre 0 y 16. A tal fin, se disponen, respectivamente, de 389 y 380 ejemplos de cifras "1" y "2" representadas por 64 variables. En la figura 1 se dan ejemplos de imagen.

Se etiquetan dos imágenes tomadas aleatoriamente. Se utiliza el procedimiento según la invención suministrándose de entrada estas dos imágenes (datos) etiquetadas y el resto de imágenes (767 datos) en su etiqueta:

20 1.1 El sistema construye un modelo de mezcla gaussiana para explicar localmente los datos. El número N de componentes seleccionados por el sistema con la ayuda del criterio BIC es 40.

25 1.2 El sistema construye el modelo de grafo generador para explicar globalmente la estructura de los datos a partir de los componentes determinados en la etapa precedente.

1.3-2 El sistema combina los modelos local y global con la ayuda de una marcha aleatoria con el fin de construir un nuevo clasificador.

30 3. El sistema clasifica los datos no etiquetados que han servicio para el aprendizaje y retorna la clase prevista de cada imagen.

A continuación se comparan las clases mencionadas anteriormente por el sistema y las clases reales, lo que permite atribuir un porcentaje de buena clasificación al sistema.

35 Se repite este procedimiento aumentando progresivamente el número de datos etiquetados suministrados en la entrada del sistema. Se trazan, como se representa en la figura 5, las actuaciones del procedimiento según la invención en función del número de datos etiquetados.

40 Se comparan las actuaciones del procedimiento según la invención (símbolos redondos) con otros dos métodos:

- uno generativo que corresponde a un modelo de mezcla [Miller 96] (el obtenido al final de la primera etapa 1.1, símbolos triangulares, punta en alto), y
- el otro es el método de grafo que propaga las etiquetas disponibles a través del grafo de los vecinos más próximos [Zhu03] (símbolos triangulares, punta abajo).

45 Para este último, los parámetros del modelo (el grado de vecindad del grafo y la varianza de nudo gaussiano que pondera los enlaces) son fijados por las heurísticas propuestas en [Chapelle06], puesto que la validación cruzada es imposible cuando el número de datos etiquetados es pequeño.

50 La figura 5 muestra curvas que comparan las actuaciones de los diferentes sistemas. Se constata que con el procedimiento según la invención se obtiene un porcentaje de buena clasificación superior a los otros métodos cuando el número de datos etiquetados es muy pequeño.

Referencias citadas

- [Chapelle06]
5 O. Chapelle, B. Scholkopf et A. Zien, "Semi-Supervised Learning", MIT Press, Cambridge, MA 2006.
- [Garris97]
10 M. Garris, J. Blue, G. Candela, P. Grother, S. Janet et C. Wilson, "Nist form-based handpring recognition system (release 2.0)", 1997.
- [Miller96]
15 D. Miller et S. Uyar, "A generalized gaussian mixture classifier with learning based on both labelled and unlabelled data", Proceedings of the 1966 Conference on Information Science and Systems, 1996.
- [Zhu03]
20 X. Zhu, Z. Grahramani et J. Lafferty, "Semi-supervised learning using Gaussian fields and harmonic functions". Proceedings of the 20nd International Conference on Machine learning", páginas 912-919, 2003.

REIVINDICACIONES

- 5 1.- Procedimiento de aprendizaje semisupervisado ejecutado por ordenador para la clasificación de datos (D_i), al menos algunos de los cuales están etiquetados con una etiqueta seleccionada entre una pluralidad de clases (C_k) predeterminadas, no estando etiquetadas las otras, comprendiendo este procedimiento:
- una etapa (E20) de construcción de un modelo local en el curso de la cual se representa cada uno de dichos datos (D_i) por un prototipo (P_j);
 - 10 - una etapa (E30) de etiquetado de cada prototipo (P_j) con una etiqueta (E_j) que comprende para cada clase (C_k) una probabilidad ($P_{j,k}$) de que dicho prototipo (P_j) pertenezca a dicha clase (C_k);
 - una etapa (E40) de definición de un grafo generador (G), cuyos nudos están constituidos por dichos prototipos (P_j);
 - una etapa (R40) de atribución de un peso (W_{j_1, j_2}) a cada uno de los arcos (A_{j_1, j_2}) de este grafo, siendo estimado este peso por la densidad (d_{j_1, j_2}) de los datos alrededor de este arco;
 - 15 - una etapa (E50) de propagación de dichas etiquetas (E_j) en el grafo (G) hasta un estado de convergencia, la propagación de una etiqueta asociada a un primer prototipo (P_{j_1}) hacia un segundo prototipo (P_{j_2}) unido a dicho primer prototipo (P_{j_1}) por un arco (A_{j_1, j_2}) que consiste en modificar las probabilidades de la etiqueta (E_{j_2}) del primer prototipo; y
 - 20 - una etapa (E60) de clasificación de dichos datos (D_i) en función de la etiqueta de los prototipos que representan dichos datos después de dicha propagación (E50), siendo atribuida la clase de los datos no etiquetados según la regla del máximo a posteriori.
- 25 2.- Procedimiento de aprendizaje según la reivindicación 1, **caracterizado** porque los arcos de dicho grafo generador son definidos (R40) por un sub-grafo de Delaunay.
- 30 3.- Procedimiento de aprendizaje según la reivindicación 1 ó 2, **caracterizado** porque en el curso de dicha etapa (E20) de construcción del modelo local, se utiliza un modelo de mezcla, cada uno de cuyos componentes está centrado sobre un prototipo y un criterio estadístico del tipo BIC (Bayesian Information Criterion) para determinar el número (N) de dichos prototipos (P_j).
- 35 4.- Procedimiento de aprendizaje según la reivindicación 3, **caracterizado** porque dicho modelo de mezcla es de tipo gaussiano.
- 5.- Procedimiento de aprendizaje según una cualquiera de las reivindicaciones 2 a 4, **caracterizado** porque los arcos de dicho grafo generador están definidos (E40) por un sub-grafo del grafo de grafo de Delaunay del tipo « Topology Representing Network ».
- 40 6.- Procedimiento de aprendizaje según una cualquiera de las reivindicaciones 1 a 5, **caracterizado** porque dicha modificación de probabilidades de la etiqueta de dicho segundo prototipo (P_{j_2}) siguiendo dicha propagación de la etiqueta de dicho primer prototipo (P_{j_1}) es también función de las probabilidades de la etiqueta (E_{j_2}) de dicho segundo prototipo.
- 45 7.- Programa de ordenador que comprende instrucciones para la ejecución de las etapas del procedimiento de aprendizaje según una cualquiera de las reivindicaciones 1 a 6 cuando dicho programa es ejecutado por un ordenador.
- 50 8.- Soporte de registro legible por un ordenador en el que está registrado un programa de ordenador que comprende instrucciones para la ejecución de las etapas del procedimiento de aprendizaje según una cualquiera de las reivindicaciones 1 a 6.
- 9.- Utilización de un procedimiento de aprendizaje según una cualquiera de las reivindicaciones 1 a 6 para el reconocimiento de caracteres.

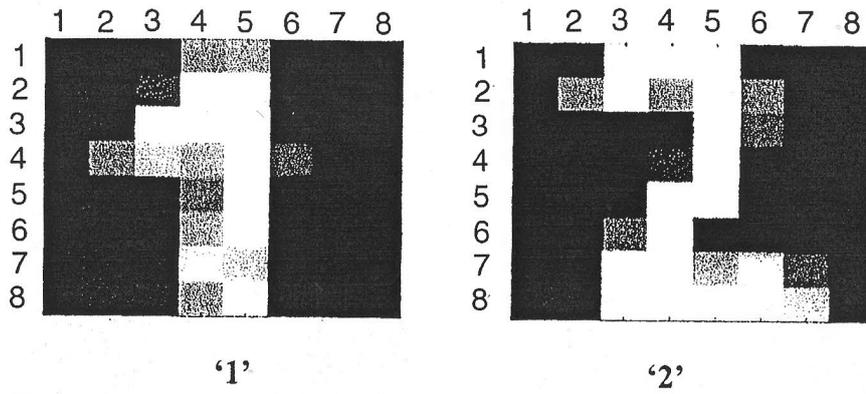


FIG. 1

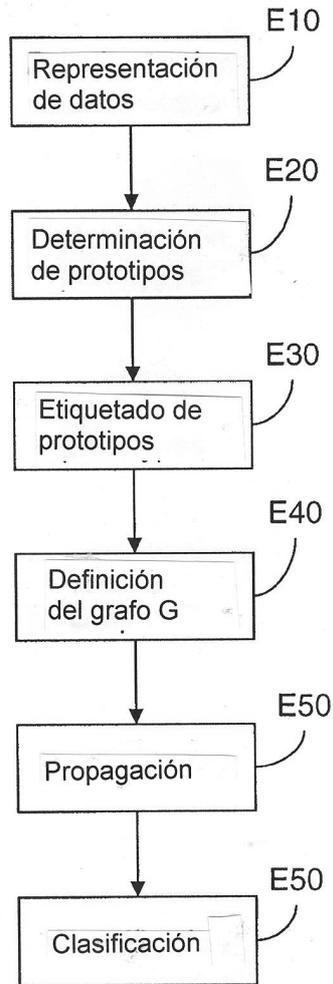


FIG. 2

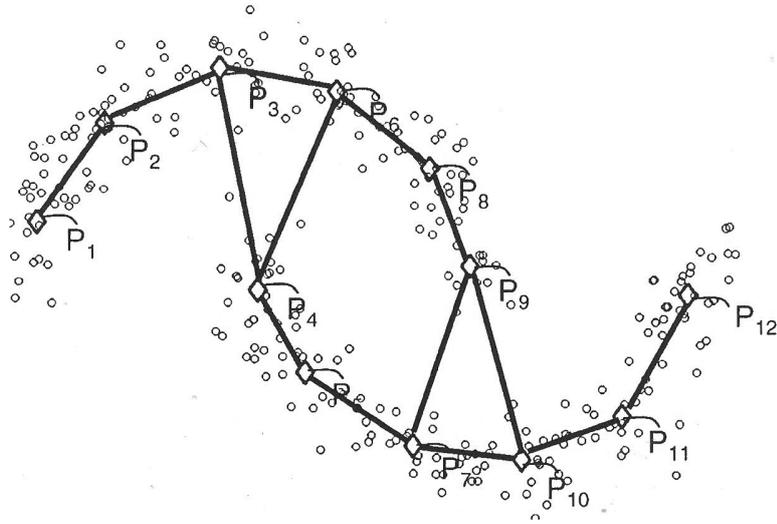


FIG. 3C

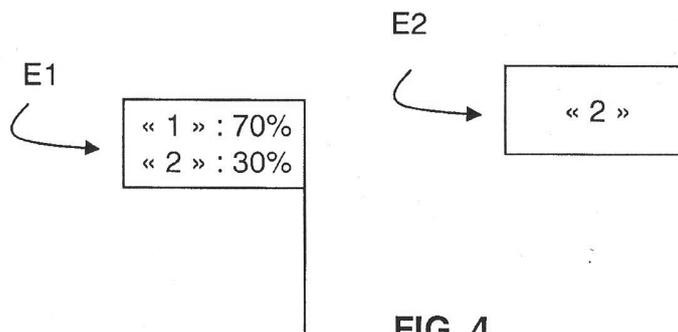


FIG. 4

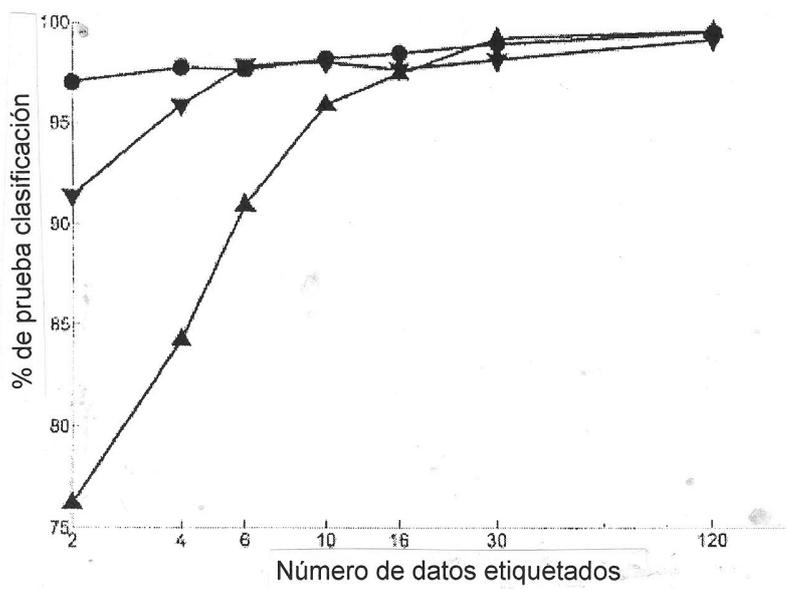


FIG. 5

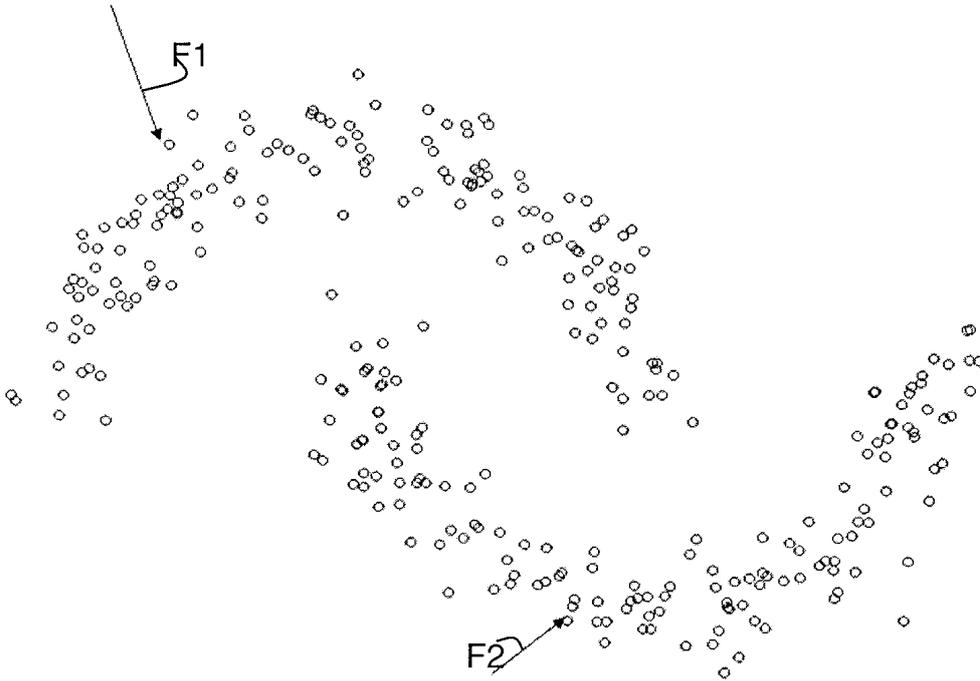


FIG. 3A

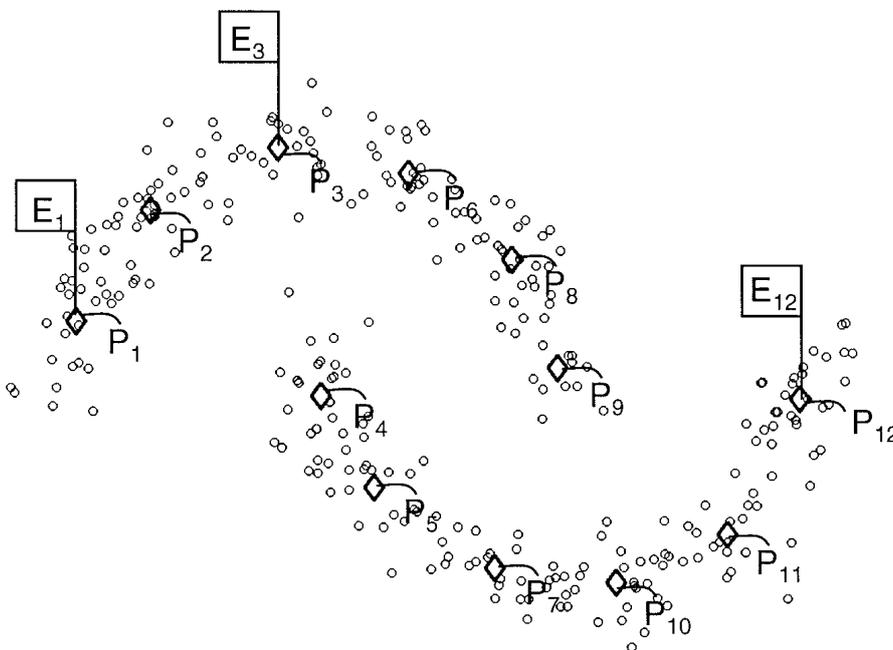


FIG. 3B