

Epílogo

Conclusiones

En este trabajo se ha propuesto, estudiado e implementado, un nuevo método incremental de inferencia gramatical: el método ECGI.

Tal como se ha explicado detalladamente en el capítulo 6, ECGI recurre a una poderosa herramienta de comparación de objetos y formas, la *corrección de errores* (implementada mediante técnicas de programación dinámica), para construir modelos de formas y (simultáneamente, si se necesario) reconocer nuevos objetos. Gracias a esta herramienta, ECGI es capaz de encontrar qué subestructuras es necesario añadir al modelo para incorporarle, con un coste mínimo de modificación, cada una de las nuevas muestras.

Junto con otros cuatro métodos, unos igualmente recientes (métodos de Thomason y Falaschi), otros poco estudiados (métodos de Chirathamjaree y de Marco) (capítulo 12), ECGI forma una nueva clase de métodos de inferencia. Esta clase, compuesta por los métodos que emplean la misma técnica que ECGI u otras técnicas similares, también basadas en la programación dinámica y en la corrección de errores, contribuye a engrosar el (hoy por hoy más bien parco) conjunto de los métodos de inferencia gramatical. De entre éstos, el método ECGI se coloca entre los que mejores resultados han obtenido en aplicaciones prácticas.

Si bien, como ha quedado patente en su lugar (capítulos 3 y 6), los algoritmos de la clase del ECGI son métodos heurísticos y difícilmente caracterizables, los resultados obtenidos (capítulo 8) demuestran que el ECGI está sorprendentemente bien adaptado a determinadas aplicaciones reales de reconocimiento de formas. Incluso en condiciones de forzada suboptimalidad (experimentos con autómatas deterministas, capítulo 11), y con información muy escasa y de pobre calidad (experimentos piloto,

capítulo 8) se obtienen tasas de reconocimiento elevadas, a veces idénticas a las obtenidas en las mejores condiciones. Ello permite introducir nuevos heurísticos adaptados al problema, en la forma (por ejemplo) de distintos criterios de distancia (relacionados o no con los tres estudiados en el capítulo 6), en la confianza de que, aún siendo su evaluación subóptima, se van a lograr resultados de alcance práctico.

Los resultados que proporciona ECGI en aplicaciones de reconocimiento de formas (capítulo 9) son perfectamente comparables, e incluso generalmente superiores, a los obtenidos aplicando, a los mismos objetos (particularmente imágenes y palabras), técnicas más convencionales como pueden ser los Modelos de Markov y varios modelos basados en la teoría de la decisión (DTW, K-Vecinos, momentos geométricos con distancia de Mahalanobis, etc.) (capítulo 12). En experimentos de reconocimiento de dígitos hablados independientes del locutor se obtiene sin dificultad un 99,8% de aciertos, mientras que para diccionarios hablados notablemente más difíciles (EE-letras) aún se consigue un 73,6% de aciertos. En reconocimiento de imágenes planas los resultados son del orden del 98,2% de aciertos (dígitos manuscritos) y del 99,9% (dígitos impresos), habiendo sido obtenidos estos últimos resultados sin ninguna adaptación de ECGI al problema y con un método relativamente simple de parametrización.

Por otra parte, la complejidad (temporal y espacial) de ECGI en tareas de reconocimiento de formas ha resultado ser similar, y a menudo inferior, a la de estos mismos métodos convencionales, siendo el coste del reconocimiento de una muestra de $O(|\alpha| \cdot B \cdot |Q|)$, donde α es la cadena muestra, B el factor de ramificación medio (entre 1,6 y 3,8) y Q el conjunto de estados del modelo (talla normalmente entre 200 y 700 estados). Para el caso de que la complejidad de ECGI fuera, a pesar de todo, una desventaja, se ha estudiado la posibilidad de simplificar los modelos inferidos (capítulo 10), comprobándose que es factible reducir la complejidad espacial de los mismos en un 40% a 60%, sin merma de la tasa de reconocimiento. Además, trabajos realizados en paralelo con éste demuestran que es posible reducir, también sin pérdida de eficacia, la complejidad temporal en un factor 10.

Asimismo, en los diversos experimentos presentados en los capítulos 8 y 9, ha quedado patente que es posible reducir la complejidad temporal de ECGI en la fase de reconocimiento en un 30-40%, sencillamente y sin reducción de eficacia (e incluso con un aumento de ésta), con sólo restringir el modelo de error, prohibiéndole inserciones y borrados. Ello es tanto más cierto cuanto con más detalle se haya inferido el modelo (muchas muestras y/o resolución)

Discutiendo las condiciones de convergencia de ECGI (capítulo 9) se ha mostrado que los modelos inferidos por ECGI nunca dejan realmente de crecer. Sin embargo, un razonamiento y una demostración empírica confirman que en condiciones reales, y siempre que las muestras no presenten una variabilidad excesiva, el ECGI converge asintóticamente

proporcionando modelos eficaces con un número de muestras relativamente reducido (≈ 200).

ECGI infiere gramáticas regulares (de tipo SANSAT: "SAmE Non-terminal, then SAmE Terminal", ver capítulo 2) sin circuitos, en general ambiguas y no deterministas. Se ha propuesto un método (muy heurístico y subóptimo) que permite obligarle a inferir gramáticas deterministas (y por lo tanto no ambiguas) *sin pérdida alguna* de eficacia en reconocimiento (capítulo 11).

Por otra parte, simultáneamente con todos estos estudios centrados en el método ECGI, y como consecuencia más o menos directa de ellos, se han desarrollado otros trabajos que pueden considerarse más marginales. Estos trabajos han proporcionado resultados que tienen interés, no sólo en el marco de ECGI, sino en otros ámbitos más generales del reconocimiento sintáctico de formas y/o la teoría de lenguajes. En particular:

Se ha mostrado la factibilidad y convergencia de un algoritmo que permite la corrección de errores en todo tipo de gramáticas regulares, independientemente de que tengan o no circuitos (véase algoritmo cíclico, capítulo 5).

Se ha demostrado que toda gramática regular tiene una gramática SANSAT equivalente y un autómata de estados etiquetados (LAS: "LAbelled State automata") también equivalente (capítulo 2). Ello proporciona un método de modelización de lenguajes que en ocasiones puede ser útil en reconocimiento de formas.

Se ha definido una nueva manera de asegurar la consistencia de las probabilidades de una gramática estocástica, expandida mediante un modelo de error convencional. Este modelo asegura la consistencia *de las reglas de error* y reduce la complejidad del análisis sintáctico cuando se utiliza el algoritmo de Viterbi. El modelo asume probabilidades de inserción independientes de la posición y del número de reglas asociadas a un no terminal.

Se ha introducido una técnica que permite la simplificación progresiva de gramáticas regulares estocásticas (o no), siempre que no tengan circuitos. Accesoriamente, se ha definido una cantidad (el "tráfico") que permite cuantificar la importancia estructural de un vértice o un arco pertenecientes a un grafo sin circuitos.

Se ha propuesto y comprobado un método para obtener la "cadena mediana" de un conjunto de cadenas (capítulo 11), utilizando la cadena más probable de la gramática inferida por ECGI para dicho conjunto de cadenas. Como alternativa para simplificar el cálculo de la cadena más probable, se han propuesto la *cadena más frecuente* y la *cadena localmente más frecuente*. Esta última permite obtener una buena aproximación a la cadena

mediana sin necesidad de recurrir a una búsqueda por optimización en la gramática inferida por ECGI.

Perspectivas

Muchas de las perspectivas que, en su momento, abrió ECGI al proporcionar los primeros resultados esperanzadores, han sido exploradas durante los años transcurridos desde entonces hasta la finalización de este texto (apéndice A): mejoras de complejidad temporal mediante búsqueda en haz, reconocimiento anticipado y examen tan sólo de los estados alcanzados [Torró,89]; utilización de las probabilidades durante el reconocimiento y reestimación estocástica de las mismas [Castaño,90]; modificación del algoritmo de inferencia para permitirles utilizar reglas que no pertenecen todas a la misma derivación [Miralles,91]; aplicación de ECGI para la inferencia de estructuras de modelos de Markov [Casacuberta,90] [Casacuberta,90a], para la inferencia de modelos de unidades subléxicas [Carpi,90] [Sanchis,91] [Tarazona,91], para la inferencia de modelos de lenguajes [Prieto,91] [Prieto,91a]; extensión de ECGI para la utilización de modelos semicontinuos [Arévalo,90],... La mayoría de estos trabajos han abierto a su vez nuevos posibles caminos y han dejado por resolver algunas cuestiones. En cualquiera de estos campos queda pues trabajo por hacer, habiendo demostrado el ECGI, no sólo ser una herramienta eficaz de reconocimiento, sino un método flexible, aplicable a muchos campos del reconocimiento de formas y susceptible de variadas extensiones y mejoras.

En general, las direcciones de más interés hacia la que se orientan, hoy por hoy, los trabajos sobre ECGI, se centran alrededor de la mejora de su capacidad de reconocimiento, recurriendo a las mismas técnicas que se utilizan en los modelos de Markov cuando es imposible sacar más partido a los símbolos provenientes de la cuantificación vectorial: el empleo de modelos (semi)continuos. Con estas aproximaciones, se espera mejorar notablemente las tasas de reconocimiento de ECGI a costa, eso sí, de un cierto aumento de la complejidad temporal (aunque probablemente pueda mantenerse inferior a la de los modelos de Markov en el mismo caso).

Por otra parte, existe la posibilidad extremadamente interesante de utilizar ECGI en reconocimiento del habla continua. La idea en este caso consiste en concatenar modelos aprendidos mediante el ECGI (de fonemas u otras unidades subléxicas) siguiendo reglas aprendidas por el mismo ECGI (modelos de lenguaje). En esto también se sigue la aproximación seguida anteriormente por otros autores, que construyen (manualmente) modelos de lenguajes a partir de la composición de modelos de Markov [Lee,88]. Los trabajos ya realizados en este campo (ver apéndice A) han ofrecido perspectivas interesantes, con buenos (no excelentes) resultados.

Apèndice A

Otros trabajos sobre ECGI

En paralelo con este trabajo se han realizado, en el interior del mismo grupo de investigación, varios estudios e implementaciones prácticas destinadas a mejorar las capacidades del ECGI desde diversos puntos de vista y a utilizarlo en diversas aplicaciones. Estos trabajos, derivados de éste, lo complementan, por lo que se reseñan a continuación.

Isabel Alfonso, en [Alfonso,91] llevó a cabo una implementación de ECGI que funciona a tiempo real, aprovechando las técnicas desarrolladas por F.Torró para disminuir la complejidad temporal de ECGI. Esto ha permitido comparar los tiempos de respuesta reales de ECGI con los de otros métodos de reconocimiento de formas (modelos de Markov, Redes neuronales), obteniéndose resultados significativamente favorables a ECGI.

Manuél Arévalo, en [Arévalo,90] implementa una versión semicontinua de ECGI, es decir, se estima una función de "densidad de probabilidad" en cada estado del modelo, que es utilizado entonces, no para inferir o reconocer a partir de símbolos discretos, sino a partir directamente de los vectores de parámetros (coeficientes cepstrales en este caso).

Francisco Casacuberta, en [Casacuberta,91] y junto con Begonia Mas, Enrique Vidal y H.Rulot en [Casacuberta,90], [Casacuberta,90a] utilizan los procedimientos de simplificación de autómatas descritos en el capítulo 10 para obtener, mediante simplificación de modelos inferidos por ECGI, la estructura de unos modelos de Markov que posteriormente entrenan con las técnicas clásicas de este campo. Finalmente, comparan los resultados obtenidos con los que proporciona ECGI, consiguiendo demostrar (ver capítulo 12) que los modelos inferidos por ECGI son, por lo menos, igualmente eficaces que modelos de Markov de no menos de 30 estados y que los métodos de simplificación propuestos en este trabajo conservan la información estructural de los modelos inferidos.

Asunción Castaño, en [Castaño,90] introdujo técnicas de reestimación estocástica para mejorar la fiabilidad de las probabilidades de los modelos inferidos por ECGI. Excepto para las primeras N (N arbitrario) muestras, la

inferencia es estocástica (se utilizan las probabilidades en la búsqueda de la derivación óptima). Cada N muestras siguientes se reestiman las probabilidades, utilizando el nuevo conjunto de frecuencias. El proceso se repite hasta que se cumpla cierto criterio de parada (p.e.: convergencia de las probabilidades). Los resultados obtenidos en reconocimiento, si bien no mejoran los de ECGI convencional, muestran la factibilidad de la idea de la reestimación de probabilidades.

M^a Isabel Galiano, en [Galiano, 90] introdujo un nuevo heurístico que le permitía simplificar autómatas inferidos por ECGI. A estos modelos simplificados, se les añadía luego un modelo duracional en los estados y se procedía a una reestimación de probabilidades. Las tasas de reconocimiento obtenidas no fueron todo lo buenas que se esperaba, aunque una revisión de la idea ha justificado la puesta en marcha de otro proyecto, actualmente en curso y que aún no ha proporcionado resultados.

Felipe Miralles, en [Miralles,91] modifica los heurísticos de inferencia de ECGI, para permitir que la que la secuencia de reglas identificada como la que genera la cadena más próxima a la cadena muestra *pueda no ser una derivación permitida* por la gramática actual en el momento de recibir la muestra (sólo se requiere que sea una combinación de fragmentos de derivaciones permitidas). La modificación realizada mantiene las características de las gramáticas inferidas por ECGI y produce en general modelos menos complejos, aunque con una mayor generalización (tamaño del lenguaje). Se introduce también un modelo de aprendizaje con muestras positivas y negativas. Sin embargo, los resultados de reconocimiento no han mostrado una clara mejora con respecto al ECGI convencional.

Natividad Prieto, H.Rulot, Emilio Sanchis y Enrique Vidal en [Prieto, 88] utilizaron el mismo corpus de letras habladas descrito en el capítulo 9, pero parametrizado con menos precisión (frecuencia de muestreo relativamente baja, clustering con pocos símbolos), obteniendo los resultados que se presentan en la tabla A.1. Estos resultados, como era de esperar por la inferioridad de la parametrización, son inferiores a los presentados en el capítulo 8, aunque a pesar de todo comparables a los que se obtienen con otros métodos de reconocimiento. La razón principal por la que se han incluido aquí es debido a que permiten observar como las tasas de reconocimiento empeoran generalmente (-0.5%) en el **caso de utilizar 10 tablas de sustitución** en vez de una única tabla promedio (ver capítulo 7) (aunque mejoran mucho más en un caso: +3%).

Tabla A.1 Tasas de aciertos y número de estados en los experimentos con las letras (aprendizaje 8 repeticiones por locutor y letra, 10 locutores, test 2 repeticiones -diferentes- por locutor y letra).

Experimento:	(L1) H,I,J,K,L,M,N,O,P,Q	(L2) F,L,LL,M,N,Ñ,R,S
Numero medio de estados	240	346
No estocástico	80,0%	60%
Estocástico		
Modelo de error Completo	83,5%	65,0%
Idem, pero 10 Tablas Sus.	86,5%	64,5%
Sólo substitución	79,0%	60,6%
Idem, pero 10 Tablas Sus.	78,5%	60,6%
Sin probabilidades de error	83,5%	61,2%

Natividad Prieto y Enrique Vidal, en [Prieto,91] y [Prieto,91a] proponen un método para la aplicación de ECGI a la inferencia de *modelos de lenguaje* y a la comprensión del habla continua. En estas técnicas se usa de forma homogénea el mismo algoritmo ECGI, tanto para el aprendizaje de un modelo de lenguaje semántico, como para el de los modelos acústicos asociados a las distintas categorías semánticas. Estos trabajos abren una nueva perspectiva en el desarrollo de aplicaciones de reconocimiento del habla continua en universos de semántica limitada, los cuales son los que suelen encontrarse en situaciones reales de aplicación práctica.

Emilio Sanchis y Francisco Casacuberta, en [Sanchis,90] y [Sanchis,91], y junto con M^aIsabel Galiano en [Galiano,91], utilizan el ECGI para la inferencia de modelos para unidades del habla de tamaño inferior a la palabra (fonemas, sílabas,...), con el fin de generar grandes vocabularios por concatenación de dichos modelos (siguiendo reglas posiblemente también inferidas por ECGI, aplicando los procedimientos propuestos en por N.Prieto). Otros trabajos basados también en la misma idea son los de *Sofía Carpi* [Carpi,90] y *Joaquín Tarazona* [Tarazona,91], que aprenden modelos de fonemas y los utilizan luego para llevar a cabo la decodificación acústico-fonética mediante el algoritmo de un paso (J.Tarazona utiliza una versión semicontinua de ECGI, como M.Arévalo en [Arévalo,91]).

Francesc Torró, en [Torró,90] propone y estudia varios métodos que permiten reducir drásticamente la complejidad temporal de ECGI durante el

reconocimiento. Utilizando técnicas de búsqueda en haz, reconocimiento anticipado y analizando sólo los estados alcanzados, obtiene las mismas tasas de aciertos visitando tan sólo un 9% de los vértices del trellis.

Apéndice B

Tablas complementarias

B.1 Número de estados de los autómatas inferidos

Se muestran a continuación una serie de tablas que contienen el número de estados de los autómatas inferidos en la mayoría de los experimentos presentados en el capítulo 8.

B.1.1 Dígitos Hablados:

	H1:	H2:	H3:	H4:	H5:	H6:	piloto
0	133	171	157	130	169	153	126
1	152	144	141	118	149	159	100
2	121	135	131	113	150	129	73
3	102	120	121	97	126	107	95
4	171	182	171	178	165	162	129
5	233	270	238	210	258	243	136
6	104	121	114	126	116	104	85
7	185	209	183	186	196	181	104
8	136	149	203	140	141	147	105
9	196	220	203	171	242	202	110
Total	1533	1721	1599	1469	1712	1587	1063

HLKO1 H55:	H11:	H22:	H33:	H44:	
0	193	175	187	178	180
1	179	177	194	182	186
2	150	155	140	138	141
3	126	141	131	121	131
4	213	228	217	203	222
5	340	314	326	305	332
6	131	148	156	123	149
7	236	250	236	216	223
8	188	175	186	174	175
9	225	242	223	220	243
	1981	2005	1996	1860	1982

B 1.2 Letras Habladas:

L1:	L2:	L3:	L4:
H 854	F 763	LL 882 M 784	LL 592 M 561
I 332	L 797	RR 914 N 696	RR 696 N 468
J 676	LL 882	CH 495 O 271	CH 387 O 243
K 316	M 784	A 304 P 472	A 281 P 356
L 797	N 696	B 514 Q 271	B 393 Q 210
M 784	Ñ 901	C 781 R 708	C 583 R 497
N 696	R 708	D 541 S 817	D 388 S 584
O 271	RR 967	E 478 T 470	E 346 T 346
P 531	S 817	F 763 U 235	F 574 U 199
Q 309		G 624 V 697	G 436 V 496
		H 838 W 1202	H 626 W 810
		I 332 X 681	I 249 X 544
		J 676 Y 1218	J 452 Y 825
		K 316 Z 959	K 276 Z 670
		L 752 Ñ 901	L 568 Ñ 631
5566	7315	17502	14287

LLKO	L11:	L22:	L33:	L44:	L55:
F	823	787	759	753	721
L	849	732	766	731	768
LL	915	847	860	828	762
M	780	756	811	734	751
N	721	690	674	638	619
Ñ	885	870	895	834	834
R	717	663	702	672	653
RR	954	924	953	905	898
S	843	790	757	774	736
	7487	7059	7177	6869	6742

B.1.3 Dígitos Manuscritos:

Experimento con Rejilla 4												
	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12
cero	225	218	222	218	219	220	218	214	213	218	163	152
uno	250	263	246	242	238	239	233	235	208	202	237	271
dos	364	357	361	391	386	379	383	391	389	386	381	365
tres	351	365	355	368	357	345	353	370	371	365	363	349
cuat	315	340	352	357	342	313	325	353	359	356	355	335
cinco	380	349	354	357	349	341	349	352	358	359	344	336
seis	257	252	255	255	247	235	242	248	247	252	257	273
siete	365	370	367	387	383	376	382	385	383	381	359	349
ocho	309	295	310	331	322	319	322	302	298	319	324	320
nueve	279	281	285	285	262	255	285	283	280	284	275	285
	3096	3090	3107	3191	3105	3022	3092	3133	3106	3122	3058	3035

Experimento con Rejilla 6												
	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12
cero	149	149	157	153	152	152	153	153	151	152	112	106
uno	168	179	190	190	188	189	185	186	171	166	188	181
dos	268	245	251	263	257	262	263	271	268	268	264	273
tres	278	258	248	246	236	235	239	245	246	244	243	245
cuat	245	239	251	248	240	211	222	244	246	248	248	236
cinco	261	268	274	276	274	273	274	278	280	279	273	254
seis	197	183	182	176	174	166	172	177	176	181	182	184
siete	257	283	267	271	263	259	264	279	278	275	245	261
ocho	229	211	215	243	235	236	235	223	223	237	241	229
nueve	205	206	211	218	193	190	204	204	203	207	200	196
	2257	2221	2246	2284	2212	2173	2211	2260	2242	2257	2196	2165

Experimento con Rejilla 8												
	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12
cero	118	120	121	119	120	118	119	118	117	118	85	91
uno	137	140	132	147	146	144	137	138	134	126	142	136
dos	202	205	197	206	208	208	207	212	213	211	208	204
tres	223	206	210	202	205	198	191	199	205	203	200	211
cuat	179	185	193	193	186	168	176	194	198	193	190	180
cinco	210	217	218	219	213	213	218	226	226	228	220	192
seis	152	140	142	136	127	128	140	142	141	144	146	153
siete	208	217	217	218	226	223	225	229	225	230	212	198
ocho	159	162	170	177	174	171	172	165	166	169	172	183
nueve	163	153	166	168	139	139	169	165	165	166	160	160
	1751	1745	1766	1785	1744	1710	1754	1788	1790	1788	1735	1708

Experimento con Rejilla 10												
	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12
cero	94	91	96	91	90	96	95	95	94	96	70	73
uno	111	116	115	112	108	109	110	110	97	94	109	111
dos	187	155	163	177	177	174	176	180	186	184	176	171
tres	185	173	173	173	168	164	161	167	166	163	164	168
cuat	146	145	150	151	148	140	144	151	154	153	152	151
cinco	170	176	186	193	189	183	185	189	190	190	187	159
seis	119	119	122	120	121	119	118	120	122	123	124	126
siete	174	183	181	187	183	181	182	181	183	183	172	152
ocho	147	144	136	148	141	139	145	134	132	135	141	137
nueve	141	136	133	134	113	117	137	132	131	132	128	127
	1474	1438	1455	1486	1438	1422	1453	1459	1455	1453	1423	1375

B.1.4 Dígitos Impresos:

Experimento con Rejilla 4								
	R1	R2	R3	R4	R5	R6	R7	R8
cero	135	139	142	141	141	142	142	142
uno	230	264	271	285	288	285	290	291
dos	296	308	300	295	283	302	301	301
tres	298	319	339	333	320	335	339	339
cuat	221	250	245	249	245	248	248	250
cinco	341	337	351	353	343	353	355	357
seis	219	246	253	243	239	247	247	246
siete	225	240	251	252	237	249	256	249
ocho	186	175	178	182	176	180	176	181
nueve	227	256	252	248	247	255	256	256
	2378	2534	2582	2581	2519	2596	2610	2612

Experimento con Rejilla 6								
	R1	R2	R3	R4	R5	R6	R7	R8
cero	91	90	94	93	95	95	93	95
uno	165	166	154	152	158	157	157	160
dos	221	224	228	236	218	237	235	234
tres	210	211	219	220	209	220	222	221
cuat	162	175	157	163	157	158	164	165
cinco	257	248	265	265	245	260	264	266
seis	154	176	164	160	152	165	165	166
siete	171	164	175	179	170	179	179	179
ocho	115	115	121	120	118	120	120	121
nueve	166	186	165	163	156	166	166	165
	1712	1755	1742	1751	1678	1757	1765	1772

Experimento con Rejilla 8								
	R1	R2	R3	R4	R5	R6	R7	R8
cero	68	75	76	76	75	76	76	76
uno	115	131	131	131	136	136	138	136
dos	150	158	158	156	153	161	160	159
tres	169	187	191	184	172	190	190	191
cuat	121	124	126	125	128	122	128	128
cinco	193	190	191	195	184	190	192	192
seis	136	130	121	123	119	125	126	123
siete	125	118	126	128	121	127	128	125
ocho	99	92	97	96	92	94	97	95
nueve	128	141	137	134	128	139	139	138
	1304	1346	1354	1348	1308	1360	1374	1363

Experimento con Rejilla 10								
	R1	R2	R3	R4	R5	R6	R7	R8
cero	59	58	60	59	59	59	59	60
uno	104	118	112	117	121	122	117	122
dos	136	141	149	148	141	149	147	148
tres	151	148	159	156	151	157	157	157
cuat	101	99	102	103	100	101	102	103
cinco	138	151	157	157	152	156	159	159
seis	100	112	113	106	110	112	113	113
siete	101	103	111	113	106	111	112	109
ocho	74	80	89	89	84	89	87	89
nueve	105	107	115	109	109	116	116	116
	1069	1117	1167	1157	1133	1172	1169	1176

B.2 Matrices de confusión

En las matrices de confusión que se incluyen a continuación (las correspondientes a los experimentos de reconocimiento de imágenes) no figuran las diagonales y se han substituído los ceros por puntos, con el fin de mejorar la legibilidad.

B.2.1 Dígitos Manuscritos (sólo substitución)

Experimento con Rejilla 4										
	0	1	2	3	4	5	6	7	8	9 (Clase correcta)
cero
uno	5	.	.	3	.	1
dos	.	9	12	1
tres	6	27
cuat
cinco
seis	2
siete	11	4
ocho	2
nueve	.	1	.	.	4	.	.	.	4	.
Errores por clase:	4	10	0	0	20	0	0	3	22	33
92 errores de 4800 muestras: 98.08% aciertos										

Experimento con Rejilla 6										
	0	1	2	3	4	5	6	7	8	9 (Clase correcta)
cero
uno	1	.	.	2	.	2
dos	.	8	12	.
tres	6	12
cuat	1	.
cinco	6
seis	3	1	.
siete	4
ocho	3	4
nueve	.	5	.	.	10	.	.	2	7	.
Errores por clase:	6	13	0	0	15	0	0	4	27	24
89 errores de 4800 muestras: 98.15% aciertos										

Experimento con Rejilla 8										
	0	1	2	3	4	5	6	7	8	9 (Clase correcta)
cero
uno	6	.	.	12	.	5
dos	.	5	1	.	.
tres	3	18
cuat	1	8
cinco	13
seis	3	3	.
siete	.	.	1	.	5	.	.	.	4	.
ocho	2	2	2	.	.	1
nueve	.	19	.	.	16	.	.	.	18	.
Errores por clase:	5	24	1	0	27	2	2	13	29	45
148 errores de 4800 muestras: 96.92% aciertos										

Experimento con Rejilla 10										
	0	1	2	3	4	5	6	7	8	9 (Clase correcta)
cero	13	2
uno	8	.	1	11	3	10
dos	.	16	1	.	.
tres	6	26
cuat	1	1	6
cinco	.	.	.	4
seis	7	.
siete	.	.	1	.	4	.	.	.	3	5
ocho	6	10
nueve	.	2	.	1	19	.	.	.	10	.
Errores por clase:	6	18	1	5	31	0	1	13	43	59
177 errores de 4800 muestras: 96.31% Aciertos										

B.2.2 Dígitos impresos (sólo sustitución)

Experimento con Rejilla 4										
	0	1	2	3	4	5	6	7	8	9 (Clase correcta)
cero
uno
dos
tres
cuat
cinco
seis
siete	.	1
ocho
nueve
Errores por clase:	0	1	0	0	0	0	0	0	0	0
1 errores de 3200 muestras: 99.97%										

Experimento con Rejilla 6										
debe ser->	0	1	2	3	4	5	6	7	8	9 (Clase correcta)
cero	1	.
uno
dos
tres
cuat
cinco
seis
siete	.	11
ocho	1	4	.	.	1
nueve
Errores por clase:	1	11	0	0	0	0	4	0	1	1
18 errores de 3200 muestras: 99.44%										

Experimento con Rejilla 8										
	0	1	2	3	4	5	6	7	8	9 (Clase correcta)
cero	.	3	7	.
uno
dos
tres
cuat
cinco
seis
siete	.	4
ocho	1	.	.	2	.	.	8	.	.	1
nueve	.	.	.	9
Errores por clase:	1	7	0	11	0	0	8	0	7	1
35 errores de 3200 muestras: 98.91%										

Experimento con Rejilla 10										
	0	1	2	3	4	5	6	7	8	9 (Clase correcta)
cero	.	1	7	.
uno
dos
tres	1	.
cuat
cinco
seis	1
siete	.	1
ocho	2	.	.	.
nueve
Errores por clase:	1	2	0	0	0	0	2	0	8	0
13 errores de 3200 muestras: 99.59%										