

UNIVERSIDAD DE LA REPÚBLICA
Facultad de Ingeniería

Introducción al Reconocimiento de Patrones

RECONOCIMIENTO EN SEÑALES EEG

**Pablo Iturralde
Martín Patrone**

Tutores: Alicia Fernández, Federico Lecumberry

Montevideo - Uruguay
Febrero 2012

Resumen

Se cuenta con una base de datos de señales provenientes de electroencefalogramas (EEG) de 14 sujetos durante 10 sesiones. En las distintas sesiones al sujeto se le muestran distintas imágenes (100) y se le indica que reconozca en cuales aparece cierto "disparado" (en este caso un animal) mediante la opresión de un botón. En la base de datos las señales se encuentran etiquetadas según si corresponde a una imagen con o sin disparador, además de indicarse el momento en que el sujeto presiona el botón.

El objetivo de este proyecto es distinguir a partir de las señales EEG si un sujeto se encuentra frente a un "disparador". Debido a la gran dimensionalidad del problema, el proyecto se centró en la extracción de características relevantes que permitan trabajar con un espacio reducido de las mismas. Además se entrenaron clasificadores a partir de éstas, trabajando con un usuario inicialmente y generalizando al resto luego.

De los resultados obtenidos se destacan dos métodos de extracción de características con los que, junto con un perceptrón, se logró un acierto promedio entre los distintos usuarios de 78.1 % y 73.5 %.

La base de datos se encuentra en [http://sccn.ucsd.edu/ arno/fam2data/data/](http://sccn.ucsd.edu/arno/fam2data/data/) y presenta en total 14000 instancias de reconocimiento de las imágenes descritas anteriormente. Las señales de EEG fueron registradas mediante el uso de 31 electrodos en total.

Introducción

Contexto

En un estudio encabezado por A. Delorme, se midió la actividad cerebral de varios usuarios mediante un EEG de 31 canales, mientras realizaban una tarea sencilla de reconocimiento visual. El objetivo inicial del estudio era identificar actividad cerebral diferencial entre las instancias donde se reconoce el objeto buscado y las que no. Los autores en [1] establecen que efectivamente existe actividad diferencial visible y que la misma empieza a notarse 150ms luego de presentado el estímulo.

El interés por este tipo de estudios surge naturalmente desde la medicina, y tiene particulares implicancias en el desarrollo de prótesis neurales o interfaces cerebro-computadora (BCIs), para las cuales es necesario hacer algún tipo de detección de la intención motora de un usuario. En esta línea el EEG ofrece una de las pocas alternativas no invasivas para dichos dispositivos. Aunque el potencial para esta tecnología es aún discutido, estudios recientes han podido reconstruir con suficiente precisión el movimiento de brazos en humanos [2].

Descripción el problema

Nuestro problema fue planteado a partir de los datos puestos a disposición por A. Delorme en ([http://sccn.ucsd.edu/ arno/fam2data/data/](http://sccn.ucsd.edu/arno/fam2data/data/)) del experimento anteriormente descrito. Dicho experimento se realizó con 14 usuarios de varias edades y ambos sexos, a los que se les presentaban en forma sucesiva y durante intervalos de 20ms, distintas imágenes en una computadora. Cuando la imagen contenía un animal, el usuario debía soltar un botón que de otra manera debía mantener apretado. Las imágenes se presentaban en sucesiones de

100 consecutivamente (apenas se identificaba un animal, o transcurría un segundo sin que se hubiera apretado el botón, se pasaba a la siguiente imagen), y cada usuario completó al menos 10 de estas sesiones, distribuidas en 2 días. Durante toda la duración del experimento, se registraron las señales EEG del usuario en 31 canales, muestreando a una tasa de 1kHz, durante 1 segundo luego de presentada cada imagen, incluyendo al menos 1000 imágenes por usuario.

El problema elegido consiste en tomar las señales registradas durante la presentación de cada una de las imágenes, y a partir de las mismas identificar si el usuario soltó o no el interruptor (notese que en principio esto no es equivalente a la presencia de un animal en la imagen, ya que en ocasiones los usuarios fallan en el reconocimiento o tienen falsos positivos, aunque hay un 94 % de coincidencia). En una segunda etapa nos proponíamos intentar una predicción del tiempo en que se suelta el botón, pero no llegamos a intentarla.

Desde el comienzo estuvo claro que la mayor dificultad de la tarea radicaría en lidiar con el espacio de altísima dimensión (31000) de las características. En particular, identificar cuáles de todas (o qué combinación de las mismas) contenían la información buscada.

Alcance del trabajo

El trabajo se centró en la extracción de características relevantes (reducción de la dimensionalidad) para el problema, y el entrenamiento de clasificadores sencillos a partir de las mismas. Pusimos especial énfasis en el estudio de la variabilidad entre usuarios de las características y, en menor medida, en la variabilidad entre experimentos con el mismo usuario.

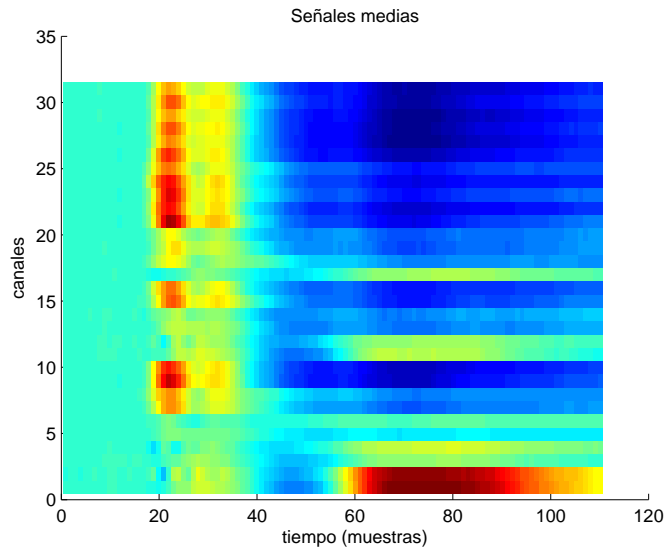


Figura 2: Señales medias de los distintos canales para un usuario.

En las imágenes puede notarse la redundancia mencionada anteriormente, así como identificarse los períodos de actividad de los distintos canales. Por ejemplo, los canales 1, 2, 3, 4, 11, 12 y 17 corresponden al lóbulo frontal, donde se realiza la toma de decisiones y el control motor [4], y son los de actividad más tardía, consecuente con lo esperado.

Como regla general, se realizó un pre-procesamiento de los datos que se encarga de forzar que todas las señales de todos los canales comiencen en el origen. Esto se debe a que el nivel de continua de las señales fluctúa muy lentamente pero con grandes amplitudes a lo largo de todos los experimentos.

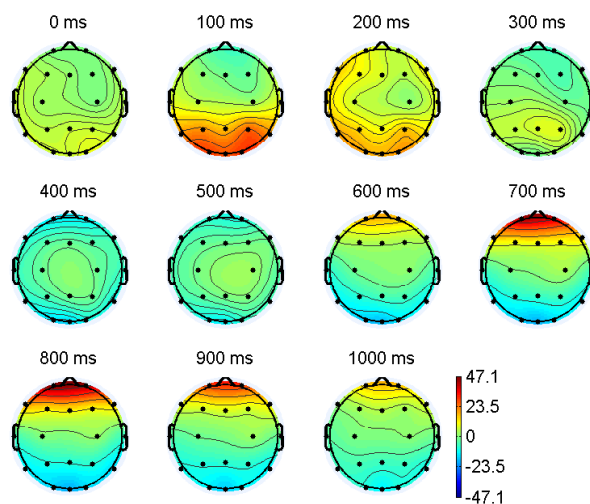


Figura 3: Activación de los distintos canales a lo largo de una instancia.

Enfoque

El proyecto consistió de 3 etapas distintas. En la primera de ellas, intentamos hacer una reducción de dimensionalidad y extracción de características con herramientas automáticas (de Weka), para luego entrenar clasificadores con dichas características. En la segunda etapa, procedimos a realizar una extracción manual de características relevantes, para utilizarlas en clasificadores entrenados en Weka. En la tercera y última etapa, procuramos generalizar los resultados de la etapa anterior al resto de los usuarios, con distintos niveles de éxito.

Técnicas y resultados

A continuación se presentan las técnicas utilizadas en las distintas etapas descritas, así como los resultados obtenidos al utilizar cada una de ella. Dado que las clases se encuentran balanceadas, se utilizará el porcentaje de instancias clasificadas correctamente como indicador de éxito.

Etapas 1: herramientas automáticas para reducción de dimensionalidad

En esta primera etapa se trabajó con dos alternativas. Por un lado se trabajó con todos los datos de un usuario en Weka corriendo distintos algoritmos de clasificación y selección de características. Entre otros, utilizamos los algoritmos para selección de atributos *Cfs Subset*, *Principal Component Analysis* e *Info Gain*. Como clasificadores utilizamos árboles *C4.5* y redes tipo *Multilayer Perceptron*. En todos los casos se realizó validación cruzada de 10 particiones. Con este enfoque no solo no logramos resultados razonables (porcentajes de éxito menores o cercanos al 60 %) sino que además los tiempos computacionales involucrados eran muy altos. Debe notarse que todos estos algoritmos se probaron también decimando los datos en un factor 10, para que quedaran muestreados a la más razonable tasa de 100Hz.

Por otro lado se utilizó el toolbox de Matlab *drtoolbox* [6] el cual cuenta con herramientas para realizar una reducción del espacio de características. Luego con Weka se utilizaron distintos clasificadores sobre el nuevo conjunto de características (de dimensión reducida). En primera instancia el toolbox permite una estimación de la dimensionalidad intrínseca de los datos mediante varios algoritmos. El único algoritmo del *toolbox* que reportaba la dimensionalidad estimada con cierta consistencia era el *MLE*, y dicha dimensionalidad oscilaba entre 29 y 35, dependiendo del usuario. Luego de estimada la dimensionalidad, el *toolbox* permitía hacer una reducción de características mediante algún algoritmo de mapeo. Hecho este mapeo, cargamos los datos en Weka para entrenar un clasificador. Obtuvimos los mejores resultados mediante *Diffusion Maps* con una adecuada elección del paso del tiempo (hay que destacar que los resultados alentadores de *Diffusion Maps* ocurrieron después de una decimación de los datos originales a 100Hz). Sin embargo el éxito en la clasificación variaba bastante entre usuarios, yendo de un 59 % hasta un 89 %. Si bien los datos de los distintos usuarios parecen tener distintos niveles de confiabilidad (e información!), confirmamos en las etapas posteriores que era posible conseguir mejores resultados (y particularmente, más consistentes entre los distintos usuarios).

El fracaso en esta etapa puede ser atribuido a la gran dimensionalidad del conjunto de características, que complican la convergencia de cualquier algoritmo que realice búsquedas en dicho espacio. A partir de esto surgió la motivación de realizar una reducción manual del espacio de características, realizada en la etapa 2 del proyecto.

Etapa 2: reducción manual de la dimensionalidad

Como segundo paso buscamos reducir el espacio de características de forma manual, buscando canales, frecuencias e instantes de tiempo más relevantes. Aquí se probaron distintos acercamientos que se enumeran y explican a continuación. En general trabajamos con un único usuario en esta etapa, probando con otros usuarios sólo cuando se obtenían resultados auspiciosos. Dichos resultados se comentan en el resumen de la tercera etapa.

- energía por canal
- energía en cada instante de tiempo
- elección de canales y ventanas según zona de actividad
- proyección sobre señal media
- proyección sobre media en frecuencia
- elección manual de frecuencias y canales

Energía por canal

Para poder reducir la dimensionalidad, inicialmente se buscaron los canales más relevantes para la clasificación. Para esto se tomaron como características la energía de cada uno de los canales. Por lo tanto se contaba en este caso con 32 características por instancia.

Al utilizar selectores de atributos con weka (*Cfs Subset* e *Info Gain*), se encontró que las características seleccionadas corresponden principalmente al lóbulo frontal (canales 1, 2, 3, 4, 11, 12, 17) donde se encuentra la corteza motora. Sin embargo los resultados al utilizar clasificadores con estas características fueron bajos, obteniendo como mejores resultados lo siguiente:

- 68,5% árbol (C4.5) podado con selección de características previa.
- 72,5% perceptrón con 2 capas ocultas de 3 neuronas y todas las características.

Ambos resultados fueron evaluados utilizando validación cruzada de 10 particiones.

Energía en cada instante de tiempo

Como segunda alternativa, se buscaron los instantes de tiempo más relevantes. Para poder trabajar con un número de atributos más reducido, se realizó la suma de los cuadrados en todos los canales para cada instante de tiempo. Como se utilizaron los datos submuestreados a 100Hz, se contaba en este caso con 110 atributos por instancia.

Los selectores de atributos utilizados indicaron que los instantes con mayor información se encuentran entre 300ms y 400ms y entre 600ms y 700ms. Aún así, nuevamente el éxito obtenido por los clasificadores fue bajo, obteniendo 71,9 % con un perceptrón y 66,3 % con un árbol de decisión.

Elección de canales y ventanas según zona de actividad

Al graficar las señales medias para todos los canales, se puede observar que se activan distintas zonas del cerebro en distintos momentos. Aproximadamente 100ms luego de que se presenta la imagen al usuario se activan los canales correspondientes al lóbulo occipital. Este lóbulo es el encargado de realizar el procesamiento visual, lo que indicaría que se está realizando un análisis de la imagen presentada. Luego, aproximadamente a los 550ms, aparece actividad en los canales ubicados en la zona frontal, donde, como se dijo anteriormente, se encuentra el área motora primaria. Esto parece indicar el movimiento de la mano al apretar el botón. Sin embargo, a pesar de que la actividad es más notoria en la media de las instancias en que se suelta el botón, igual se observa en la media del las instancias en las que no se apreta.

La señales medias para los distintos canales de las señales tipo 0 (sin soltar el botón) y tipo 1 (señales en las que se suelta el botón) se pueden observar en la figura 4.




Figura 4: Señales medias de las instancias separadas por clase.

Es razonable creer que la información para distinguir si se apreta o no el botón se encuentra por lo tanto en los canales correspondientes al lóbulo frontal donde se genera la

orden motora y no en los canales donde parecería encontrarse el procesamiento visual de la imagen, el cual debe ocurrir en ambas instancias. Por este motivo se realizó una reducción manual de las características considerando sólo los canales F (frontales) con mayor actividad. Con estos atributos se obtuvo un 76,5% de éxito con un perceptrón como clasificador arriba de una preselección mediante PCA. Se utilizó PCA principalmente para disminuir la dimensión de entrada al perceptrón y de esta forma reducir los tiempos computacionales involucrados dado que los resultados (con y sin PCA) no variaban significativamente para un perceptrón. Adicionalmente, las señales se utilizaron submuestreadas a 50Hz.

Proyección sobre señal media

Se separaron los datos en conjuntos de train y de test (50-50). A partir del conjunto de train se calculó la señal media de cada canal, promediando en todas las instancias. Luego se proyectaron todas las señales contra estas medias, obteniendo así 32 características por instancia. Finalmente se cargan los dos grupos (train y test) al weka, donde se corrieron distintos clasificadores y selectores de atributo.

Mediante este método se obtuvieron uno de los mejores resultados en cuanto a performance del clasificador para este usuario, obteniendo 86.6 % con un perceptrón de dos capas, con 4 y 3 neuronas cada una.

Una observación importante que pudimos hacer aquí fue que de no realizar una mezcla aleatoria de las instancias previo a separar los grupos de train y test, los resultados caen notoriamente. Esto indica la variabilidad temporal que existe en las señales de un mismo usuario, donde se pueden apreciar grandes cambios entre señales adquiridas en distintos experimentos, y las diferencias son más notorias cuanto más separadas estén en el tiempo.

Proyección sobre media en frecuencia

Partiendo del análisis anterior se realizó la proyección sobre el módulo de la transformada de Fourier de las señales media de cada clase. De esta forma se buscaba reducir el efecto de los desfases temporales entre las instancias (tiempos de respuesta), dándole mayor importancia a la forma de onda de las señales. Los resultados obtenidos con este método fueron considerablemente inferiores a los obtenidos con la proyección temporal. Esto parece indicar que el momento en que se activan los canales es importante al momento de la clasificación buscada.

Cabe la aclaración de que, para un mismo usuario, todas las instancias presentan aproximadamente la misma energía, lo cual es necesario para que el análisis anterior sea válido.

Por otro lado, observando la respuesta en frecuencia de las señales se pudo observar que toda la información aparece en las bajas frecuencias, lo que permitió realizar un submuestreo para reducir la cantidad de atributos (previo filtro pasabajos). Esto se corresponde con el hecho de que los selectores de atributo automáticos tienden a elegir las bandas de frecuencia inferiores al tomar las muestras de la transformada de Fourier como atributos.

Elección manual de frecuencias y canales

La última estrategia utilizada fue realizar una inspección visual en busca de los atributos más determinantes. El objetivo principal de esto fue tener un resultado contra el cual contrastar el resto, en especial en esta etapa de análisis de un único usuario. Para esto se utilizaron los espectros de los primeros 14 canales, se observaron las gráficas enfrentado uno a uno los atributos y se escogieron aquellos para los cuales las instancias de distinto tipo se encontraban más disjuntas (a ojo!). Los atributos escogidos fueron la mayoría en baja frecuencia (por debajo de 5Hz), donde todos los canales considerados, excepto el 13 y 14, tenían alguna contribución. El resultado obtenido fue de 79.5 % de éxito.

Etapa 3: generalización a varios usuarios

Una vez probadas varias estrategias sobre un usuario en particular, buscamos generalizar los resultados obtenidos aplicándolas al resto de los usuarios.

La primer estrategia que se buscó generalizar fue la de tomar como atributos la energía de cada canal, especialmente por su sencillez. Sin embargo no tuvimos éxito, obteniendo porcentajes de éxito del orden del 60 en la mayoría de los usuarios.

Por otro lado, utilizando los mismos atributos elegidos manualmente para el usuario cba con el resto de los usuarios, los resultados también cayeron incluso por debajo del 60 %. Esto es determinante y permite afirmar que los usuarios presentan información relevante en distintas características con las implicancias que ello conlleva.

Mejores resultados, aunque algo variados, se obtuvieron con otros métodos. En la siguiente tabla se pueden ver los resultados para los distintos usuarios al utilizar la proyección sobre la señal media temporal (Método 1) y al utilizar los canales F más activos submuestreados (Método 2). Estos métodos fueron elegidos por ser los que mejores tasas de éxito tenían en el promedio de los usuarios.

Usuario	% éxito Método 1	% éxito Método 2
cba	86.6	76.3
clm	78.8	74.5
ega	76.2	71.5
fsa	75.6	67.0
gro	72.4	72.2
hth	74.6	72.3
lmi	90.2	88.7
mba	74.2	71.9
mma	77.2	78.8
mta	83.6	78.8
pla	69.2	56.3
sce	85.8	71.7
sph	80.4	80.0
wpa	69.0	68.7
promedio	78.1	73.5

Como se puede observar, los resultados son consistentes en gran medida entre los dos métodos para cada usuario, a pesar de que entre usuarios llegan a variar entre 56 % y 90 %. En particular el método 1 es el más consistente entre todos los usuarios, con una varianza total menor al 5 %.

Discusión y conclusiones

Como primer conclusión se destaca la ya prevista necesidad de reducir manualmente la dimensión del espacio de características con el que se cuenta originalmente. La dimensionalidad inicial excede largamente la capacidad de casi todos los algoritmos automáticos de reducción, que dan resultados malos o poco consistentes entre usuarios, aunque funcionan para algunos de ellos.

La reducción de dimensiones puede comenzarse naturalmente por un decimado de las señales, cuyo ancho de banda no excede los 10Hz, pero que se encuentra inicialmente muestreada a 1kHz. Aún con una decimación por un factor 20, el espacio de características tiene una dimensión 1550. Visualizando las señales, concluimos que los canales de EEG asociados al lóbulo frontal (control motor) contenían la mayor cantidad de información de entre todos los canales, resultado que coincide con lo esperado. Quedándonos con 5 de estos canales logramos una reducción a una dimensionalidad 200, que probó ser adecuada para entrenar clasificadores con tasas de éxito en el orden del 74 %. Un acercamiento basado en la comparación de las formas de onda (que reduce las características a 31, una por canal) logró una tasa global de éxito del 78 %. Este método probó ser el mejor de todos los intentados.

En general los resultados anteriores son los de mayor interés porque, si bien requirieron de una selección manual de atributos en primera instancia, son generalizables para todos los usuarios, lo que permite automatizar todo el proceso de extracción de características y clasificación en nuevos usuarios. A pesar de esto, los mecanismos semi-automáticos anteriores pueden ser mejorados aún más con una elección de atributos manual. Por ejemplo, para uno de los usuarios, mediante la selección manual de algunos canales y bandas de frecuencia que parecían contener la mayor cantidad de información, fue posible elevar la tasa de éxito (en clasificadores basados en su transformada de Fourier) del 70 % hasta casi el 80 %. Sin embargo, los mismos atributos no lograban mejores clasificadores (de hecho, empeoraban) en el resto de los usuarios. Este mecanismo tiene entonces el problema de requerir mucho tiempo para la selección manual atributo por atributo, selección que debe ser realizada para cada usuario por separado, lo que lo hace inaplicable en el caso general.

A modo de conclusiones generales es posible establecer que existe suficiente información en las señales de EEG para realizar una adecuada predicción. Sin embargo, los niveles de éxito son bastante dispares entre usuarios. Más aún, la información parece presentarse en distintas características para los distintos usuarios y, aunque hay características comunes a todos que contienen información (por ejemplo, los canales F), dicha información se presenta en forma dispar, haciendo que un clasificador entrenado para un usuario sea completamente inútil en otro. Esto confirma una tendencia aceptada en estudios similares.

Trabajo a futuro

Como trabajo futuro debe incluirse, sin duda alguna, la combinación de clasificadores. Actualmente contamos con dos buenos clasificadores obtenidos en forma independiente. Es de suponer que una combinación adecuada de ambos, e incluso de algún otro clasificador de los estudiados, mejoraría la tasa de reconocimiento.

Pensando en nuevas líneas de trabajo, parecería interesante incluir un mayor estudio de las variaciones entre distintas pruebas de un mismo usuario, sobre todo para aquellas realizadas en días distintos. Los resultados obtenidos hasta el momento indican que las variaciones entre estos experimentos serían significativas (varianza temporal a largo plazo), y esto podría ser un inconveniente si se desean clasificar nuevas instancias de los usuarios ya entrenados.

Otra nueva línea de trabajo es la de la predicción del tiempo en que se suelta el botón, que creemos puede ser muy ilustrativo respecto de dónde se encuentra la información en los distintos usuarios dentro de la ventana temporal observada.

Finalmente, debería explorarse la remoción de artefactos de origen muscular en el EEG (pestaño, etc.). Aunque no nos consta que existan artefactos de este tipo, o que estén interfiriendo con el sistema de clasificación, esta etapa de pre-procesamiento es habitual en estudios similares, aunque no encontramos en las referencias exploradas una descripción de cómo identificar y remover dichos artefactos.

Bibliografía

- [1] A. Delorme and L. Jolla, *From Single-trial EEG to Brain Area Dynamics 2002*, pp. 44-46.
- [2] T.J. Bradberry, R.J. Gentili, J.L. Contreras-Vidal, *Reconstructing Three-Dimensional Hand Movements from Noninvasive Electroencephalographic Signals*, *The Journal of Neuroscience*, March 3 2010, pp. 3432-3437.
- [3] J. Malmivuo, R. Plonsey, *Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields, cap. 13*, Oxford University Press, 1995. Obtenido de www.bem.fi/book/00/ti.htm
- [4] M.A. Rebollo, C. Carriquiry, M. Christophersen, A.L. Rodríguez , *Alteraciones del Desarrollo Neurológico*, Prensa Médica Latinoamericana, 2010.
- [5] Weka people, *Weka*, pp. 44-46.
- [6] L.V.D. Maaten and G. Hinton, *Visualizing Data using t-SNE*, *Journal of Machine Learning Research*, vol. 9, 2008, pp. 2579-2605. http://homepage.tudelft.nl/19j49/Matlab_Toolbox_for_Dimensionality_Reduction.html