
Resultados experimentales

En este capítulo se exponen con detalle los experimentos de reconocimiento de formas que se han realizado a lo largo de este trabajo para comprobar la viabilidad y buen funcionamiento del algoritmo ECGI, así como de sus extensiones.

En primer lugar se describen los conjuntos de datos a partir de los cuales se organizaron los experimentos. Seguidamente, se detallan éstos y se tabulan sus resultados.

En este capítulo no se incluyen los resultados de los experimentos de obtención de cadena media, de simplificación de autómatas, de obtención de autómatas deterministas y de comparación entre los distintos criterios, todos los cuales se hallan a continuación, en los capítulos correspondientes (capítulos 9, 10 y 11). Tampoco se pretende exponer *todos* los experimentos realizados, pues se han realizado muchos que luego han quedado obsoletos por mejoras (a veces mínimas) en la parametrización, se han visto incluidos en otros por ampliación del conjunto de datos, etc.; sin contar la gran cantidad de pequeñas pruebas que requiere la puesta a punto de un método heurístico como lo es ECGI.

Se han empleado cinco grupos distintos de datos, cada uno de ellos correspondiente a un grupo distinto de experimentos.

De los cuatro grupo de experimentos, dos involucraron dígitos hablados, uno letras habladas y otros dos utilizaron imágenes. De estos últimos el primer grupo correspondía a dígitos manuscritos y el otro a dígitos impresos. El primer grupo de datos de dígitos hablados, basado en una parametrización y etiquetados elementales, se utilizó como experimento piloto cada vez que se desarrollaba un nuevo prototipo de ECGI, pues representaba un auténtico desafío por lo poco elaborado de los símbolos utilizados. Sin embargo, el corpus de datos de letras habladas es, con margen, el más difícil (sobre todo el subconjunto de EE-letras), dada la extrema similitud de las formas a reconocer.

Casi todos los experimentos se realizaron en un ordenador Hewlett-Packard HP9300, con sistema operativo UNIX (HP-UX)¹.

8.1 Reconocimiento del Habla

Se describen a continuación los experimentos realizados en el campo para el cual fue diseñado ECGI en un principio: el reconocimiento del habla. Se presentan primero los corpus de datos (el piloto, el principal y las letras), seguidos de la descripción de los distintos experimentos y de los resultados obtenidos en cada caso.

8.1.1 Representación simbólica de la señal vocal

Los corpora de los dígitos hablados están formados por la pronunciación repetida frente a un micrófono, por parte de uno o varios locutores (según el corpus), de los diez dígitos *castellanos* (tabla 8.1).

Tabla 8.1 Los diez dígitos castellanos.

| Palabra de sílabas | Transcripción fonética | Nº |
|--------------------|------------------------|----|
| ceró | /θéro/ | 2 |
| uno | /úno/ | 2 |
| dos | /dós/ | 1 |
| tres | /trés/ | 1 |
| cuatro | /kwátro/ | 2 |
| cinco | /θínko/ | 2 |
| seis | /seís/ ^ | 1 |
| siete | /sjete/ | 2 |
| ocho | /óco/ | 2 |
| nueve | /nwéβe/ | 2 |

El corpus de las letras habladas está formado por las treinta letras del alfabeto castellano (tabla 8.2).

¹Los experimentos iniciales se llevaron a cabo en un Eclipse C-350 de Data-General, aunque luego se repitieron en el HP9300. Por aquel entonces, el ECGI, integrando inferencia y reconocimiento, y junto con los autómatas inferidos, cabía en 64Kbytes de memoria (¡que tiempos aquellos!). Los últimos experimentos se realizaron con la última versión de ECGI, escrita en C y que funciona en un RISC 6000 de IBM (S.O. AIX).

Tabla 8.2 Las letras del alfabeto castellano habladas y su transcripción fonética.

| | | | | | |
|----|-------|----|--------|----|------------|
| A | /a/ | J | /xóta/ | R | /ére/ |
| B | /be/ | K | /ka/ | RR | /érē/ |
| C | /θe/ | L | /éle/ | S | /ése/ |
| CH | /ce/ | LL | /éle/ | T | /te/ |
| D | /de/ | M | /éme/ | U | /u/ |
| E | /e/ | N | /éne/ | V | /úβε/ |
| F | /éfe/ | Ñ | /éñe/ | W | /úβedóble/ |
| G | /xé/ | O | /o/ | X | /ékis/ |
| H | /áce/ | P | /pe/ | Y | /ígríéγa/ |
| I | /i/ | Q | /ku/ | Z | /θéta/ |

Llamaremos "EE-letras" al conjunto de 9 letras {F, L, LL, M, N, Ñ, R, RR, S} cuya pronunciación se diferencia estrictamente por la consonante *intermedia* (no confundir con las E-letras {B,C,D,E,G,P,T y –en inglés– V y Z}, que se diferencian por la consonante *inicial*).

Las palabras fueron adquiridas en una habitación no especialmente aislada, mediante un micrófono de proximidad (relación señal/ruido \approx 40 dB). Se trata de experimentos de reconocimiento de *palabras aisladas*, por lo que existía una gran pausa entre palabra y palabra, con el fin de trivializar su extracción y segmentación del fondo. El proceso de conversión de estas palabras en cadenas de símbolos es distinto para cada uno de los corpora presentados, aunque sigue el esquema adquisición, parametrización y etiquetado presentado en el capítulo 1.

8.1.1.1 Corpus piloto: Dígitos monolocator

El grupo de datos que conforman el corpus piloto fué adquirido y cuantificado linealmente mediante un conversor A/D de 12 bits a una frecuencia de muestreo de 8533 Hz.

Cada palabra adquirida se sometió posteriormente a un submuestreo en el que se aplicó una ventana rectangular de longitud 256 muestras (20 mseg.) con una frecuencia de 66.6 Hz.. De cada ventana se extrajeron tres parámetros muy elementales: la amplitud media, la densidad de cruces por cero y la densidad de cruces por cero de la primera derivada de la señal (preénfasis) (ver [Casacuberta,87] para una descripción mas completa de estos parámetros), que permiten detectar con cierta seguridad segmentos fricativos y realizar una clasificación "tosca" de las vocales (figura 8.1).




Figura 8.1 Adquisición y parametrización para los experimentos piloto: amplitud media, densidad de cruces por cero y densidad de cruces por cero de la derivada.

El conjunto de símbolos (aproximadamente) fonéticos era el mostrado en la tabla 8.3.

Tabla 8.3 Símbolos para las cadenas del experimento básico.

| | |
|----------|------------------|
| I | Vocal anterior |
| U | Vocal posterior |
| N | Sonora débil |
| S | Fricativa fuerte |
| Z | Fricativa débil |
| T | Oclusiva. |

Cada ventana, descrita por estos tres parámetros se sometió a un procedimiento de etiquetado *difuso* (descrito en [Vidal,85]), para luego asignarle el símbolo de la etiqueta difusa más evidente, o el símbolo "?" si ninguna era lo suficientemente evidente.

Un único locutor pronunció (en varias sesiones) 58 repeticiones de cada uno de los dígitos. El corpus se compone por lo tanto de un total de 580 cadenas, habiendo resultado la longitud media de las mismas ser 43 caracteres (figura 8.2).

| | |
|----------|--|
| /CERO/ | ZZZZZZIIIIIIIZIIUUUIN??ZZTZZ |
| /UNO/ | ZUUUUUUUN?NNUUUIIINNN?ZZZZ |
| /DOS/ | ZIIUUUUUUUISSSSSSSSSSSZ |
| /TRES/ | NIINIIIIIIIIUINSSSSSSSSSSSZ |
| /CUATRO/ | ZZZUUUUUUUU?TTZNIIZ?NUUUNN??Z |
| /CINCO/ | ZZZZZZZ?II?NNNNNNN?TTT?ZIUUUUINNN?ZZZZ |
| /SEIS/ | ?SSSSSSS?IIIIIIIIIN?SSSSSSSSSS |
| /SIETE/ | ZSSSSSSSZIIIIIIITTTTTZIIIIINNN?Z?? |
| /OCHO/ | ZZZ?IIUUUITTTTSSSSIIIIINNN?ZZZZ |
| /NUEVE/ | ZZNNIIUUUUUUUUUUIIINNN?SZZZZ |

Figura 8.2 Ejemplo de las cadenas utilizadas en el experimento básico de dígitos hablados (una por clase).

8.1.1.2 Corpus principal: Dígitos

El grupo de datos que conforman el corpus principal fue adquirido y cuantificado linealmente mediante un conversor A/D de 12 bits a una frecuencia de muestreo de 8533 Hz.

Cada palabra adquirida se sometió posteriormente a un submuestreo en el que se aplicó una ventana de Hamming [Casacuberta,87] de 30 msg. (128 muestras) con una frecuencia de 66.6 Hz. (128 muestras). De cada ventana se extrajeron 11 parámetros, 10 de ellos correspondían a 10 *coeficientes cepstrales* y el undécimo a la energía media en la ventana (convenientemente normalizada). En [Benedí,89] se dan los detalles del procedimiento para calcular los coeficientes cepstrales, que se resume en (figura 8.3):

- Obtención de la *transformada (rápida) de Fourier*, que proporciona 128 puntos complejos correspondientes a las frecuencias de 0 a 4267 Hz.
- Obtención del módulo de la transformada, elevando al cuadrado dichos valores complejos.
- Submuestreo frecuencial, mediante aplicación de 18 ventanas trapezoidales distribuidas según la *escala de Mel*².
- Codificación de cada uno de los 18 valores de este *banco de filtros*, a 8 bits con escala logarítmica.
- Análisis *cepstral* de estos 18 valores, es decir aplicación a ellos de una transformada inversa de Fourier. La información contenida en cada uno de los 18 coeficientes así obtenidos decrece con su índice, reteniéndose los más significativos para el problema concreto: en nuestro caso los 10 coeficientes cepstrales.




Figura 8.3 Esquema del proceso de adquisición y parametrización: obtención de los 10 Coeficientes Cespstrales y la Energía media.

²La escala de Mel es una escala, basada en el estudio de la membrana basilar del oído humano, aproximadamente lineal en las bajas frecuencias y logarítmica a medias y altas.

Cada ventana, descrita por estos once parámetros, se sometió a un etiquetado, clasificándola según la regla k-NN (k=7 vecinos) en la clase fonética más próxima de entre 15 clases. Para la definición de estas 15 clases "fonéticas" se recurrió a un algoritmo de agrupamiento no supervisado (*clustering* o *cuantificación vectorial*) del tipo C-Medias [Duda,73]. Así se obtuvieron 255 grupos a partir de un conjunto de vectores de parámetros (coeficientes ceptrales obtenidos como arriba descrito). Los prototipos (centroides) de estos 255 grupos se volvieron a agrupar, mediante el mismo algoritmo, en las 15 clases fonéticas mencionadas; convirtiéndose cada par (prototipo,clase) en uno de los representantes de la clase. Finalmente, mediante un procedimiento puramente manual y heurístico, se eligieron 15 símbolos para etiquetar cada una de las clases de acuerdo con sus características "perceptivas" acústico-fonéticas.

El conjunto de vectores para el agrupamiento estaba constituido por 4171 vectores extraídos de 150 palabras, las cuales corresponden a las primeras 5 repeticiones de cada dígito, pronunciadas por 3 de los locutores, 1 femenino y 2 masculinos (locutores 1,7,8). Estos locutores se escogieron porque no aparecían en las muestras de test y sí en las de aprendizaje en la mayoría de los experimentos.

Once locutores pronunciaron, en varias sesiones, 10 repeticiones de cada uno de los dígitos castellanos. El corpus se compone pues de un total de 1100 palabras, que se distribuyeron de distintas maneras para realizar los experimentos. La longitud media de las cadenas es de 28,3 caracteres (figura 8.4).

| | |
|----------|----------------------------------|
| /CERO/ | TZZZZZvEEEEEEEEErZEEwoooUUT |
| /UNO/ | UUUUUUUooNNNNvwoooUUUUT |
| /DOS/ | ZvOOOOOOOvsvSSSSSSSSSSSST |
| /TRES/ | ZrEErrEEEeveeeenrSSSSS |
| /CUATRO/ | UUoUUOOOOOvNTTTZZSZSZvooUUuTTT |
| /CINCO/ | TZZrllllllNNNNNNnTTTKToooooUUTTT |
| /SEIS/ | SSSSSSZrvEEEEEEEellInnrSSSSS |
| /SIETE/ | SSSSSSrlllllllEEnTTTTZZeeennTTT |
| /OCHO/ | ToOOOOOwTTTTZZSSSSewUUUUTTT |
| /NUEVE/ | TnNNvEOOVEEEEEvNNeeennnnnTT |

Figura 8.4 Ejemplos de las cadenas del corpus principal de los dígitos hablados (una por clase).

Todos los experimentos son *multilocutor* o *independientes del locutor*, estando garantizada la variedad por la presencia de 5 voces femeninas y 6 masculinas.

8.1.1.3 Corpus difícil: letras

La parametrización para el corpus de letras siguió un procedimiento similar al de los dígitos (corpus principal), si se exceptúa la utilización de una frecuencia de muestreo mayor (133.3 Hz.), para disponer de una mayor finura de análisis de fonemas individuales (con una frecuencia de submuestreo de 66.6 Hz. es muy posible que una transición quede representada por un único símbolo), y un clustering que proporciona 32 símbolos en lugar de 15; estando todos estos cambios justificados por la mucho mayor dificultad de la tarea de reconocimiento planteada.

| | |
|------|---|
| /F/ | uUoojjjjjjjjjjjeeMVUUUUUUUUUUUUUUUUUveeeooooeIIAAAAAA |
| /L/ | UojjjjjjjjjjjjjMRRReTTVTVMooooooooIIAAAAAuu |
| /LL/ | UoJJjoeooooooMMVVVVVMeMMMooooooooIIAAAA |
| /M/ | uUoJJjjjjjjjjjjjeeVvvvvvEeJoooooIIIIIAAAAA |
| /N/ | UoJJjjjjjoejjjoooeIISSSIIooooooooIIIIIAAAA |
| /Ñ/ | uUoJJjjjjjjjjjoooeIIIIIIIIIZZFFIIIGGGGGoIIIIIAAAAA |
| /R/ | KoJJjjjjjoejjjjjoeVUUooooooooIIIAAAuuuuuuu |
| /RR/ | UJJjjjjjjjjjjjjjNNEXENNEENSSSSSEEEeeeeeIIIAAAAAuuuur |
| /S/ | ulooJJjjjjjjjjjeeMGHHHHHHHHHHHHHHHPIIeeeeeIIIIIAA |

Figura 8.5 Ejemplos de cadenas utilizadas en los experimentos de reconocimiento de letras habladas (una por clase del subconjunto de EE-Letras).

10 locutores (5 femeninos y 5 masculinos) pronunciaron 10 veces cada una de las letras, consiguiéndose de esta manera un corpus de 3000 palabras., representadas por cadenas de 56,8 símbolos de longitud media (figura 8.5).

8.1.2 Experimentos de reconocimiento

Para cada corpus se realizaron una serie de experimentos, ya partiéndolo de distintas maneras en conjuntos de aprendizaje y test, ya utilizando distintas variantes de ECGI (no estocástico, estocástico, sólo autorizando sustituciones: capítulo 7). Las variantes «Ignorando las frecuencias de los errores» e «ignorando las frecuencias de las reglas» se describen con detalle en el capítulo 9.

8.1.2.1 Corpus piloto

En todos los experimentos realizados con el corpus piloto se utilizaron las 38 primeras muestras de cada dígito como conjunto de aprendizaje, y las 20 siguientes como muestras de test. Los autómatas se infirieron con el criterio minEL (ver apartado 6.6). Las tasas de reconocimiento de los experimentos efectuados, variando el tipo de algoritmo de reconocimiento fueron las mostradas en la tabla 8.4 (cada experimento implica el reconocimiento de 200 muestras).

Tabla 8.4 Resultados de los experimentos piloto (todos monolocutor, 380 cadenas de aprendizaje, 200 de test). En el capítulo 9 se detalla el procedimiento seguido para ignorar las frecuencias de las reglas y/o de los errores.

| Algoritmo de Reconocimiento | %Aciertos |
|--|-----------|
| No estocástico | |
| Modelo de error completo | 97,5 |
| Sólo substituciones | 96,5 |
| Estocástico | |
| Modelo de error completo | 99,5 |
| Ignorando frecuencia de los errores | 98,5 |
| Sólo substituciones | 99,5 |
| Sólo substituciones, ignorando frecuencia de las reglas | 99,5 |
| Sólo substituciones, ignorando frecuencia de los errores | 99 |
| Número medio de estados | 1063 |

A causa de la baja calidad de los parámetros, los resultados son inferiores a los que se obtienen con el corpus principal (ver exposición de éste más adelante), variando la diferencia entre los porcentajes de aciertos de 0 a -0.5 en el caso estocástico y de un -1.5 a -3 en el caso no estocástico (téngase en cuenta que los experimentos del corpus piloto son monolocutor). La relación entre los distintos tipo de reconocimiento se mantiene, discutiéndose en el apartado dedicado a los resultados del corpus principal.

En un apéndice se dan el tamaño de cada uno de los autómatas inferidos, que varía de 73 a 136 estados.

Como ejemplo visual de cómo distintos modelos representan realmente distintas estructuras, se adjunta la figura 8.6 con los 10 autómatas inferidos en con este corpus de datos.




Figura 8.6 (a) Los 10 autómatas inferidos en el experimento piloto, del /cero/ al /cuatro/.




Figura 8.6 (b) Los 10 autómatas inferidos en el experimento piloto, del /cinco/ al /nueve/

8.1.2.2 Corpus principal

El corpus principal, de 1100 dígitos pronunciados por 11 locutores (numerados del 1 al 11), se utilizó en 6 experimentos sencillos y dos experimentos en los que se utilizó la técnica "Leaving-k-out" (cross-validation) [Raudys,91] para suplir la relativa pequeñez del corpus.

8.1.2.2.1 Experimentos sencillos

Los experimentos sencillos se resumen en la tabla 8.5. Se encuentra un experimento multilocutor (H2) y varios independientes del locutor. H1,H3,H4 pretenden estudiar cómo afecta la mayor o menor cantidad de muestras de aprendizaje con respecto a las utilizadas posteriormente para el test de reconocimiento. H5, realizado posteriormente utiliza el reparto más adecuado con todas las muestras disponibles. H6 sustituye el locutor 10 de H5, que demostró estar adquirido en condiciones inadecuadas (saturación, palabras cortadas, etc...).

Tabla 8.5 Descripción de los experimentos sencillos efectuados con el corpus principal de dígitos hablados. El número de muestras se da como locutores*repeticiones_locutor*clases. F,M son locutores femeninos y masculinos respectivamente.

| Exp. | Aprendizaje | Test | Descripción |
|------|---|---|---|
| | Id. de Locutores, Sexo, N°Muestras | Id. de Locutores, Sexo N°Muestras | |
| H1 | 1,3,4,7,8 2F,3M $5 * 10 * 10 = 500$ | 2,5,9,10 3F,2M $5 * 5_{(primeras)} * 10 = 250$ | Independiente del locutor, mitad y mitad de las muestras |
| H2 | 1,2,3,4,5,6,7,8,9,10 5F,5M $10 * 5_{(primeras)} * 10 = 500$ | 1,2,3,4,5,6,7,8,9,10 5F,5M $10 * 5_{(siguientes)} * 10 = 500$ | Multilocutor |
| H3 | 1,2,5,6,7,8,9,10 4F,4M $8 * 6_{(primeras)} * 10 = 480$ | 3,4 1M,1F $2 * 10 * 10 = 200$ | Independiente del locutor, más locutores en aprendizaje |
| H4 | 3,5,6,9 2F,2M $4 * 10 * 10 = 400$ | 1,2,4,7,8,10 3F,3M $6 * 3_{(primeras)} * 10 = 180$ | Independiente del locutor, pocos locutores en aprendizaje |

| | | | |
|----|--|-----------------------------------|--|
| H5 | 1,2,4,7,8,10 3F,3M $6*10*10=600$ | 3,5,6,9 2F,2M $4*10*10=400$ | Independiente del locutor, todas las muestras, locutor 10 mal adquirido. |
| H6 | 1,2,4,7,8,11 3F,3M $6*10*10=600$ | 3,5,6,9 2F,2M $4*10*10=400$ | Independiente del locutor, todas las muestras. |

Cada uno de estos experimentos se repitió con varios tipos de algoritmos de reconocimiento (no todos en todos los casos), proporcionando la tabla 8.6.

Tabla 8.6 Resultados de los experimentos sencillos de reconocimiento de dígitos hablados (% de aciertos). Corpus de 1000 dígitos, distribuidos diferentemente según los experimentos. Ver capítulo 9 para una descripción de cómo se ignoran las frecuencias de los errores y/o de las reglas.

| Algoritmo de Reconocimiento | H1 | H2 | H3 | H4 | H5 | H6 |
|--|------|------|------|------|------|------|
| No estocástico | | | | | | |
| Modelo de error completo | – | – | – | – | 98,5 | 99 |
| Sólo substituciones | – | – | – | – | 99,5 | 99,5 |
| Estocástico | | | | | | |
| Modelo de error completo | 99,2 | – | – | – | 100 | 100 |
| Ignorando frecuencia de errores | 97,6 | – | – | – | – | – |
| Sólo substituciones | 98 | 100 | 100 | 98,8 | 99,7 | 99,8 |
| Sólo substituciones, ignorando frecuencia de reglas | 96,8 | 100 | 99,5 | 96,6 | 99,5 | 99,8 |
| Sólo substituciones, ignorando frecuencia de errores | 97,6 | 99,8 | 100 | 98,8 | 99 | 99 |
| Número medio de estados | 153 | 172 | 159 | 146 | 171 | 158 |

Se observa como la información que aporta la extensión estocástica siempre mejora el reconocimiento, bastando a veces con su aportación para alcanzar el 100% de reconocimiento.

En un caso no estocástico, es interesante comprobar que prohibir errores de inserción y borrado mejora el reconocimiento, llevándolo del 99% al 99,5%. Posiblemente debido a que (como indica el caso de utilizar sólo sustituciones, pero ignorando las frecuencias de error en el modelo estocástico) (ver capítulo 9) las reglas de error incorporadas al autómata toman demasiada importancia si se les superpone las del modelo de error, a menos que se hallen presentes las probabilidades de las reglas para suavizar el efecto.

8.1.2.2 Leaving-k-out

Como es posible comprobar con el experimento H4 (40 muestras por autómata frente a 50..60 en los demás experimentos), una disminución de muestras en aprendizaje conlleva un empeoramiento notable de la efectividad de los modelos en aprendizaje.

Por otro lado, el número de muestras utilizadas en reconocimiento (500 en el mejor de los casos) tampoco es realmente suficiente para estimar la capacidad de reconocimiento de ECGI. En [Duda,73] se estudia formalmente esta cuestión y se presenta una tabla en la que aparece el intervalo de confianza de una estimación del error medio real (y desconocido) p de un clasificador, en función del error estimado \hat{p} (por máxima verosimilitud) y del número de muestras utilizadas para la estimación n . Aún en el caso de que \hat{p} sea nulo (no hayan errores de reconocimiento), si se han utilizado 250 muestras, p se halla (con un 0.95 de probabilidad) entre el 0 y 0.6%. Con 1000 muestras todavía podría estar entre el 0 y 0.2%.

Para paliar el inconveniente de disponer tan sólo de un conjunto reducido de muestras, a la hora de estimar las capacidades de un reconocedor, se suele recurrir, en reconocimiento de formas, a la técnica de "leaving-k-out" [Raudys,91]. Esta técnica consiste en repetir varias veces los experimentos de reconocimiento intercambiando cada vez parte del conjunto de aprendizaje con parte del de test.

En nuestro caso se han repetido 5 veces un experimento de reconocimiento, intercambiando cada vez las muestras pertenecientes a 2 locutores (uno masculino y otro femenino). De esta manera, cada experimento sigue siendo independiente del locutor y se disponen cada vez de 800 muestras de aprendizaje (80 por autómata) y 200 de test, dando lugar a un conjunto de test efectivo de 1000 muestras. A lo largo de este trabajo hemos llamado HLKO11 este conjunto de experimentos (tabla 8.7).

Tabla 8.7 Experimentos "leaving-k-out" (HLKO11) para los dígitos hablados. El número de muestras se da como Locutores*muestras_locutor*clases. F,M son significan "femenino" y "masculino" respectivamente.

| Exp. | Aprendizaje | | Test | |
|------|------------------|----------------------|-----------|----------------------|
| | Locutores | Sexo NºMuestras | Locutores | Sexo NºMuestras |
| H11 | 2,4,5,6,7,8,9,11 | 4F,4M 8*10*10=800 | 1,3 | 1F,1M 2*10*10=200 |
| H22 | 1,3,4,5,6,8,9,11 | 4F,4M 8*10*10=800 | 2,7 | 1F,1M 2*10*10=200 |
| H33 | 1,2,3,5,6,7,9,11 | 4F,4M 8*10*10=800 | 4,8 | 1F,1M 2*10*10=200 |
| H44 | 1,2,3,4,6,7,8,11 | 4F,4M 8*10*10=800 | 5,9 | 1F,1M 2*10*10=200 |
| H55 | 1,2,3,4,5,7,8,9 | 4F,4M 8*10*10=800 | 6,11 | 1F,1M 2*10*10=200 |

Los resultados, utilizando el criterio minEL (definida en 6.6) durante la generación de autómatas, fueron los mostrados en la tabla 8.8.

Tabla 8.8 Resultados de los experimentos "leaving-k-out" (HLKO11) para los dígitos hablados (% de aciertos). Cada experimento involucra 800 muestras de aprendizaje y 200 de test.

| Algoritmo de Reconocimiento | H11 | H22 | H33 | H44 | H55 | Total |
|--------------------------------|------|------|------|-----|------|-------|
| No estocástico | | | | | | |
| Modelo de error completo | 99,5 | 99 | 99,5 | 100 | 99,5 | 99,5 |
| Sólo substituciones | 99,5 | 99,5 | 99 | 100 | 99,5 | 99,5 |
| Estocástico | | | | | | |
| Completo | 100 | 99,5 | 100 | 100 | 99,5 | 99,8 |
| Sólo substituciones | 100 | 99,5 | 100 | 100 | 99,5 | 99,8 |
| Número medio de estados | 181 | 200 | 199 | 186 | 198 | 192 |

El resultado final de 99,8%, presentado en la última columna de la tabla 8.8, representa tan sólo dos errores en 1000 operaciones de reconocimiento (reconocer /cuatro/ en vez de /ocho/ y /ocho/ en vez de /cuatro/).

Es muy notable el que, al aumentar las muestras de aprendizaje, los resultados del modelo de error completo y del obtenido prohibiendo los errores de borrado e inserción coinciden. Ello confirma que los modelos inferidos han ido incorporando los errores más frecuentes, e implica evidentemente un aumento de la complejidad espacial de los autómatas. Este aumento no es sin embargo excesivo, pues, en el peor de los casos, ha sido sólo de un 26% (comparando H4, de sólo 400 de muestras de aprendizaje y H22, de 800), y en el mejor 7.5% (H2, de 500 muestras, con H44).

Una idea de la estructura de los autómatas inferidos se puede extraer de la tabla 8.9 (todas las cantidades son medias para los 50 autómatas).

Tabla 8.9 Estadísticas (promedios) para los 50 autómatas inferidos en el experimento HLK011 (Tamaño del lenguaje, Número de estados, Factor de ramificación, número de reglas, longitud promedio de las cadenas del corpus, longitud mínima, media y máxima de las cadenas aceptadas).

| Tam. Len. | NºEstados | F.Ramific. | NºReglas | Long.Cad. | | | |
|-----------------------|-----------|------------|----------|-------------|------|------|------|
| | | | | aprendizaje | min. | med. | max. |
| 6,25·10 ¹⁴ | 192,8 | 1,97 | 387 | 28,3 | 15,4 | 19,9 | 55,1 |

El número de estados de los autómatas varía de 126 a 340 (ver apéndice B para detalles).

Los mismos experimentos, pero utilizando el locutor 10, demuestran que éste efectivamente es muy distinto a los demás (mala adquisición, comprobada examinando la señal en el dominio del tiempo), pues los resultados empeoran sensiblemente al estar este locutor en el conjunto de test (H55) (tabla 8.10).

Tabla 8.10 Resultados (% de aciertos) de los experimentos "leaving-k-out" (HLK010) cuando se sustituye el locutor 11 por el 10 (mal adquirido).

| Algoritmo de Reconocimiento | H11 | H22 | H33 | H44 | H55 | Total |
|--------------------------------|-----|-----|-----|-----|------|-------|
| Estocástico | | | | | | |
| Modelo de error Completo | 100 | 99 | 100 | 100 | 97,5 | 99,3 |
| Sólo substituciones | 100 | 99 | 100 | 100 | 97,5 | 99,3 |
| Número medio de estados | 210 | 210 | 209 | 196 | 198 | 205 |

8.1.2.3 Corpus de Letras

El corpus de 3000 letras habladas se utilizó en 4 experimentos sencillos y uno utilizando la técnica de "Leaving-k-out", con la misma filosofía que la aplicada en el corpus principal de dígitos hablados.

8.1.2.3.1 Experimentos sencillos

De los 4 experimentos sencillos, los 3 primeros fueron multilocutor y el cuarto independiente del locutor. En los dos primeros se utilizó un subconjunto del corpus, una vez escogiendo un rango cualquiera de letras ('H', 'I', 'J', 'K', 'L', 'M', 'N', 'O', 'P', 'Q') y la otra, el especialmente difícil conjunto de las EE-Letras. En los dos últimos se experimentó con las 30 clases posibles, una vez multilocutor y la otra independiente del locutor (ver tabla 8.11).

Tabla 8.11 Descripción de los experimentos sencillos efectuados con el corpus de letras habladas. El número de muestras se da como locutores*repeticiones_locutor*clases. F,M son locutores femeninos y masculinos respectivamente.

| Exp. | Aprendizaje | Test | Descripción |
|------|--|--|---|
| | Id. de Locutores, Sexo, N°Muestras | Id. de Locutores, Sexo, N°Muestras | |
| L1 | 1,2,3,4,5,6,7,8,9,10 5F,5M $10 * 8(\text{primeras}) * 9 = 720$ | 1,2,3,4,5,6,7,8,9,10 5F,5M $10 * 2(\text{últimas}) * 9 = 180$ | Multilocutor, vocabulario: "H,I,J,K,L,M,N,O,P,Q" (9 letras) |
| L2 | 1,2,3,4,5,6,7,8,9,10 5F,5M $10 * 8(\text{primeras}) * 9 = 720$ | 1,2,3,4,5,6,7,8,9,10 5F,5M $10 * 2(\text{últimas}) * 9 = 180$ | Multilocutor, vocabulario: "F,L,LL,M,N,Ñ,R,RR,S" (9 letras) |
| L3 | 1,2,3,4,5,6,7,8,9,10 5F,5M $10 * 8(\text{primeras}) * 30 = 2400$ | 1,2,3,4,5,6,7,8,9,10 5F,5M $10 * 2(\text{últimas}) * 30 = 600$ | Multilocutor, vocabulario: Todas las letras. (30 letras) |
| L4 | 1,2,3,4,5,8 3F,3M $6 * 10 * 30 = 1800$ | 6,7,9,10 2F,2M $4 * 10 * 30 = 1200$ | Independiente del locutor, vocabulario: Todas las letras (30 letras). |

Los resultados, obtenidos utilizando el modelo de error completo y el criterio minEN (definida en 6.6), se resumen en la tabla 8.12.

Tabla 8.12 Resultados de los experimentos sencillos de reconocimiento de letras hablados (% de aciertos). Corpus de 3000 letras, distribuidas diferentemente según los experimentos

| L1 | L2 | L3 | L4 |
|----|------|----|------|
| 99 | 86,7 | 86 | 76,5 |

Se comprueba efectivamente la mucho mayor dificultad del conjunto de las letras y EE-letras, y el empeoramiento de los resultados en el caso independiente del locutor, debido en partes iguales al menor número de muestras de aprendizaje para cada autómatas y a la mayor disimilitud de las muestras del conjunto de test.

8.1.2.3.1 Leaving-k-out

Para obtener una estimación del comportamiento de ECGI en un caso aún más difícil, se repitió el experimento L2 (EE-letras), pero en el caso independiente del locutor. Para aumentar la fiabilidad de los resultados se recurrió a la técnica de "leaving-k-out". Se realizó pues 5 veces el experimento, utilizando dos locutores en la fase de test (uno masculino y otro femenino) e intercambiando en cada experimento estos dos locutores con otros dos del conjunto de aprendizaje. Con ello se dispone en cada experimento de 720 muestras de aprendizaje (72 por autómatas) y 180 de test (llamamos LLKO a este experimento), dando lugar a un conjunto de test efectivo de 900 muestras (tabla 8.13).

Tabla 8.13 Experimentos "leaving-k-out" (LLKO) para las letras habladas. El número de muestras se da como Locutores*muestras_locutor*clases. F,M son significan "femenino" y "masculino" respectivamente.

| Exp. | Aprendizaje | | Test | |
|------|------------------|-----------------------------|-----------|-----------------------------|
| | Locutores | Sexo NºMuestras | Locutores | Sexo NºMuestras |
| L11 | 3,4,5,6,7,8,9,10 | 4F,4M $8 * 10 * 9 = 720$ | 1,2 | 1F,1M $2 * 10 * 9 = 180$ |
| L22 | 1,2,5,6,7,8,9,10 | 4F,4M $8 * 10 * 9 = 720$ | 3,4 | 1F,1M $2 * 10 * 9 = 180$ |
| L33 | 1,2,3,4,6,7,9,10 | 4F,4M $8 * 10 * 9 = 720$ | 5,8 | 1F,1M $2 * 10 * 9 = 180$ |
| L44 | 1,2,3,4,5,7,8,10 | 4F,4M $8 * 10 * 9 = 720$ | 6,9 | 1F,1M $2 * 10 * 9 = 180$ |
| L55 | 1,2,3,4,5,6,8,9 | 4F,4M $8 * 10 * 9 = 720$ | 7,10 | 1F,1M $2 * 10 * 9 = 180$ |

El experimento se realizó utilizando el criterio minEN (definida en 6.6), con el modelo de error completo, ignorando las frecuencias de los errores, ignorando las frecuencias de las reglas y sin utilizar probabilidades. Las tasas de reconocimiento obtenidas se dan en la tabla 8.14.

Tabla 8.14 Tasas de reconocimiento (% aciertos) en el experimento "leaving-k-out" llevado a cabo con letras habladas (EE-letras). Sin información estocástica, ignorando las frecuencias de las reglas, de los errores y con el modelo de error completo.

| Algoritmo de Reconocimiento | L11 | L22 | L33 | L44 | L55 | Total |
|---------------------------------|------|------|------|------|------|-------|
| No estocástico | | | | | | |
| Modelo de error completo | 76,1 | 73,8 | 71,1 | 68,3 | 60 | 69,9 |
| Estocástico | | | | | | |
| Completo | 77,7 | 76,1 | 76,6 | 72,2 | 66,6 | 73,8 |
| Ignorando frecuencia de reglas | 72,2 | 73,9 | 72,2 | 67,8 | 62,2 | 69,8 |
| ignorando frecuencia de errores | 76,7 | 77,2 | 70 | 70 | 62,8 | 71,3 |
| Número medio de estados | 831 | 784 | 797 | 763 | 749 | 785 |

Las tasas de reconocimiento mostradas en la tabla 8.14 evidencian una vez más la importancia que tiene para el buen funcionamiento de ECGI el utilizar la información estadística. Estas tasas, sin ser las que obtiene Bahl [Bahl,87] aplicando HMM al problema (similar) del E-set inglés (92%), son muy aceptables si se tiene en cuenta que no se han utilizados "símbolos continuos" (vectores de parámetros sin cuantizar vectorialmente) (Bahl –y Jelinek– obtienen un 79% con 200 símbolos discretos submuestreando a 100Hz). Utilizando el mismo corpus de EE-letras y HMM de 20 estados [Casacuberta,91] llega a obtener un 75%.

En la matriz de confusión media de los 5 experimentos se puede comprobar que la letra que da más problemas para su reconocimiento es la N (que se confunde con la M y Ñ), seguida de la L (que se confunde con la LL y R), lo cual es completamente consistente con nuestra apreciación perceptiva de la dificultad de la tarea (tabla 8.15).

Tabla 8.15 Matriz de confusión para el experimento LIO de reconocimiento de letras habladas (EE-letras). Los valores mostrados son acumulados para los 5 reconocimientos.

| Letra | F | L | LL | M | N | Ñ | R | RR | S | %Clase |
|--------------|----|----|----|----|----|----|----|----|----|-------------|
| F | 82 | 1 | 0 | 0 | 0 | 0 | 0 | 2 | 15 | 82% |
| L | 0 | 55 | 16 | 5 | 1 | 2 | 14 | 7 | 0 | 55% |
| LL | 0 | 15 | 78 | 0 | 0 | 5 | 1 | 0 | 1 | 78% |
| M | 1 | 3 | 0 | 70 | 6 | 13 | 1 | 6 | 0 | 70% |
| N | 1 | 5 | 0 | 24 | 43 | 21 | 6 | 0 | 0 | 43% |
| Ñ | 2 | 2 | 5 | 3 | 1 | 87 | 0 | 0 | 0 | 87% |
| R | 0 | 23 | 1 | 4 | 2 | 1 | 69 | 0 | 0 | 69% |
| RR | 3 | 6 | 0 | 2 | 0 | 0 | 0 | 89 | 0 | 89% |
| S | 11 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 89 | 89% |
| Total | | | | | | | | | | 73,5 |

Las cantidades que resumen la estructura media de los 45 autómatas se dan en la tabla 8.16.

Tabla 8.16 Estadísticas (promedios) para los 45 autómatas inferidos en el experimento LLKO. Tamaño del lenguaje, número de estados, factor de ramificación, número de reglas, longitud promedio de las cadenas del conjunto de aprendizaje, longitud mínima, media y máxima de las cadenas aceptadas.

| Tam. Len. | NºEstados | F.Ramif. | NºReglas | Long.Cad. aprendizaje | Long.Cad. min. | Long.Cad. med. | Long.Cad. max. |
|----------------------|-----------|----------|----------|-----------------------|----------------|----------------|----------------|
| 1,2·10 ²⁶ | 785 | 1,62 | 1271 | 56,8 | 26,8 | 51,8 | 130,3 |

La mayor cantidad media de reglas (3 veces más) de estos autómatas, si se les compara con los de los dígitos hablados, es debida no sólo a que las cadenas son el doble de largas en promedio, sino también a la mucha mayor variabilidad inducida por la existencia del doble número de símbolos.

8.2 Reconocimiento de imágenes planas

Aunque ECGI surgió durante la búsqueda de una solución para un determinado problema de reconocimiento del habla, fué evidente desde un principio que representaba una metodología aplicable a muchos otros campos del reconocimiento de formas.

Los siguientes experimentos se llevaron a cabo para demostrar esta independencia de ECGI de un campo de aplicación concreto, y pusieron en

evidencia una vez más su eficacia como método de reconocimiento de formas.

Hay que hacer notar que los resultados obtenidos, y que se muestran a continuación, se han conseguido *sin ningún tipo de adaptación* de ECGI al problema concreto del reconocimiento de imágenes.

8.2.1 Representación simbólica de imágenes planas

La adquisición, parametrización y conversión en una cadena de las imágenes se realiza siguiendo el procedimiento esquematizado en el capítulo 1. Más concretamente, todos los experimentos se han realizado a partir de muestras de dígitos (arábicos) manuscritos o impresos, adquiridas mediante una cámara que proporciona una imagen de 512*512 pixels, con una resolución de 3 pixels/mm.

Una vez digitalizada la imagen a 8 bits/pixel, se aplica un umbral para reducirla a 1 bit/pixel, suprimiendo así los grises. Seguidamente un barrido de izquierda a derecha y de arriba abajo, detecta la parte superior izquierda de cada uno de los dígitos individuales. Este es el primer punto del contorno de dicho dígito. A continuación, se aplica un algoritmo de seguimiento de contornos [Freeman,74], que proporciona la dirección en la que se encuentra el siguiente punto del contorno, de entre las 8 posibles. La secuencia de direcciones, codificadas del 0 al 7 (figura 8.7), proporciona la cadena de símbolos correspondiente a la imagen.




Figura 8.7 Símbolos para las cadenas de los corpus de dígitos manuscritos e impresos.

Los puntos aislados o puntos de "ruido" del contorno pueden suprimirse durante esta etapa. Evidentemente, esta codificación no tiene en cuenta los espacios huecos internos a la imagen del dígito, lo cual tiene fuertes repercusiones cuando no se cierra un trazado (ver ejemplos de dígitos manuscritos en la figura 8.9).

No se ha aplicado ningún procedimiento para asegurar la invarianza de la representación con respecto al giro y a la escala. La invarianza a la posición es intrínseca a la representación. Por lo tanto, se supondrá que ECGI es perfectamente capaz de tener en cuenta, gracias a su capacidad de generalización y corrección de errores, pequeñas variaciones de giro, inclinación y tamaño de los caracteres.

La resolución original de la imagen de 3 pixels/mm., proporciona cadenas largas, con gran cantidad de información probablemente redundante. Conocida la capacidad de ECGI de obtener resultados con muy poca información, se decidió disminuir esta resolución progresivamente, mediante aplicación de 4 rejillas de separación respectivamente de 4, 6, 8 y 10 pixels sobre la imagen original (figura 8.8). Un objetivo añadido de los experimentos consiste pues en determinar la rejilla (resolución, o lo que es igual: longitud de las cadenas) máxima que nos proporcione resultados óptimos.




Figura 8.8 Imágenes de los dígitos manuscritos, reconstruídas a partir de las cadenas obtenidas con rejillas de distinta resolución. Algunas de las cadenas correspondientes a estos dígitos.

8.2.3 Dígitos Manuscritos

El corpus de los dígitos manuscritos está formado por 20 repeticiones de cada dígito, escritas por 12 personas diferentes (2400 dígitos en total).

Cada escritor, utilizando un rotulador grueso, escribió los dígitos en hojas de papel blanco, en las que ya figuraban unas líneas guía inferiores, muy ténues. La única condición impuesta a los escritores fue que los dígitos se escribieran separados unos de otros. No se mencionó ninguna restricción de tamaño ni estilo (aunque las líneas guía y el grosor del rotulador

impidieran fantasías excesivas), observándose finalmente una variación 1:1/2 en tamaño y variaciones de inclinación del orden de -10 a +20 grados.




Figura 8.9 Imágenes escogidas para mostrar la variabilidad del corpus de dígitos manuscritos, reconstruídas a partir de las cadenas correspondientes a 6 pixels de resolución. Nótese el efecto de no cerrar algunos trazos (p.e. en los /8/).

8.2.3.1 Los experimentos

Al igual que en el experimento HLKO de los dígitos hablados, se recurrió a la técnica del "leaving-k-out". Se realizaron 12 experimentos, en cada uno de ellos se utilizaron las muestras de 10 de los escritores (2000 cadenas) para el aprendizaje y las de los dos restantes para test (400 cadenas). Por lo tanto, en todos los casos las cadenas de test pertenecían a escritores diferentes que los de las cadenas de aprendizaje. Cada experimento se diferencia del anterior por permutación circular del papel de cada uno de los escritores (tabla 8.17). De esta manera el total de operaciones de reconocimiento se eleva a 4800, habiéndose generado 120 autómatas a partir de 200 cadenas cada uno.

Tabla 8.17 Los 12 experimentos "leaving-k-out" con los dígitos manuscritos. El número de muestras se da como escritores*repeticiones*clases.

| Exp. | Aprendizaje | Test |
|------|-------------------------------------|--------------------------|
| | Escritores NºMuestras | Escritores NºMuestras |
| M1 | 3,4,5,6,7,8,9,0,A,B 10*20*10=200 | 1,2 2*20*10=400 |
| | 0 | |

| | | |
|-----|--|--------------------|
| M2 | 1,4,5,6,7,8,9,0,A,B 10*20*10=200 0 | 2,3 2*20*10=400 |
| ... | ... | ... |
| M12 | 1,2,3,4,5,6,7,8,9,0 10*20*10=200 0 | A,B 2*20*10=400 |

8.2.3.2 Los resultados

Los autómatas se infirieron utilizando el criterio maxA (definido en 6.6). Cada experimento de "leaving-k-out" se repitió variando el algoritmo de reconocimiento; obteniéndose los resultados mostrados en la tabla 8.18.

Tabla 8.18 Tasas de reconocimiento (% aciertos) para el experimento "leaving-k-out" con dígitos manuscritos. Cada cifra cooresponde a un total de 24000 muestras efectivas de aprendizaje (12 experimentos, en cada uno de los cuales se han utilizado 200 muestras para cada una de las 10 clases), y 48000 análisis sintácticos (12 experimentos con 10 autómatas a los que se presentaron 400 muestras).

| Algoritmo de Reconocimiento | Rej4 | Rej6 | Rej8 | Rej10 |
|-----------------------------|------|------|------|-------|
| No estocástico | | | | |
| Modelo de error Completo | 92,3 | 92 | 91 | 89 |
| Sólo substituciones | 92,5 | 92 | 91 | 89,4 |
| Estocástico | | | | |
| Modelo de error Completo | 98,4 | 98,3 | 96,9 | 96,0 |
| Sólo substituciones | 98 | 98,1 | 96,9 | 96,3 |

Vuelve a mostrarse la importancia de la información estadística. Se observa que la diferencia de precisión entre utilizar el modelo de error completo y prohibir inserciones y borrados es muy reducida, e incluso es a favor de utilizar sólo substituciones en el caso no estocástico.

Por otro lado, y como se esperaba, al aumentar la resolución de la rejilla la tasa de error disminuye. Sin embargo, la mejora obtenida al pasar de la rejilla de resolución 8 a la 6 es muy superior a la obtenida al pasar de la 6 a la 4, casi insignificante, por lo que no resulta útil emplear esta última.

En la tabla 8.19, se muestra la matriz de confusión media de los 12 reconocimientos efectuados para la rejilla 6 en el caso estocástico de sólo

substitución en reconocimiento. La matriz correspondiente al modelo de error completo es muy similar (véase apéndice B para poder comparar las 4 rejillas).

Tabla 8.19 Matriz de confusión para el experimento con rejilla 6 y sólo sustitución de los dígitos manuscritos. Los valores mostrados son acumulados para los 12 reconocimientos.

| Dígito | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | %Clase |
|--------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|--------|
| 0 | 474 | 0 | 0 | 0 | 0 | 0 | 3 | 0 | 3 | 0 | 98.7% |
| 1 | 0 | 467 | 8 | 0 | 0 | 0 | 0 | 0 | 0 | 5 | 97.3% |
| 2 | 0 | 0 | 480 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100.0% |
| 3 | 0 | 0 | 0 | 480 | 0 | 0 | 0 | 0 | 0 | 0 | 100.0% |
| 4 | 0 | 1 | 0 | 0 | 465 | 0 | 0 | 4 | 0 | 10 | 96.9% |
| 5 | 0 | 0 | 0 | 0 | 0 | 480 | 0 | 0 | 0 | 0 | 100.0% |
| 6 | 0 | 0 | 0 | 0 | 0 | 0 | 480 | 0 | 0 | 0 | 100.0% |
| 7 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 476 | 0 | 2 | 99.2% |
| 8 | 0 | 0 | 12 | 6 | 1 | 0 | 1 | 0 | 453 | 7 | 94.4% |
| 9 | 0 | 2 | 0 | 12 | 0 | 6 | 0 | 0 | 4 | 456 | 95.0% |

Seguidamente se tabulan las tasas de error, para cada uno de los autómatas y cada uno de los 12 reconocimientos (R1 a R12) efectuados con las 4 rejillas, también cuando sólo se permiten sustituciones en reconocimiento.

Tabla 8.20 Tasa de aciertos para los 48 reconocimientos de dígitos manuscritos realizados en el experimento estocástico con sólo sustitución (12 experimentos leaving-k-out, R1 a R12, con 4 rejillas distintas).

| Rec. | Rej4 | Rej6 | Rej8 | Rej10 | Promedio |
|--------------|------|------|------|-------|----------|
| R1 | 99,7 | 99,7 | 98,7 | 98,7 | 99,2 |
| R2 | 98,7 | 99 | 98,5 | 98,2 | 98,6 |
| R3 | 99,2 | 98,7 | 98,2 | 97 | 98,3 |
| R4 | 100 | 99,2 | 99,5 | 96,5 | 98,8 |
| R5 | 96 | 98 | 95,7 | 94,7 | 96,2 |
| R6 | 93,5 | 95 | 92,7 | 90,7 | 93,7 |
| R7 | 97,2 | 98 | 96,2 | 94,7 | 96,5 |
| R8 | 98,2 | 97,7 | 97,5 | 98,7 | 98,3 |
| R9 | 97 | 96,5 | 96,5 | 96,5 | 96,6 |
| R10 | 98,7 | 98,2 | 97 | 97 | 97,7 |
| R11 | 99,7 | 99 | 96,2 | 97,5 | 98,1 |
| R12 | 98,7 | 98,5 | 96 | 95,2 | 98,1 |
| Media | 98 | 98,1 | 96,9 | 96,3 | |

Una idea de la estructura y dimensiones espaciales de los autómatas se puede extraer de la tabla 8.21.

Tabla 8.21 Dimensiones espaciales de los autómatas inferidos en los experimentos de dígitos manuscritos.

| | Rej4 | Rej6 | Rej8 | Rej10 |
|--------------------------------------|---------------------|---------------------|---------------------|---------------------|
| Tamaño del Lenguaje | $5,6 \cdot 10^{60}$ | $1,8 \cdot 10^{40}$ | $1,0 \cdot 10^{31}$ | $8,5 \cdot 10^{23}$ |
| Número medio de estados | 309 | 223 | 175 | 144 |
| Factor de Ramificación | 3,78 | 3,71 | 3,70 | 3,60 |
| Nº de Reglas | 1170 | 826 | 649 | 519 |
| Longitud Cadenas Corpus | 73,1 | 48,1 | 35,7 | 28,3 |
| Longitud de cadenas Aceptadas | | | | |
| mínima | 22 | 16 | 13 | 11 |
| máxima | 182 | 120 | 91 | 71 |
| media | 80 | 52 | 39 | 30 |

8.2.4 Dígitos Impresos

El corpus de los dígitos impresos está formado por caracteres impresos con 8 diferentes tipos de letra. Cada tipo se ha impreso con 4 tamaños diferentes en el rango 1:1/2. Para cada tamaño de cada tipo se imprimió cada dígito 10 veces, 5 en negrita y 5 en grosor normal. Para cada tipo de letra hay por lo tanto $4 \cdot (5+5) \cdot 10 = 400$ muestras, estando el corpus completo constituido por 3200 imágenes. En la figura 8.10 se muestra un ejemplo representativo de las mismas.

| C. Font | Normal | Negrita |
|---------------|---------------------|----------------------------|
| 1 Avant Garde | 0 1 2 3 4 5 6 7 8 9 | 0 1 2 4 5 6 7 8 9 |
| 2 Bookman | 0 1 2 3 4 5 6 7 8 9 | 0 1 2 3 4 5 6 7 8 9 |
| 3 Courier | 0 1 2 3 4 5 6 7 8 9 | 0 1 2 3 4 5 6 7 8 9 |
| 4 Helvética | 0 1 2 3 4 5 6 7 8 9 | 0 1 2 3 4 5 6 7 8 9 |
| 5 New Century | 0 1 2 3 4 5 6 7 8 9 | 0 1 2 3 4 5 6 7 8 9 |
| 6 Palatino | 0 1 2 3 4 5 6 7 8 9 | 0 1 2 3 4 5 6 7 8 9 |
| 7 Times | 0 1 2 3 4 5 6 7 8 9 | 0 1 2 3 4 5 6 7 8 9 |

8 Zapf Chancery

0 1 2 3 4 5 6 7 8 9

0 1 2 3 4 5 6 7 8 9

Tamaño

0000 1111 2222 3333 4444 5555 6666 7777
8888 9999

Figura 8.10 Tipos de letra (clases) utilizados en los experimentos de dígitos impresos. Los tamaños no son absolutos.

Por otra parte, debido a una presentación poco cuidadosa de las hojas de papel al sistema de adquisición, se observó una inclinación de los tipos (añadida a la natural de los propios tipos de letra) que variaba en un rango de ± 10 grados (figura 8.11).




Figura 8.11 Imágenes escogidas para mostrar la variabilidad del corpus de dígitos impresos una vez adquirido y parametrizado. Dígitos reconstruídos a partir de las cadenas correspondientes a 6 pixels de resolución.

8.2.4.1 Los experimentos

Utilizando la técnica del "leaving-k-out" se realizaron 8 experimentos, en cada uno de ellos se utilizaron las muestras correspondientes a 7 tipos de letra para el aprendizaje (2800 cadenas), y la restante para el reconocimiento (400 cadenas). Por lo tanto, las cadenas de test pertenecían, en todos los casos,

a un tipo de letra distinto que el de las utilizadas en aprendizaje. Cada experimento se diferencia del anterior por permutación circular del papel de cada uno de los tipos. De esta manera el total de operaciones de reconocimiento se eleva a 3200, habiéndose generado 80 autómatas a partir de 280 cadenas cada uno (tabla 8.22).

Tabla 8.22 Los 8 experimentos "leaving-k-out" con los dígitos impresos. El número de muestras se da como tipos*repeticiones*clases

| Exp. | Aprendizaje | Test |
|------|---------------------------------------|--------------------------|
| | Tipos NºMuestras | Tipos NºMuestras |
| I 1 | 2,3,4,5,6,7,8 $7 * 40 * 10 = 2800$ | 1 $1 * 40 * 10 = 400$ |
| I 2 | 1,3,4,5,6,7,8 $7 * 40 * 10 = 2800$ | 2 $1 * 40 * 10 = 400$ |
| ... | ... | ... |
| I 8 | 1,2,3,4,5,6,7 $7 * 40 * 10 = 2800$ | 8 $1 * 40 * 10 = 400$ |

8.2.4.2 Los resultados

Los autómatas se infirieron utilizando el criterio maxA (definido en 6.6). Cada experimento de "leaving-k-out" se repitió con el modelo de error completo y prohibiendo inserciones y borrados; obteniéndose los resultados mostrados en la tabla 8.23.

Tabla 8.23 Tasas de reconocimiento para el experimento "leaving-k-out" con dígitos impresos. Cada cifra se ha obtenido con 22400 muestras de aprendizaje (8 experimentos en los que se utilizaron 280 muestras para cada una de las 10 clases) y corresponde a un total 32000 análisis sintácticos (8 experimentos en cada uno de los cuales se presentaron 400 muestras a 10 autómatas).

| Algoritmo de Reconocimiento | Rej4 | Rej6 | Rej8 | Rej10 |
|-----------------------------|------|------|------|-------|
| Estocástico | | | | |
| Completo | 99,4 | 99,8 | 99,6 | 98,2 |
| Sólo substituciones | 99,9 | 99,4 | 98,9 | 97,7 |

De nuevo se observa que cuando la información es abundante para generar los autómatas, el prohibir las inserciones y borrados puede incluso llevar a mejorar la tasa de reconocimiento.

Con el modelo de error completo resulta ser ventajoso limitarse a la rejilla de resolución 6. Si sólo se autorizan sustituciones la variación de la rejilla 8 a la 4 es casi lineal, pudiéndose entonces considerar la rejilla 6, al igual que para los dígitos manuscritos, como un buen compromiso en caso de necesidad imperiosa de reducir la complejidad espacial y temporal.

Los resultados, como era de esperar, son mejores que los obtenidos en los experimentos equivalentes de dígitos manuscritos, situándose aproximadamente en un 1,5% en el caso de sólo sustitución. Con el modelo de error completo, en las bajas resoluciones de la rejilla (8 y 10) se llega a más de un 2% de diferencia.

A continuación (tabla 8.24) se muestra la matriz de confusión media de los 8 reconocimientos efectuados para la rejilla 6 en el caso de sólo sustitución en reconocimiento. La matriz correspondiente al modelo de error completo es muy similar (véase apéndice B para poder comparar las 4 rejillas).

Tabla 8.24 Matriz de confusión para el experimento de reconocimiento de dígitos impresos con rejilla 6 y con sólo sustitución. Los valores mostrados son acumulados para los 8 reconocimientos.

| Dígito | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | %Clase |
|--------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|--------|
| 0 | 319 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 99.7% |
| 1 | 0 | 309 | 0 | 0 | 0 | 0 | 0 | 11 | 0 | 0 | 96.6% |
| 2 | 0 | 0 | 320 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100.0% |
| 3 | 0 | 0 | 0 | 320 | 0 | 0 | 0 | 0 | 0 | 0 | 100.0% |
| 4 | 0 | 1 | 0 | 0 | 320 | 0 | 0 | 0 | 0 | 0 | 100.0% |
| 5 | 0 | 0 | 0 | 0 | 0 | 320 | 0 | 0 | 0 | 0 | 100.0% |
| 6 | 0 | 0 | 0 | 0 | 0 | 0 | 316 | 0 | 4 | 0 | 98.8% |
| 7 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 320 | 0 | 0 | 100.0% |
| 8 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 319 | 0 | 99.7% |
| 9 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 319 | 99.7% |

Seguidamente se tabulan las tasas de error, para cada uno de los autómatas y cada uno de los 8 (R1 a R8) reconocimientos efectuados con las 4 rejillas, también cuando sólo se permiten sustituciones en reconocimiento (tabla 8.25).

Tabla 8.25 Tasa de aciertos para los 8 experimentos R1 a R8 y las 4 rejillas (un total de 12800 reconocimientos), experimentos de sólo sustitución con los dígitos impresos.

| Rec. | Rej4 | Rej6 | Rej8 | Rej10 | Promedio |
|------|-------|-------|-------|-------|----------|
| R1 | 99,75 | 99,75 | 96 | 94,25 | 97,43 |
| R2 | 100 | 99,75 | 100 | 98 | 99,43 |
| R3 | 100 | 100 | 99,25 | 99 | 99,5 |

| | | | | | |
|-------|-------|-------|-------|-------|-------|
| R4 | 100 | 100 | 99 | 99,25 | 99,56 |
| R5 | 100 | 100 | 100 | 96,75 | 99,18 |
| R6 | 100 | 100 | 100 | 99,25 | 99,18 |
| R7 | 100 | 100 | 100 | 99,25 | 99,8 |
| R8 | 100 | 100 | 97 | 95,5 | 98,12 |
| Media | 99,97 | 99,44 | 98,91 | 97,75 | |

Donde se observa claramente que el tipo que más difícil es de reconocer es el que sirve de test en el primero de los 8 reconocimientos: el tipo AvantGarde (0123456789). Este tipo es, con el Helvetica (0123456789) el único que no tiene *serif*, y tiene los 6 y 9 mucho más abiertos que todos los otros tipos. El siguiente tipo en dificultad es el ZapfChancery (0123456789), del cual se esperaba que fuera el más difícil por su estilo mucho más curvilíneo.

Una idea de la estructura y dimensiones espaciales de los autómatas se puede tener examinando la tabla 8.26.

Tabla 8.26 Dimensiones espaciales de los autómatas inferidos en los experimentos de dígitos impresos.

| | Rej4 | Rej6 | Rej8 | Rej10 |
|--------------------------------------|---------------------|---------------------|---------------------|---------------------|
| Tamaño del Lenguaje | $3,3 \cdot 10^{45}$ | $1,2 \cdot 10^{36}$ | $5,4 \cdot 10^{26}$ | $6,2 \cdot 10^{20}$ |
| Número medio de estados | 255 | 174 | 134 | 114 |
| Factor de Ramificación | 3,57 | 3,46 | 3,34 | 3,22 |
| Nº de Reglas | 911 | 602 | 449 | 369 |
| Longitud Cadenas Corpus | 72,8 | 47,9 | 35,5 | 28,1 |
| Longitud de cadenas Aceptadas | | | | |
| mínima | 22 | 17 | 14 | 12 |
| máxima | 154 | 101 | 75 | 60 |
| media | 66 | 42 | 30 | 24 |

8.2.4.3 El uno sin base

Con exactamente la misma filosofía descrita en el apartado anterior, se repitieron todos los experimentos en los que sólo se autorizaba substitución

y en los que se utilizaba el modelo de error completo, pero quitando del conjunto de muestras, una vez el ZapfChancery, y otra el Helvética. Los resultados se muestran en la tabla 8.27.

Tabla 8.27 Resultados de los experimentos de "leaving-k-out" para los dígitos impresos. Los mismos, pero suprimiendo del conjunto de datos el tipo ZapfChancery y el Helvética.

| Algoritmo de Reconocimiento | Rej4 | Rej6 | Rej8 | Rej10 |
|-----------------------------|-------|-------|-------|-------|
| Todos Los Tipos | | | | |
| Completo | 99,4 | 99,78 | 99,59 | 98,22 |
| Sólo substituciones | 99,97 | 99,44 | 98,91 | 97,75 |
| Sin ZapfChancery | | | | |
| Completo | 99,93 | 99,75 | 99,43 | 98,50 |
| Sólo substituciones | 100 | 99,29 | 99,32 | 97,82 |
| Sin Helvética | | | | |
| Completo | 99,36 | 99,75 | 98,82 | 98,50 |
| Sólo substituciones | 99,18 | 98,75 | 98,14 | 97,32 |

Donde resulta obvio que ZapfChancery es más dificultoso que Helvética, hasta el punto que no incluirlo en el conjunto de datos permite conseguir el 100% de aciertos, notablemente, en el caso de sólo tolerar errores de substitución, aunque, eso, sí con la rejilla de mayor resolución.

Por otra parte, resulta interesante comprobar cómo ECGI modeliza efectivamente las características más importantes de las formas consideradas. Examinando con detalle los resultados del experimento sin tipo Helvética, se comprueba que en *todos los casos* (con rejilla 4 y 6) se obtuvo un 100% de aciertos excepto en el primero de los 8 reconocimientos, el R1, en el que se obtuvieron las tasas mostradas en la tabla 8.28.

Tabla 8.28 Resultados del reconocimiento R1 para dos rejillas. Experimento sin Helvética de reconocimiento de dígitos impresos

| | Rej4 | Rej6 |
|---------------------|-------|-------|
| Completo | 95,5 | 94,25 |
| Sólo substituciones | 98,25 | 91,25 |

Lo que evidencia que la única dificultad se presenta cuando el tipo AvantGarde esta en el conjunto de test. Del examen de las matrices de confusión (en apéndice B) se desprende que en un 71% de los casos el error es debido a confundir un 1 con un 7. Es decir, en vez de asignar (**1**) a la clase cuyo modelo se ha aprendido mediante (**1 1 1 1 1 1**), se le asigna a la clase

correspondiente a (777777), lo cual evidentemente es debido a dos obvias características diferenciadoras del (1) de AvantGarde: no tiene la "base" debida al serif, y la parte superior del uno es horizontal en vez de dirigirse hacia abajo. Ello es tanto más relevante, en cuanto el único error que se produce en el experimento con todos los tipos (correspondiente al valor 99,97% de aciertos: 1 error de 3200 muestras, sólo substitución con rejilla 4) es debido a la misma confusión de (1) de AvantGarde con un 7 (véase matrices de confusión en el apéndice B), y ello aunque ECGI haya aprendido, gracias a Helvética que existen unos sin serif: (1) (figura 8.12).




Figura 8.12 La única muestra no reconocida en el experimento de reconocimiento de dígitos impresos (Rejilla 4 y sólo autorizando errores de substitución).

8.2.6 Invarianza a la rotación y otras posibles extensiones

Como ya se expuso, al hablar del método de parametrización y conversión de imágenes planas a cadenas, la representación utilizada en los experimentos no es en absoluto invariante a la rotación ni al cambio de escala. Se ha comprobado, a través de los resultados obtenidos, que ECGI es capaz de adaptarse a *pequeñas* variaciones de escala y ángulo de presentación de los objetos, recurriendo a sus capacidades de generalización. No ocurre lo mismo si las variaciones de tamaño y de inclinación son muy amplias, pues ello llevaría a un crecimiento desmesurado de los modelos inferidos por ECGI, al tener éstos que dar cuenta de todas las posibilidades de presentación. Afortunadamente, una invarianza a la escala es fácilmente obtenible mediante una adaptación automática de la resolución de la rejilla.

Sin embargo, la invarianza a la rotación presenta mayores inconvenientes. Una posibilidad podría ser el utilizar códigos de cadena *relativos* [Bribiesca,80], en los que cada símbolo representa un ángulo *relativo al anterior* y no un ángulo absoluto como aquí se ha definido. Todos los contornos de un mismo objeto en distintas rotaciones, codificado de esta manera, proporcionará la misma *cadena circular*. Desafortunadamente, dependiendo del punto de corte se obtendrán diferentes cadenas lineales.

En casi todos los casos, en aprendizaje sigue siendo posible presentar los objetos patrón en una posición específica, lo cual permite cortar las cadenas

circulares en un punto fijo (p.e. la parte superior izquierda) y aplicar continuación ECGI en aprendizaje como es usual. En reconocimiento, sin embargo, será necesario aplicar un proceso de comparación que tenga en cuenta la posible permutación circular de las cadenas.

También es posible el reconocimiento de dígitos trazados, en los que se adquiere directamente una secuencia de direcciones, la cual es mucho más significativa que la proporcionada por los contornos. Si se prescinde del problema de la invarianza a la rotación, ECGI es inmediatamente aplicable a este tipo de adquisición con sólo realizar una adecuada normalización de escala (y quizá algún filtrado).

Por otra parte, no es imprescindible representar las imágenes mediante contornos (pueden utilizarse esqueletos por ejemplo [Davies,81] [Zhang,84]), ni siquiera mediante modelos lineales. Es extremadamente sencillo extender los algoritmos que mediante corrección de errores realizan la comparación de una cadena con una gramática, es decir de una estructura lineal (la cadena) con una arbórea (la gramática), de manera que permitan comparar dos estructuras arbóreas. Así se podría conseguir que encontraran (p.e.) la cadena más similar entre dos gramáticas, o comparar una estructura arbórea (e incluso quizás una red en general) con otra (una estructura arbórea con una gramática de Web o de árbol [Fu,82]). Ello permitiría utilizar ECGI para inferir modelos de estructuras *no lineales*.

8.3 Experimentos de síntesis

Una posible aproximación, para comprobar hasta qué punto los modelos inferidos por ECGI modelizan las formas que se suponen deben representar, consiste en utilizar los autómatas inferidos en la *síntesis* de nuevas muestras (objetos), y compararlos "de visu" con objetos reales.

Ello es especialmente factible en el caso de imágenes, las cuales presentan además la ventaja —que no tendría un experimento de síntesis de la palabra— de proporcionar resultados fácilmente mostrables.

El algoritmo de síntesis consiste simplemente en un recorrido aleatorio de las reglas de la gramática: partiendo del axioma se llega hasta una regla final ($A \rightarrow a$), escogiendo en cada paso al azar la siguiente regla a aplicar. La decisión aleatoria tiene en cuenta las probabilidades de las reglas (pero no las de error: no se pretende añadir a las cadenas sintetizadas errores provenientes del modelo de error). Este proceso se ha utilizado para generar las muestras de las figuras siguientes, que presentan cada una 100 muestras. Las muestras (figura 8.13), en un primer caso (parte superior de la la figura) han sido generadas con los autómatas inferidos a partir del corpus de dígitos

manuscritos, y en un segundo caso (parte inferior de la figura) a partir del de dígitos impresos.





Figura 8.13 100 Muestras de dígitos manuscritos (arriba) e impresos (abajo) sintetizadas a partir de las gramáticas inferidas por ECGI. De arriba abajo, 1 fila de cada dígito, en el orden 0123456789.

Se observa que, en su gran mayoría, los dígitos sintetizados corresponden con la clase a los que se los asignaría intuitivamente. Si exceptúa unos pocos casos irreconocibles³, la defomidad observada en muchos dígitos se debe en gran medida a que ECGI no es capaz de inferir la condición de cierre del contorno, lo que incluso le lleva a veces a intercambiar los contornos derecho e izquierdo.

8.4 Resumen de resultados

Del conjunto de resultados presentados a lo largo de todo este capítulo, se puede comprobar la gran eficacia que tiene el método ECGI en el reconocimiento de formas, por poco que el problema se adapte a los heurísticos que el método lleva implícitos.

En reconocimiento del habla, los resultados son similares o superiores a los proporcionados por otros métodos de reconocimiento de palabras aisladas, usualmente considerados como los que más eficaces en la práctica (modelos de Markov (HMM), alineamiento temporal (DTW),...) (ver capítulo 12). En tareas de reconocimiento de dígitos hablados (independientes del locutor, en ambiente no ruidoso) se consigue con ECGI tasas de aciertos superiores al 99% en todos los casos, llegando sin especial dificultad al 99,8% e incluso al 100% en algunos casos. Para diccionarios difíciles, como las letras, y especialmente las EE-letras, los resultados son también similares a los que proporcionan otras técnicas: 76,5% de aciertos para las 26 letras castellanas y 73.8% para las 9 EE-letras. Como punto de comparación, se puede mencionar que en [Casacuberta,91] se obtiene un 75% en este último corpus, mientras que en [Bahl,87] se obtiene (con HMM) un 92% reconociendo el E-set inglés, pero utilizando símbolos no cuantizados vectorialmente. Los resultados de [Bahl,87] bajan a un 79% si se procede a la cuantización, aunque se muestree a 100Hz., en vez de los 66.6Hz. de los experimentos aquí presentados. Por otro lado, ECGI consigue muy buenos resultados (99.5%, dependiente del locutor) incluso con cadenas formadas por símbolos muy poco elaborados y con relativamente pocas muestras de aprendizaje (38 por clase).

En reconocimiento de imágenes (en concreto dígitos manuscritos e impresos), los resultados son similarmente satisfactorios, realmente mejores que otros métodos más clásicos (98% frente a 80-90% obtenidos mediante la utilización de momentos geométricos y distancia de Mahalanobis [Vidal,92] [Vidal,92a], ver capítulo 12) y similares a las mejores que se obtienen

³ Debería decir: ...que muestran inmundos garabatos indignos del escolar más travieso.

actualmente con métodos mucho más adaptados a la tarea específica (98-99% [Kurosawa,86] [Shridar,86] [Baptista,88]).

Por otra parte, los experimentos han mostrado la real y necesaria aportación que lleva a cabo la información estadística al reconocimiento (la inferencia ha sido en todos los casos no estocástica), ganando ECGI gracias a ella un 5% de promedio en la tasa de reconocimiento. También se ha evidenciado que es posible conseguir los mismos resultados (a veces mejores) incluso suprimiendo parte del modelo de error en reconocimiento (permitiendo tan sólo errores de sustitución), lo que reduce fuertemente la complejidad temporal del reconocimiento y permite utilizar otros métodos que llevan a reducir dicha complejidad de hasta un 90% [Torró, 90].

La complejidad espacial (que afecta fuertemente a la temporal) de los modelos inferidos nunca llega a ser excesiva: de 400 reglas en tareas sencillas (dígitos hablados) a 1300 en tareas difíciles (EE-letras habladas) y puede ser reducida por los métodos de simplificación que se presentarán en el capítulo 10. En la mayoría de los casos ECGI se comporta "razonablemente", pudiéndose comprobar que los errores de reconocimiento son debidos a muestras notablemente distintas de las utilizadas para el aprendizaje (locutor 11 en dígitos hablados, el uno de AvantGarde en dígitos impresos) o a clases que se prestan a confusión (N se confunde con M y Ñ, L se confunde con LL y R, en letras habladas, 1 se confunde con 7 en dígitos impresos).

Finalmente, se ha comprobado de manera muy visual, mediante experimentos de síntesis de imágenes, que los modelos inferidos por ECGI almacenan realmente suficiente información como para poder generar nuevos objetos de su clase, que evidencian todas las características que los diferencian de las otras clases.